

Eötvös Loránd Tudomány Egyetem

Meteorológiai Tanszék

**A természetes eredetű szén-dioxid fluxus és a
vegetáció időbeli fejlődésének modellezése a
SURFEX modell segítségével**



Készítette:

Kelemen Fanni Dóra

Meteorológus Msc

Témavezető:

Kullmann László

(Országos Meteorológiai Szolgálat)

Tanszéki konzulens:

dr. Barcza Zoltán

(ELTE Meteorológiai Tanszék)

Budapest, 2011.

Tartalomjegyzék

1. Bevezetés.....	3
2. SURFEX	6
2.1. Az ISBA és az ISBA-A-gs.....	7
2.1.1 ISBA-A-gs.....	9
2.2. A SURFEX alkalmazása	16
3. Felhasznált adatok	19
3.1. Műholdas mérések.....	20
3.2. Hegyhátsáli mérések	23
4. Az adatasszimiláció	25
4.1. A Kálmán-szűrő	26
4.2. A Kálmán-szűrő alkalmazása a SURFEX-ben	32
5. Eredmények.....	35
5.1. A SURFEX általános vizsgálata.....	35
5.1.1. Fűves terület	36
5.1.2. Összetett vegetáció	42
5.2. Az adatasszimilációs vizsgálatok	44
5.2.1. Fűves terület	44
5.2.2. Összetett vegetáció	53
6. Összefoglalás	61
7. Köszönetnyilvánítás.....	63
8. Irodalomjegyzék.....	64
9. Függelék.....	68

1. Bevezetés

A mai meteorológia alapvető eszköze a modellezés. A kutatások és az operatív munka is nagyban támaszkodik a különböző modellek eredményeire. A meteorológiai modellek folyamatosan fejlődnek, egyre bonyolultabbá és átfogóbbá válnak. Ma már a fejlett időjárás és éghajlat modellekben nem kizárólag a légkört, hanem a vele kapcsolatos szférákat is figyelembe veszik. A felszín folyamatait, amelyekben szerepe van a talajnak, a növényzetnek és a légkörnek is, úgynevezett felszín modellek írják le. A felszín modellekkel kapott felszíni áramok pontosíthatják a meteorológiai modellek előrejelzéseit, és segítik környezetünk megértését.

A talaj-növényzet-légkör transzfer modelleket eredetileg a felszín, és a légkör közötti anyag és energia áramok modellezésére fejlesztették ki, ezekben a vegetáció állapotát, mint bemenő paramétert kezelték. A modellek fejlődésével viszont lehetőség nyílt a vegetáció dinamikus leírására, ezáltal a növényzetet jellemző levélfelületi index (Leaf Area Index, LAI) is prognosztikai változóvá vált. A LAI egy olyan mérőszám, ami a levélfelület nagyságát adja meg a felszín egységnyi területére vonatkozóan, ezáltal jól jellemzi a növényzet állapotát.

Dolgozatomban a természetes eredetű szén-dioxid (CO_2) fluxus és a vegetáció időbeli fejlődésének modellezését vizsgáltam a SURFEX felszín modellel. Először pusztán a modellt, majd az adatasszimiláció alkalmazását, és annak eredményeit vizsgáltam. Munkám kapcsolódik a GEOLAND2 projekthez (www.gmes-geoland.info), melyben az Országos Meteorológiai Szolgálat is részt vesz. A GEOLAND2 projekten belül a Land Carbon munkacsoport foglalkozik egy, a szárazföldi szén ciklust befolyásoló változókat összefoglaló pre-operatív infrastruktúra felállításával. Ehhez a munkához kapcsolható a diplomamunkám is.

A munkám során a SURFEX-en belül a természetes felszínt leíró ISBA, és annak fotoszintézist is modellező változatát, az ISBA-A-gs sémát használtam. Az ISBA-A-gs interaktív módon számítja a LAI fejlődését, és ezáltal a növényzettel összefüggő természetes CO_2 áramot is. Gibelin et al. (2006) globális skálán összehasonlította az ISBA-A-gs séma LAI szimulációit műholdas mérésekkel, és azt tapasztalta, hogy a séma képes a LAI általános változásának leírására. A séma nagyobb felbontású vizsgálatánál (Brut et al., 2009) viszont már figyelembe kell venni a vegetáció különböző típusait, és egy rácsponton

belüli vegetáció összetételét is. Mi a vizsgálataink során főként egy rácspontra futtattuk a modellt (hegyhátsági mérőállomás). Először egy egyszerű, csupán egyetlen vegetáció típust tartalmazó beállítás, majd a rácsponton belüli vegetáció összetételét is figyelembe vevő, több vegetáció típust tartalmazó beállítás eredményeit vizsgáltuk.

A meteorológiai modell eredmények pontosabbá tételének hatékony eszköze az adatasszimiláció. Az adatasszimiláció során megfigyelések és egy ún. háttér mező felhasználásával pontosabb kezdeti feltételeket készítünk a modell számára. A pontosabb kezdeti feltételnek köszönhetően pedig az előrejelzés is pontosabbá válhat.

A dolgozat elkészítése során a Kálmán-szűrő módszerével asszimiláltunk LAI, és a gyökérszóna talajnedvességéről információt adó talajnedvesség index (Soil Wetness Index, SWI) értékeket. A LAI és a gyökérszóna talajnedvessége több fontos folyamatot befolyásoló változók, amelyek hosszú memóriával rendelkeznek, ezért helyes inicializálásuk fontos az előrejelzés szempontjából. A LAI fontos szerepet játszik a felszíni vízgőz és CO₂ áramok alakulásában. A gyökérszóna talajnedvessége pedig jelentős szerepet játszik a latens és szenzibilis hőáram szétválasztásában, ezen kívül a növényzet növekedése szempontjából is fontos változó. A SURFEX adatasszimilációs rendszerén belül lehetőség van a Kálmán-szűrő kiterjesztett (Extended Kalman Filter, EKF), és annak egyszerűsített (Simplified Extended Kalman Filter, SEKF) változatának alkalmazására. Több vizsgálat született már a talajnedvesség asszimilálásáról a SURFEX-en belül. Mahfouf (2010) műholddal mért felszíni talajnedvesség adatokat használt fel a felszíni, és a gyökérszóna talajnedvesség értékek változtatására, az SEKF módszerrel. Draper et al. (2009) Mahfouf-hoz hasonlóan szintén műholddal mért talajnedvesség értékeket asszimilált, de nem csak az SEKF, hanem a bonyolultabb EKF módszerrel is. A LAI, és az általunk is használt SWI együttes alkalmazásának előnyeit Barbu et al. (2011) vizsgálta meg, de csak az SEKF módszerrel, és csak egyféle vegetációtípusra. Az általunk elvégzett asszimilációs kísérletek a fent felsoroltaktól abban különböznek, hogy mi az SEKF és az EKF módszert is alkalmaztuk LAI, és SWI együttes asszimilálásához, egy egyszerű, és egy összetett vegetációjú beállítás esetén is. Az összetett vegetációjú beállítás vizsgálatának előnye, hogy a tapasztalatok később felhasználhatóak a kiterjesztett 2 dimenziós futtatásoknál. Megemlítendő, hogy az EKF módszerrel, összetett vegetációjú beállítás mellett sem a LAI, sem a LAI és az SWI együttes asszimilálását nem vizsgálta még előtünk senki.

A dolgozat első felében bemutatom a SURFEX modellt, és részletesebben kitérek az általunk alkalmazott ISBA és ISBA-A-gs sémákra. A 3. fejezetben a felhasznált mérési adatokat foglalom össze. Ezután bemutatom az általunk használt adatasszimilációs módszert, és a SURFEX-en belüli alkalmazását. Az 5. fejezetben az eredményeinket, fejlesztéseinket foglalom össze. A fejezet első felében a modell általános vizsgálatát, a második felében pedig az adatasszimilációval végzett futtatások eredményeit mutatom be. Végül a 6. fejezetben összegzem a dolgozat során elvégzett vizsgálatokat, tapasztalatokat, és azok alapján levonható következtetéseket.

2. SURFEX

A SURFEX (SURFace EXternalized module) (Le Moigne, 2009) modellcsomag a numerikus időjárás előrejelző modellekben leggyakrabban használt felszíni folyamatokkal kapcsolatos parametrizációs modulokat foglalja magában. A SURFEX-et a kétezres évek végén fejlesztették ki a francia meteorológiai szolgálatnál azzal a céllal, hogy a Centre National de Recherches Météorologiques (CNRM) által használt, és fejlesztett felszíni sémákat széles körben elérhetővé tegyék.

Mint a neve is mutatja a SURFEX egy externalizált programcsomag, amely azt jelenti, hogy a programkód nem szerves része a légköri folyamatokat leíró modellnek, csupán egy interfészen keresztül csatlakozik ahhoz (a csatolt légkör-óceán modellekhez hasonlóan). A SURFEX elvben bármely légköri modellhez kapcsolható, amennyiben megfelelő interfészt választunk. Jelenleg az ALADIN/AROME korlátos tartományú, és az ARPEGE globális numerikus előrejelző modellekben használják operatíván, valamint a MESO-NH kutatói modellben.

A felszín és a légkör összekapcsolása, azaz a SURFEX és a légköri modell között a kapcsolat lehet egyirányú (offline futtatás), illetve kétirányú (online futtatás). A kétféle futtatás között az a különbség, hogy az offline esetben csak a légkör hat a felszínre, míg az online beállításnál a felszín is visszahat a légkörre, ezáltal aktív módon részt vesz az időjárási folyamatok alakításában. A felszíni modell futtatásához tehát mindig szükséges a légköri kényszerek megadása, de a számítások eredményeül kapott felszíni áramok csak az online esetben kerülnek vissza a légkörbe. Az offline futtatásnál a légköri kényszereket vehetjük egy már lefuttatott időjárás előrejelző modellből, vagy akár egy reanalízis adatbázisból is.

A SURFEX négy fő felszínípust különböztet meg, nevezetesen a természetes, a városi, a tenger, és a tó felszín, ezért négy fő parametrizációs sémát tartalmaz. A természetes felszínhez az ISBA (Interaction between Soil, Biosphere and Atmosphere) elnevezésű felszín-légkör kölcsönhatás modell tartozik. Az ISBA-t a '80-as évek végén fejlesztették ki (Noilhan et al., 1989) oly módon, hogy a lehető legkevesebb paraméter felhasználásával írja le a felszín (talaj, növényzet, hóval borított felszín), és a légkör közötti energia- és vízcserét. Az ISBA egy fejlettebb verziója az ISBA-A-gs (Calvet et al., 1998), amely egy egyszerűsített fotoszintézis sémát is tartalmaz. Az ISBA-A-gs-ben figyelembe van véve a

növények szén-dioxid asszimilációja, és ezen keresztül a vegetáció fejlődése, tekintettel a környezeti kényszerekre. Az ISBA-A-gs séma a CNRM által fejlesztett SURFEX modell része, de a fizikáját felhasználták az ECMWF felszíni modelljében, a TESSEL-ben is. A TESSEL A-gs-sel kibővített változata a C-TESEL (Voogt et al., 2006)

A városi felszín kezelésére 2000-ben fejlesztették ki a TEB (Town Energy Balance) modellt (Masson, 2000), amely tulajdonképpen kanyonként kezeli a városi felszínt a korábban alkalmazott kopár talaj közelítés helyett. Ezáltal lehetőség van a városi energia egyenleg pontosabb leírására, a momentum, a turbulens hő és a talaj hőáramának kifinomultabb kezelésére.

A harmadik fő felszíntípus a tengerfelszín, amely felett a modell meghatározott tengerfelszín hőmérséklet mellett számítja a felszíni áramokat.

A negyedik és egyben utolsó felszíni séma a mezo skálán már lényeges, szárazföldön belüli vízfelszínekre, azaz a tavakra vonatkozik. A tavak energia egyenlegének kezelésére, és a változó vízfelszín hőmérsékletének leírására az egyszerű, de robusztus Flake modellt (Mironov, 2005) vezették be a SURFEX-be.

2.1. Az ISBA és az ISBA-A-gs

Diplomamunkámban a természetes eredetű CO₂ fluxus és a LAI időbeli fejlődésének vizsgálatával foglalkoztam, ezért a SURFEX modell ISBA sémájára koncentráltam.

Az ISBA egy ún. force-restore módszeren alapuló modell, amely a talaj hőmérsékletének és nedvességének időbeli változását írja le. A hőmérsékletre vonatkozó prognosztikai változók a felszíni hőmérséklet T_s (a talaj legfelső 10 cm-e), és a talajhőmérséklet átlaga T_2 (az egész talajrétegre vonatkozóan). A hőmérsékleti változókra vonatkozó force-restore egyenletekben (2.1 és 2.2) (Bhumralkar, 1975; Blackadar, 1976) a felszíni hőmérséklet alakulására vonatkozó külső kényszerek („force” tag) a felszínre beérkező sugárzás, a latens és a szenzibilis hőáram. A „restore” tag jelképezi a felszíni hőmérséklet simulását az átlagos talajhőmérséklet értékhez. A prognosztikai egyenletek tehát:

$$\frac{\partial T_s}{\partial t} = C_T(R_n - H - LE) - \frac{2\pi}{\tau}(T_s - T_2) \quad (2.1)$$

$$\frac{\partial T_2}{\partial t} = \frac{1}{\tau}(T_s - T_2) \quad (2.2)$$

ahol R_n a felszíni nettó sugárzás, H és LE a szenzibilis, és a látens hőáram, a τ idő paraméter (jelen esetben egy nap), a C_T együttható pedig magában foglalja a talaj, a hó és a vegetáció hőkapacitásának értékét a felszíni arányoknak megfelelő mértékben.

Az ISBA-nak létezik két, illetve három talajréteget definiáló változat is (Boone et al., 1999). Munkám során a három rétegű verziót használtam. Ebben az esetben a felszíni pár centiméteres talajrétegen, és a gyökérszónán kívül definiálva van még egy réteg, az úgynevezett alapáramlási zóna. A talajnedvesség prognosztikai változói ez alapján tehát a felszíni réteg talajnedvessége w_g , a gyökérszóna talajnedvessége w_2 , és a legalsó, alapáramlási réteg talajnedvessége w_3 . A talajnedvesség értékeket is a force-restore módszer alapján számolja az ISBA (Deardorff 1977; Boone et al., 1999) (2.3, 2.4 és 2.5).

$$\frac{\partial w_g}{\partial t} = \frac{c_1}{\rho_w d_1} (P_g - E_g) - \frac{c_2}{\tau} (w_g - w_{geq}), \quad 0 \leq w_g \leq w_{sat} \quad (2.3)$$

$$\frac{\partial w_2}{\partial t} = \frac{1}{\rho_w d_1} (P_g - E_g - E_{tr}) - \frac{c_3}{d_2 \tau} \max[0, (w_2 - w_{fc})] - \frac{c_4}{\tau} (w_2 - w_3) \quad (2.4)$$

$$\frac{\partial w_3}{\partial t} = \frac{d_2}{(d_3 - d_2)} \left\{ \frac{c_3}{d_2 \tau} \max[0, (w_2 - w_{fc})] + \frac{c_4}{\tau} (w_2 - w_3) \right\} - \frac{c_3}{(d_3 - d_2) \tau} \max[0, (w_3 - w_{fc})] \quad (2.5)$$

$$0 \leq w_3 \leq w_{sat}$$


A felszíni réteg kényszerei („force” tag) a felszínre jutó folyékony víz árama (P_g) (csapadék, olvadó hó, és a növények leveléről lehulló víz), és az evaporáció (E_g). A gyökérszóna ettől abban különbözik, hogy ott már megjelenik a növények által elpárologtatott víz árama, a transzspiráció is (E_{tr}). A felszíni réteg talajnedvessége a „restore” tagon keresztül az egyensúlyi talajnedvesség értékhez (w_{geq}) közelít. A w_{geq} az a talajnedvesség érték, amikor a gravitáció és a kapilláris erő egyensúlyt tart egymással. A gyökérszóna egyenletében (2.4) a jobb oldal második tagja a rétegből elszivárgó víz hatását jelöli. Az elszivárgás akkor fordul elő, ha a talajnedvesség értéke meghaladja a szabadföldi vízkapacitás (field capacity, w_{fc}) értékét, mivel a szabadföldi vízkapacitás azt a maximális talajnedvesség értéket jelöli, amelyet a talaj meg tud tartani. A gyökérszóna talajnedvesség tartalmát befolyásolhatja még az alatta levő rétegből a kapilláris emelés által feláramló víz, ezt a 2.4-es egyenlet jobb oldalának utolsó tagja írja le. Az alapáramlási zóna talajnedvesség értékét (2.5) a tömegmegmaradás értelmében a felette elhelyezkedő zóna ezen réteggel kapcsolatban lévő folyamatainak komplementer folyamatai, és a rétegből

elszivárgó víz mennyisége alakítja ki. Az egyenletekben szereplő C_1, C_2, C_3, C_4 együtthatók, és a w_{geq} értéke a talajtextúrák figyelembevételével lett meghatározva. A w_{sat} a telítettségi talajnedvesség érték, a ρ_w a víz sűrűsége, a d_1, d_2, d_3 értékek pedig az egyes talajrétegek mélységét jelölik.

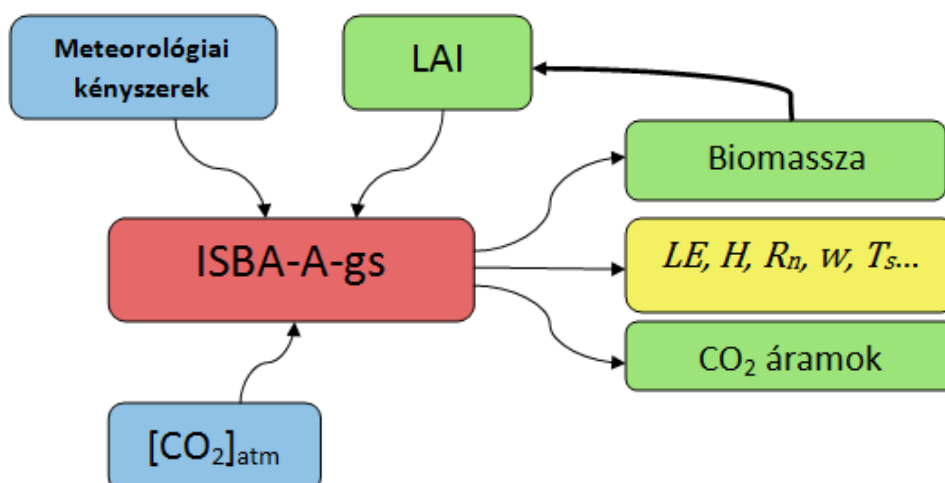
2.1.1 ISBA-A-gs

A vegetáció fejlődésének leírásával az ISBA-A-gs séma foglalkozik (Calvet et al., 1998; Gibelin et al., 2006).

Az ISBA, és az ISBA-A-gs séma közötti fő különbségeket a 2.1-es és a 2.2-es ábra mutatja be. Az ábrákról leolvasható, hogy míg az ISBA-nál a LAI egy bemeneti paraméter, addig az ISBA-A-gs sémánál a LAI is egy dinamikusan számított modellváltozó. A futtatáshoz szükséges LAI értékeket az ISBA egy külső adatbázisból határozza meg. Ez azt jelenti, hogy az ISBA-ban a LAI értéke egy havonta változó paraméter. Az ISBA-A-gs viszont naponta számítja a LAI értékét a biomasszából, aminek számításánál figyelembe veszi a növények CO_2 asszimilációját, és a respirációt. Ezáltal információt kapunk a természetes eredetű CO_2 áramokról is.



2.1. ábra. Az ISBA szerkezete (LE a latens hőáram, H a szenzibilis hőáram, R_n a nettó sugárzás árama, w a talajnedvesség, T_s pedig a felszíni talajhőmérséklet).



2.2. ábra. AZ ISBA-A-gs szerkezete.

Az ISBA-A-gs sémát a SURFEX a természetes felszínű területekre alkalmazza, de a természetes felszínt nem tekinti homogénnek, hanem 12 különböző vegetációtípust különít el. Egy adott rácspont természetes felszínét 12 parcellára osztja fel a 12 vegetációtípusnak megfelelően. Ezután a parcellák arányát az ott meghatározott természetes ökoszisztémának megfelelően állítja be egy felszíni jellemzőket tartalmazó adatbázis segítségével. Az ISBA-A-gs a parcellákat egymástól függetlenül kezeli, minden parcellának megvan a maga víz és energia egyenlege a rácspont területén belül. Az ISBA-A-gs-ben alkalmazott 12 vegetációtípust a 2.1 táblázat foglalja össze.

Parcella	Felszín típus
1	kopár talaj
2	szikla
3	állandó hó
4	lombhullató erdő
5	tűlevelű erdő
6	örökzöld erdő
7	C3-as mezőgazdasági növények
8	C4-es mezőgazdasági növények
9	öntözött növények
10	mérsékelt övi füves terület
11	trópusi füves terület
12	lápok, parkok, kertek

2.1 táblázat. Az ISBA 12 vegetáció típusa.

Az első három típus azokat a természetes felszíneket jelöli, ahol nem található növényzet, a 4-es, 5-ös és 6-os parcella a fás szárú növényzetet jelöli, a maradék hét parcella pedig a lágyszárú növények közül kerül ki. A C3-as illetve a C4-es jelölés a növények különböző szén megkötési módjára, azaz a fotoszintézis során végbemenő eltérő biokémiai folyamatokra utal. A C3-as növények közé tartozik a Föld vegetációjának nagy része, a C4-es növények pedig főként a trópusi fűfélék illetve pár kultúrnövény (kukorica, cirok, köles, cukornád) (Calvet et al., 2008). Az általunk vizsgált rácspontban a fenti vegetációtípusok közül az általunk használt felszíni adatbázis szerint a 4-es, az 5-ös, a 7-es, a 8-as és a 10-es fordul elő. Ez az összetétel (a parcella hányadokat is figyelembe véve) ráillik a főként mezőgazdasági művelés alatt álló, helyenként erdős illetve füves térségre, ami a hegyhátsági mérőtorony környezetében található (lásd alább).

A séma interaktív módon számítja a LAI illetve a biomassa értékét, ezáltal képes a vegetáció éves változékonyságának modellezésére. A biomasszát a növények által asszimilált szén növeli, a légzés pedig csökkenti. Az aktív biomassa, és a LAI között az ISBA-A-gs-ben lineáris kapcsolatot feltételeznek, ahol a lineáris együttható függ az éghajlati körülményektől, és a növény nitrogén tartalmától is.

A séma első verziójában egyetlen biomassa tározó van definiálva (Calvet et al., 1998), ami a fotoszintetikus aktív vegetációt, tehát a leveleket és a szár illetve a gyökérzet egy részét reprezentálja. A későbbiekben a séma ki lett egészítve még két biomassa rezervoárral, nevezetesen a szerkezeti illetve a felszín alatti szerkezeti biomasszával (Calvet and Soussana, 2001). Az aktív biomassa számítása azonban nem változott:

$$B(t + \Delta t) = B(t) + \Delta B^+ - \Delta B^- \quad (2.6)$$

A 2.6 egyenletben ΔB^+ a biomassa növekedését, ΔB^- pedig az elhalását jelenti, amelyeket hozzáadunk az előző napi biomassa értékhez. A biomassa növekedése az elmúlt nap, a növényállományban összegyűlt nettó CO₂ asszimilációjától ($A_{nl,day}$) függ (2.7):

$$\Delta B^+ = \frac{M_C}{P_C M_{CO_2}} A_{nl,day} \Delta t \quad (2.7)$$

ahol P_C a száraz biomassa széntartalma, M_C és M_{CO_2} pedig a szén és a szén-dioxid moláris tömege. Az $A_{nl,day}$ kiszámításához először ki kell számolnunk a levelek szintjén a nettó CO₂ asszimiláció értékét (Gourdian et al., 1985) (2.8 és 2.9).

$$A_m = A_{m,max} \left[1 - \exp \left\{ \frac{-g_m^*(C_i - \Gamma)}{A_{m,max}} \right\} \right] \quad (2.8)$$

$$A_n = (A_m + R_d) \left[1 - \exp \left\{ -\frac{\varepsilon I_a}{A_m + R_d} \right\} \right] - R_d \quad (2.9)$$

A 2.8-as egyenlet a növény CO₂ asszimilációjának a levegőben lévő CO₂ koncentráció által befolyásolt értékét adja meg, amit a sugárzás tovább limitál a 2.9-es egyenlet alapján. A 2.8-as egyenletben szereplő $A_{m,max}$ a maximális CO₂ asszimiláció értéke, ami főként a levél felületnek hőmérsékletétől függ. A C_i a levélben lévő CO₂ koncentráció, amit a levegő nedvesség tartalma és CO₂ koncentrációja befolyásol. A Γ az úgynevezett kompenzációs CO₂ koncentráció, az a koncentráció érték, ami mellett az asszimiláció pont kiegyenlíti a légzést, g_m^* pedig a mezofill réteg vezetőképessége. A 2.8-as egyenletet úgy lehetne összefoglalni, hogy a CO₂ asszimiláció annál nagyobb, minél nagyobb a mezofill réteg vezetőképessége, illetve minél nagyobb a levélben a CO₂ koncentráció. A 2.9-es egyenlettel a CO₂ asszimiláció, sugárzás által befolyásolt tagját kapjuk meg. I_a jelenti a fotoszintetikusan aktív sugárzást, ε a kezdeti kvantum felhasználás hatékonyságát, azaz hogy a sugárzás mekkora részét tudja a növény hasznosítani, R_d pedig a sötét lélegzés (2.10).

$$R_d = \frac{A_m}{9} \quad (2.10)$$

A 2.9-es egyenlet jobb oldalának első tagja tehát leírja, hogy a fotoszintézis során a növény mennyi CO₂-t tudott asszimilálni, ami természetesen annál több, minél több volt a növény által hasznosítható fotoszintetikusan aktív sugárzás. A második tag pedig a légzés általi CO₂ veszteséget jelöli. Így eredményül megkapjuk a nettó CO₂ asszimiláció értékét (A_n). Ezután ahhoz, hogy megkapjuk a teljes növényállomány által asszimilált CO₂ értékét (A_{nl}), már csak összegezni kell A_n -t a növényzet teljes egészére. Az integrálás során figyelembe vesszük a beérkező sugárzás gyengülését a növényállományban, és az összegzésnél nincsenek figyelembe véve azok a levelek, amelyek vízzel vagy hóval borítottak, mert feltesszük, hogy ezek a levelek nem vesznek részt a CO₂ asszimilációjában.

Visszatérve a biomassza változásához, a ΔB^- azaz a biomassza csökkenése egy exponenciális összefüggéssel adható meg (2.11), ahol τ az időfüggő várható hasznos élettartam.

$$\Delta B^- = B \left(1 - \exp \left(-\frac{\Delta t}{\tau} \right) \right) \quad (2.11)$$

A biomassza elhalását okozhatja talajnedvesség stressz, vagy betegségek, vagy csak egyszerűen a növény elöregedése, illetve a szerves molekulák átáramlása az aktív biomasszából a szerkezeti elemekbe. Az ISBA-A-gs későbbi verziójában a biomassza csökkenése külön van bontva egy halálozási, és egy tározási tagra.

A biomassza értékéből egy egyszerű lineáris összefüggéssel (2.12) megkapjuk a LAI értékét.

$$\alpha_B = \frac{B}{LAI} \quad (2.12)$$

A valóságban az α_B paraméter függ a vegetáció típusától, az éghajlati tényezőktől, és a növény nitrogén tartalmától is. Az ISBA-A-gs egyik újabb változatában ezért figyelembe vették Lemaire és Gastal (1997) nitrogén hígulással foglalkozó elméletét, ami kapcsolatot ír fel a teljes növényi biomassza (B_T), és a növény nitrogén tartalma között. A növény kritikus nitrogén tartalma az az érték, amely mellett a növekedés maximális. Ez az érték fordítottan arányos a biomasszával, tehát növekvő biomassza esetén csökken az a nitrogén mennyiség, amely mellett a növény növekedése maximális. A levélfelületi arány (leaf area ratio LAR) és a felszín feletti nitrogén koncentráció (N_T) között felírható kapcsolat (2.13):

$$LAR = \frac{LAI}{B_T} = eN_T + f \quad (2.13)$$

ahol e és f a vegetációtípustól függő paraméterek. Felhasználva azt a feltevést miszerint a teljes biomassza, és az aktív biomassza közötti kapcsolat felírható a 2.14-es egyenlet alakjában, a 2.13-as egyenlet segítségével kiszámítható az α_B paraméter értéke (2.15).

$$B_T = \left(\frac{B}{c}\right)^{1/(1-a)} \quad (2.14)$$

$$\alpha_B = \frac{1}{eN_a + f / (cB_T^{-a})} \quad (2.15)$$

A fenti egyenletekben a és c állandó paraméterek, N_a pedig az aktív biomassza nitrogén koncentrációja. Az α_B ilyen módon való becslése a paramétert, egy a teljes biomassza mennyiségétől függő modellváltozóvá teszi.

Összességében tehát a séma a LAI származtatásához először kiszámítja a növényállomány által asszimilált CO_2 mennyiségét. Ez függ a növény fajtájától, a CO_2 koncentrációjától, a levél hőmérsékletétől, a levegő nedvesség tartalmától, a levegő CO_2 koncentrációjától, és a sugárzástól. Az asszimilált CO_2 mennyiségéből kiszámítja a

biomassza növekményt, és emellett a biomassza csökkenést is, majd a kapott biomassza értékből az α_B paraméter segítségével becsüli az aznapi LAI értéket.

A felszíni CO₂ áramok kiszámításánál a modell felhasználja a már korábban részletezett nettó CO₂ asszimiláció értékét (2.9) a teljes növényzetre nézve, melyhez hozzáadva a növényzet által kilélegzett CO₂ értékét, megkapja a növényzet által a fotoszintézis folytán elnyelt CO₂ mennyiségét, azaz a bruttó elsődleges produkciót (Gross Primary Productivity, GPP). A nettó ökoszisztéma gázcsere (Net Ecosystem Exchange, NEE) kiszámításához a GPP-ből le kell vonni az ökoszisztéma által kibocsátott CO₂ áramot, azaz a teljes ökoszisztéma légzését (Ecosystem Respiration, R_{ECO}), amelybe a biomassza légzésén kívül bele tartozik a talaj respiráció is.

$$NEE = R_{ECO} - GPP \quad (2.16)$$

Az ISBA-A-gs az R_{ECO} -t egy egyszerű parametrizációval írja le (2.17):

$$R_{ECO} = R_{E25} \frac{w_2}{w_{fc}} Q_{10}^{(T_{talaj}-25)/10} \quad (2.17)$$

ahol R_{E25} a 25°C-os referencia respiráció, T_{talaj} a talaj réteg hőmérséklete, Q_{10} pedig egy állandó. Az R_{ECO} becslése a 2.17-es egyenletben igen le van egyszerűsítve, az R_{ECO} pontosabb becslését az ISBA-CC séma tartalmazza (Gibelin et al., 2008). Mind a három fluxus függ a vegetáció típusától, tehát egy rácsponton belül a vegetációtípusok figyelembevétele mellett szükséges az értéket kiszámolni.

Az ISBA-A-gs számításai során figyelembe veszi azt is, hogy a növények fotoszintézise hogyan reagál a talajnedvesség stresszre. Külön vizsgálja a lágú illetve fás szárú növényeket, és viselkedésük szerint két csoportba sorolja őket, ez a két csoport a szárazság tűrő, és a szárazság kerülő. Ezen túl, mindkét stratégián belül megkülönböztethető a növények reakciója mérséklet, és erős szárazsággal szemben. A túlevelű erdők, a C3-as és az öntözött növények sorolhatók a szárazság kerülő csoportba, míg a többi vegetációtípus szárazság tűrő.

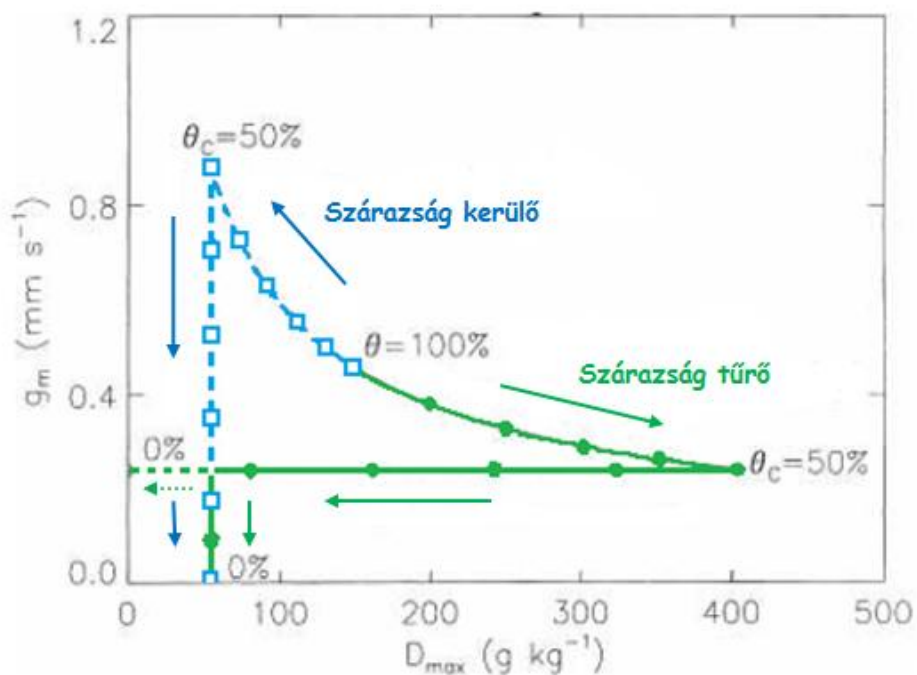
A növények viselkedésének páratartalom függését a D_{max} paraméter jellemzi. D_{max} az a legnagyobb specifikus nedvesség deficit, amit a növények még el tudnak viselni. A stressz nélküli időszakban a lágyszárú növények mezofill vezetőképességének (g_m) logaritmusa arányos a D_{max} logaritmusával (2.18), ez az összefüggés változik meg talajnedvesség stressz hatására.

$$\text{C3-as növények: } \ln(g_m) = 2.381 - 0.6103 \ln(D_{max})$$

$$\text{C4-es növények: } \ln(g_m) = 25.323 - 0.8923 \ln(D_{max}) \quad (2.18)$$

A légyszárú szárazság kerülő növények szárazság hatására egyre kevésbé tolerálják a levegő alacsony páratartalmát, azaz hamarabb bezárják a sztómáikat, ami folytán kevesebb vizet párologtatnak. A szárazság hatására viszont a szárazság kerülő növények mezofill vezetőképessége egy kritikus talajnedvesség érték eléréséig növekszik, aminek hatása az, hogy a CO₂ asszimiláció a kevésbé nyitott sztómák ellenére is működik. Tehát ez a stratégia csökkenti a párologtatást, és szinten tartja az asszimilácót. Ennek eredményeként a stratégia növeli a növények vízfelhasználásának hatékonyságát. Egy kritikus talajnedvesség érték elérése után viszont a növény mezofill vezetőképessége leesik nullára, így a CO₂ asszimiláció is erősen lecsökken (2.3 ábra kék vonal).

A légyszárú, szárazság tűrő növények a száraz időszakok alkalmával jobban tűrik a levegő alacsony páratartalmát, azaz egyre nagyobb szárazság mellett is nyitva tartják a sztómáikat, ez azt jelenti, hogy D_{max} értéke nő. A mezofill vezetőképességük ellenben csökkenni kezd, egy kritikus talajnedvesség érték eléréséig, ahol beáll egy konstans értékre (2.3 ábra zöld vonal, a végén szaggatott). Ez a stratégia tehát több párologtatást tesz lehetővé a növényeknek, de a CO₂ asszimilációt nem növeli meg a mezofill vezetőképességen keresztül, így ennek a módszernek a vízfelhasználása kevésbé hatékony. A modell egy újabb verziójában a mezofill vezetőképesség alakulásán annyiban változtattak, hogy a konstans érték elérése után igen erős talajnedvesség stressz esetén itt is lecsökken nullára (2.3 ábra zöld vonal).



2.3 ábra A lágyszárú növények viselkedése száraz időszakok előfordulásakor,

$$\theta = \frac{\bar{w}_z - w_{wilt}}{w_{fc} - w_{wilt}} \text{ . (forrás: Le Moigne, 2009)}$$

A fás szárú növények kevésbé érzékenyek a szárazságra, de az itt is elmondható, hogy a szárazság kerülő növények vízfelhasználásának hatékonysága nő, a szárazság tűrőké pedig csökken.

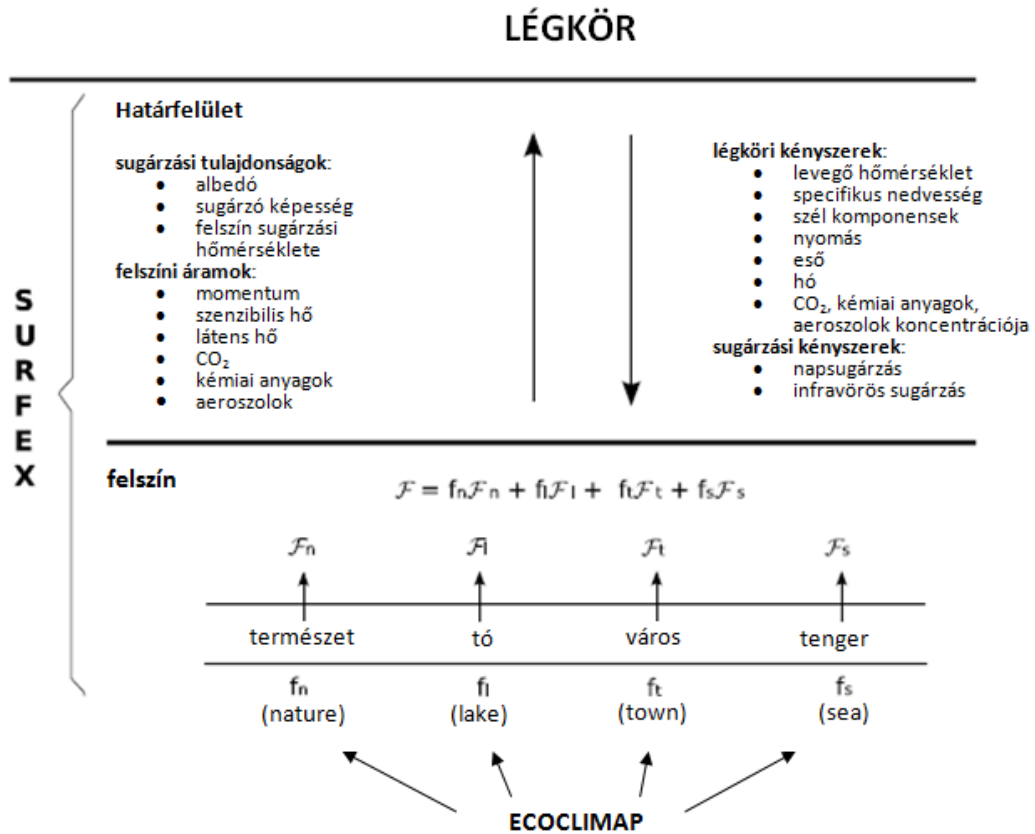
Összességében elmondhatjuk, hogy az ISBA-A-gs egy olyan modell, amely képes realiztikusan leírni a vegetáció főbb változását, és viselkedését különböző ökoszisztémák, és időjárási helyzetek esetében úgy, hogy közben a paraméterek számát a fejlesztők igyekeznek a lehető legalacsonyabban tartani.

2.2. A SURFEX alkalmazása

Ebben a fejezetben röviden összefoglalom, hogy a gyakorlatban hogyan zajlik a SUREX futtatása offline esetben, adatasszimiláció nélkül.

A SURFEX futtatásához szükséges az adott rácspont felszíni jellemzőinek ismerete, amely paramétereket különböző adatbázisokból határozhatjuk meg. A SURFEX először

kiszámítja a szükséges állandó paraméterek (talajösszetétel, albedó, növényzet típusa, városi felszín paraméterei stb.) értékeit, majd a légköri kényszerek felhasználásával kiszámítja a felszíni áramokat, sugárzási értékeket, és egyéb felszíni változókat, amelyeket különböző, a felszín típusokhoz (természetes, város, tenger, tó) tartozó parametrizációs sémák számítanak ki (2.4 ábra).



2.4 ábra. A SURFEX felépítése, ahol az f ez egyes felszínek hányadát, F pedig azon felszínrész áramait jelöli (forrás: Le Moigne, 2009).

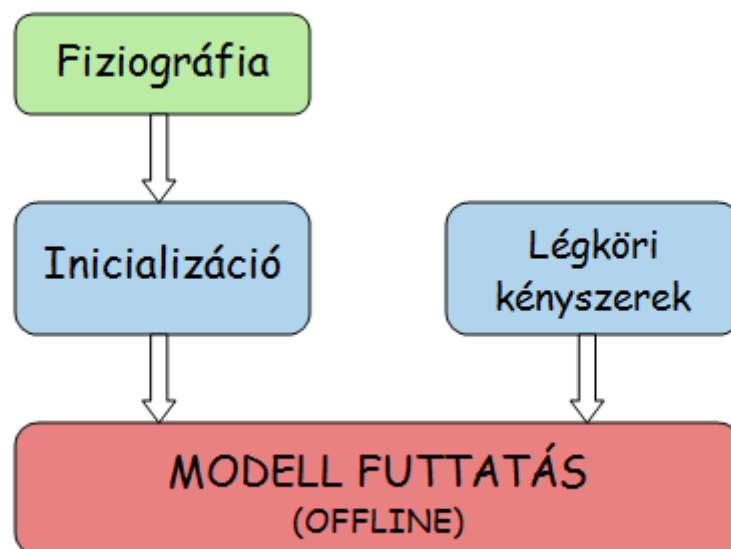
Az első lépés, amit el kell végezni, ha egy adott területen futtatni szeretnénk a SURFEX-et, a felszín fiziográfiájának meghatározása. Ehhez el kell készíteni egy fájlt, ami tartalmazza a kiválasztott felszín domborzati sajátosságait (GTOPO 30 adatbázisból), a talajtextúrát (FAO adatbázisból) és a szükséges felszíni paramétereket (ECOCLIMAP). Ebben a fázisban osztja fel a modell a rácspont területét a felszín típusok szerint, és ekkor határozza meg azt is, hogy a természetes felszínen belül mely parcellák mekkora hányaddal szerepelnek. A felszín típusok és a parcellahányadok meghatározását a SURFEX

az ECOCLIMAP (Masson et al., 2003) adatbázis által meghatározott ökoszisztéma csoportok szerint végzi el.

Az ECOCLIMAP egy felszíni paramétereket tartalmazó globális adatbázis. Célja, hogy akár időjárás előrejelző, akár éghajlati modellekben a felszín-légkör kapcsolatokat leíró sémák számára szolgáltatson információt a felszín jellemzőiről. Felbontása igen nagy, 1 km-es, aminek köszönhetően akár mezo-skálájú modellekben is használható a felszíni paraméterek meghatározására. Az első verziója 2003-ban lett kifejlesztve, már létező felszínborítottság, és éghajlati térképek illetve műholdas adatok felhasználásával. Az adatbázisban 215 ökoszisztéma csoportot definiáltak a Föld teljes felszínére.

A következő lépés az inicializáció, azaz a modell prognosztikai változóinak meghatározása a futtatás kezdetekor, $t=0$ -ban.

Ezen lépések elvégzése után már csak a megfelelő légköri kényszereket kell megadnunk a SURFEX-nek, hogy a felszíni változók előrejelzését el tudja végezni. Amennyiben a légköri kényszerek kisebb időbeli frekvenciával állnak rendelkezésre, mint a modell időlépcsője, a SURFEX időbeli interpolációval állítja elő a kényszerek értékeit a hiányzó időpontokban. A fent leírt folyamatot a 2.5-ös ábra szemlélteti.



2.5 ábra. A SURFEX offline, adatasszimiláció nélküli futtatásának vázlata.

3. Felhasznált adatok

A dolgozatom elkészítése során mind a SURFEX általános vizsgálatakor, mind az asszimilációs feladat elvégzésekor szükségünk volt mérési adatokra, amelyekkel a modell jóságát, illetve magát az asszimilációt végrehajtottuk. Munkánk során a hegyhátsági mérőállomást illetve az azt magában foglaló rácspontot vizsgáltuk, a mérőállomás felszíni mérései, és műholdas adatok felhasználásával. Az általunk felhasznált felszíni mérések között CO_2 fluxus (NEE, GPP), LAI és talajnedvesség adatok szerepeltek, a műholdas mérések pedig talajnedvességi index (Soil Wetness Index, SWI), illetve LAI adatokat szolgáltatottak.

A közvetlen felszíni és a műholdas mérési technikák sokban különböznek egymástól, és mindkét típusnak megvan a maga előnye, illetve hátránya. A felszíni méréseknél, mivel a műszer közvetlenül kapcsolatban van a mérendő közeggel, nem kell olyan hibaforrásokkal számolni, mint a műholdas méréseknél a légkör zavaró hatása. A felszíni mérőhálózat azonban sokszor térben és időben is rendszertelenebb, ritkább, mint a műholdas megfigyelések, amelyek nagy előnye, hogy szabályos időközönként, nagy területre biztosítanak adatokat.

A mérések különbözősége miatt az adatok összehasonlítását és felhasználását is körültekintően kellett elvégezni. A mi esetünkben figyelni kellett arra, hogy a LAI értékek milyen vegetációra vonatkoznak. A felszíni LAI mérések kizárólag a mérőállomás közvetlen környezetére, főre vonatkoznak, azaz egyetlen vegetációtípusra, a rácspontban előforduló 5 közül. A műholdas mérések ellenben érzékelik az összes vegetációtípust, mivel a műhold még a legnagyobb felbontás esetén is csak egy nagyobb terület átlagolt LAI értékét tudja megbecsülni. A műholdas adatokból származtatott LAI tehát leírja az összes vegetációtípust, de az átlagos érték nem választható külön vegetációtípusok szerint, mint ahogy az a modellben megtörténik. Így az adatasszimiláció során is csak a rácspont átlagos LAI értékét tudjuk összevetni a mért értékekkel.

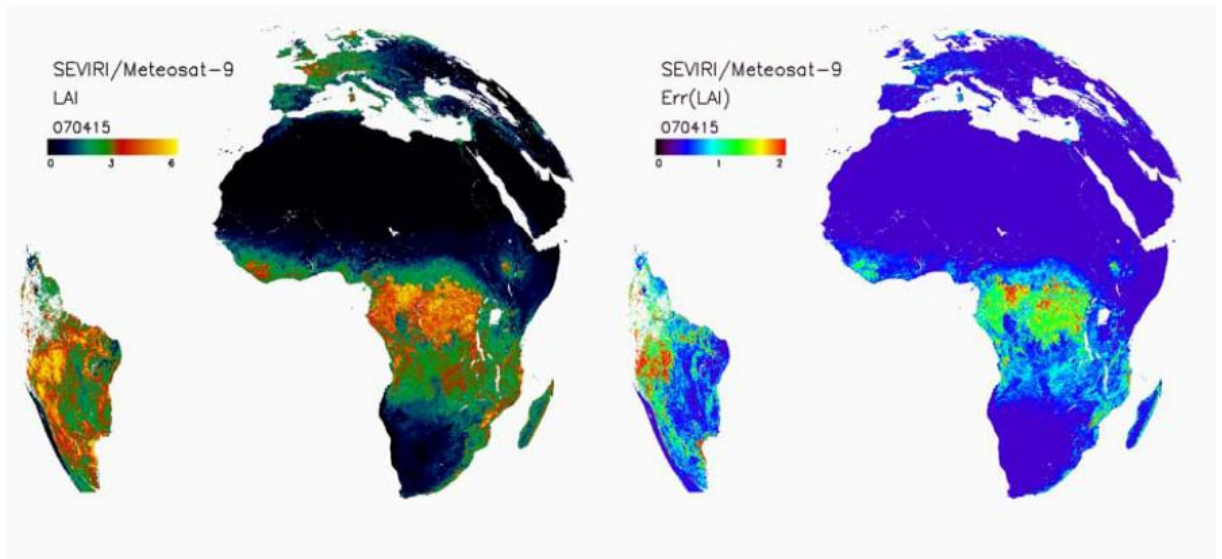
A mérési és a modellezési környezet különbsége a CO_2 áramok összehasonlításánál is figyelembe veendő szempont. Ugyanis a hegyhátsági mérőállomáson a nettó ökoszisztéma gázcserét (NEE) mérik, amit aztán az ökoszisztéma respirációjának (R_{ECO}) modellezésével tudnak különválasztani bruttó elődleges produkcióra (GPP) és az ökoszisztéma respirációjára (2.16). A modellben a CO_2 fluxusok kiszámítása viszont fordított úton

történik. A modellben az egyenletekből elsőként a GPP értékét kapjuk meg, majd az R_{ECO} parametrizációja után a kettő különbségéből számítja a modell az NEE értékét. A vizsgálatainknál tehát ezt a különbséget figyelembe véve kellett eldöntenünk, hogy mely CO_2 fluxusokat hasonlítjuk össze. Még inkább leegyszerűsítve, azt kellett eldöntenünk, hogy melyik R_{ECO} becslést használjuk fel, ugyanis ha a GPP értékeket hasonlítjuk össze, akkor a méréseknél becsült R_{ECO} -t kell felhasználnunk, hogy a mért NEE-ből GPP-t kapjunk. Az NEE összehasonlításakor pedig a modell által parametrizált R_{ECO} -t használjuk fel, hogy a modell GPP-jéből NEE-t számoljunk. Úgy gondoltuk, hogy a mérések elvégzésekor becsült R_{ECO} értéke valószínűleg jobban közelíti a valóságot, mint a modell igen leegyszerűsített egyenlete, így a GPP értékek összehasonlítása mellett döntöttünk.

3.1. Műholdas mérések

A felhasznált műholdas adataink között szerepelt egy LAI és egy SWI adatsor. A LAI adataink LandSAF produktumok, az SWI-t pedig a GEOLAD2-n belüli BioPar állította elő.

A LandSAF LAI ként emlegetett produktumokat az LSA SAF (Land Surface Analysis Satellite Application Facility) készíti, ami az EUMETSAT (European Organization for the Exploitation of Meteorological Satellites) adatainak széleskörű meteorológiai felhasználását segítő SAF hálózat része. A LSA SAF célja, hogy az EUMETSAT szenzorok által szolgáltatott adatok felhasználásával az elsősorban a meteorológiában használt felszíni változók értékeit előállítsák. Ilyen fontos bemenő adat a numerikus előrejelző modellek számára a LAI is. A LAI mérését az MSG (Meteosat Second Generation) műholdon elhelyezett SEVIRI (Spinning Enhanced Visible and Infrared Imager) műszer segítségével végzik, a VIS 0.6-os (látható fény, $0.6 \mu m$) a NIR 0.8-as (közeli infravörös, $0.8 \mu m$) és a MIR 1.6-os (középső infravörös, $1.6 \mu m$) csatorna adataink felhasználásával [1]. A műszer által érzékelt adatokból először az FVC-t (Fractional Vegetation Cover) számítják ki, majd ebből a felszíni változóból becslik a LAI értékeket. A LAI adatok naponta 3 km-es felbontáson érhetőek el, az MSG műhold által látott terület szárazföldi részén. A LAI értékek 0 és 7 között változhatnak, és a pontok 70%-ában 0.6-es pontosságúak (3.1 ábra).



3.1 ábra. A LandsAF LAI értékek (bal) és hibáik (jobb) 2007. április 15.-én, a műhold által látott területeken [1].

A dolgozatomban azokat a 2008-as adatokat használtuk fel, amelyek a hegyhátsági rácspontba estek. Ezek értékét átlagolva használtuk fel a számításainkhoz.

A másik általunk használt műholdas adat a talaj nedvességről szolgáltat információt, melyet az adatasszimilációs feladatnál használtunk fel. A mérési adatokat a GEOLAND2 projekt egyik alcsoportja, a BioPar (Biogeophysical Parameters) számítja a MetOp műholdon lévő ASCAT (Advanced Scatterometer) műszer mérési eredményeiből. A MetOp műhold az EPS (EUMETSAT Polar System) része, ami az első európai, poláris, operatíván működő meteorológiai műholdcsalád. Az általunk felhasznált adat az úgynevezett talaj nedvesség index (SWI), amelyet a műhold által érzékelt felszíni talajnedvesség értékekből számítanak egy rekurzív exponenciális filter felhasználásával (Albergel et al., 2008).

A talajnedvesség egy igen fontos változó a numerikus modellekben, hiszen a talaj gyökérszónájában lévő víz befolyásolja a látens és a szenzibilis hőáram egymáshoz viszonyított arányát, ezen kívül a növények számára is kulcsfontosságú a talaj víztartalma. A modellekben ezért igyekeznek a talaj nedvességét jól inicializálni, és azon belül is a gyökérszóna, és nem a könnyebben mérhető felszíni nedvességtartalomra koncentrálni. A felszíni talajnedvesség értékek (w_g) időben viszonylag gyorsan változnak, a rossz kezdeti értékének hatása egy nap alatt lecseng. Ezzel szemben a gyökérszóna talajnedvessége (w_2) a tározó réteg mérete miatt jóval nagyobb memóriával bír, így egy esetleges rossz érték

napokig befolyásolhatja az előrejelzés kimenetelét (Balsamo et al., 2004). Ezért is igyekeznek a numerikus modellekben a gyökérszóna talajnedvességének pontos inicializálására. Ennek érdekében sok helyen alkalmaznak adatasszimilációs eljárásokat. A felszíni talajnedvesség értékek azonban bizonyos körülmények mellett jól korrelálnak a talaj mélyebb rétegeinek nedvességtartalmával, és megmutatható, hogy a gyökérszóna talajnedvesség értékének számítása lehetséges felszíni mérések alapján (Calvet and Noilhan, 2000). Ezen kívül Barbu et al. (2011) megmutatta azt is, hogy az ISBA-A-gs modell használatánál az SWI asszimilálása jobb eredményekre vezetett, mint a w_g mérések asszimilálása.

Az exponenciális filterrel számított SWI értékek (SWI^o) 0 és 1 között változnak. Ezt úgy kapjuk meg, hogy a w_g értékekből az exponenciális összefüggéssel kiszámított w_2 értékeket a legkisebb és a legnagyobb értékük különbségével normalizáljuk (3.1).

$$SWI^o = \frac{w_2 - w_{2\min}}{w_{2\max} - w_{2\min}} \quad (3.1)$$

A modellben is definiálva van egy SWI érték (SWI^m), amely számítása (3.2) kicsit eltér a megfigyelésnél használt egyenlettől.

$$SWI^m = \frac{w_2 - w_{wilt}}{w_{fc} - w_{wilt}} \quad (3.2)$$

Az SWI^m egy olyan index, ami a w_2 értékét átskálázza a hervadásponthoz tartozó talajnedvesség (w_{wilt}), és a szabadföldi vízkapacitás értéke közé (w_{fc}). Információval szolgál arról, hogy mennyi talajnedvesség érték érhető el a transzspiráció számára, értéke főként 0 és 1 között változik, de felvehet negatív illetve egynél nagyobb értékeket is, ez a hervadás pontnál szárazabb, vagy a szabadföldi vízkapacitásnál nedvesebb talajt jelenti, mely állapotok a növényzet számára kimondottan előnytelenek.

A modellben szereplő, és a mért SWI összehasonlíthatásának kedvéért az adatasszimiláció elvégzésekor a modellben átszámoljuk az SWI^m értékeket SWI^o értékekké. Tehát a modellel kapott w_2 eredményeket, egy adatasszimiláció nélküli futásából vett minimum és maximum értékek felhasználásával skálázzuk át.

Fontos még megjegyezni, hogy az exponenciális filter alkalmazásakor egy T karakterisztikus idő konstanst is felhasználnak, ami a talajnedvesség változásának időskáláját reprezentálja, napokban mérve. Ez az egy paraméter foglalja magában az összes, a talajnedvesség dinamikáját időben befolyásoló folyamatot, mint például a talaj vastagságának befolyásoló hatása, a talaj hidraulikus tulajdonságai, a párolgás vagy a

lefolyás (Albergel et al., 2008). Minél nagyobb a T értéke, annál hosszabb időtartamot vettek figyelembe az SWI kiszámításakor. A dolgozat elkészítésekor 2008-as adatokat használtunk fel, amik közül a T=1 (SWIT1) és a T=5-el (SWIT5) számított SWI adatokkal dolgoztunk. Az elvégzett vizsgálataink azt mutatták, hogy az adatasszimiláció során a SWIT5-ös adatsor használata jobb eredményeket ad.

3.2. Hegyhátsáli mérések

A hegyhátsáli mérőállomás Körmend közelében, az északi szélesség $46,95^\circ$, keleti hosszúság $16,65^\circ$ -on, 248 tenger szint feletti magasságon helyezkedik el (Haszpra et al., 2005). A mérőállomás egy TV/rádió átjátszó toronyból, és a torony körül lévő füves kertből áll. A méréseket toronyra felszerelt mérőműszerek segítségével (van hogy különböző magasságokban is) illetve a kert területén végzik. A torony közvetlen környezetében füves vegetáció található, a tágabb környezetében pedig főként mezőgazdasági művelés alatt álló területek vannak, de előfordulnak erdős foltok is.

A korábban már említett NEE méréseket eddy-kovariancia technikával végezték el 3 méteres magasságban (Barcza et al., 2003), a füves felszín felett. Az eddy-kovariancia méréseket egyre többször használják modellek kalibrációjához, vagy validációjához, amely esetekben hasznos az NEE szétválasztása GPP-re, és R_{ECO} -ra, hiszen ezáltal jobban meg lehet vizsgálni, hogy a modell a CO_2 asszimilációját, vagy respirációját írja le pontatlanul (Reichstein et al., 2005). Jelen esetben az áramok szétválasztását egy olyan módszerrel oldották meg (Haszpra et al., 2005), ami azt használja ki, hogy az éjszakai NEE értékek megegyeznek az R_{ECO} értékével, mivel éjszaka a növények nem fotoszintetizálnak. Ezen egyenlőség alapján az éjszakai NEE értékek hőmérsékletfüggését felhasználva becsülik a nappali R_{ECO} értékeket is. Így a nappalra kapott R_{ECO} , és az NEE összegéből megkapják a nappali GPP értékeket. Dolgozatomban a már említett okok miatt a 2008-as GPP értékeket használtuk fel a modell vizsgálatánál.

Az általunk felhasznált hegyhátsáli mérések között szerepelnek még LAI és talajnedvesség mérések, amelyek szintén a torony közvetlen közelében lévő füves területre vonatkoznak. A LAI méréseket heti gyakorisággal végzik 6 helyen. A mérés során a mérőműszer a növényzeten átszűrődött fotoszintetikusan aktív sugárzás értékét méri, és ebből számítja a vizsgált növényzet LAI-át [2]. A talajnedvesség méréseket egy a

földben függőlegesen 10 és 30 cm között elhelyezett mérőműszer szolgáltatja [3]. A mérőműszer folyamatos méréseit 8 percenként tárolják, és ezen adatokból számítanak napi átlagos talajnedvesség értékeket. Az adatasszimiláció során ezen mérésekből számított SWI értékeket használtunk fel, amelyeket az adatsor minimumának, és maximumának felhasználásával számítottunk a 3.1-es egyenlet alapján.

4. Az adatasszimiláció

Az időjárás-előrejelzése, a felszín folyamatait is beleértve egy kezdeti érték problémának tekinthető, ahol kulcsfontosságú a kezdeti feltételek pontos ismerete, hiszen a rendszer komplexitása miatt, ha nem megfelelő kezdeti értékből indulunk, könnyen rossz eredményre juthatunk. A pontos kezdeti értékek előállításával foglalkozik az adatasszimiláció. Az adatasszimiláció során megpróbáljuk a légkörről szerzett összes információnkat az előrejelzés szempontjából legkedvezőbb módon ötvözni úgy, hogy az előállított kezdeti mező a lehető legkisebb hibával legyen terhelve.

A modell számára egy olyan kezdeti mezőt kell előállítanunk, amely minden rácspontban tartalmaz értékeket. Ehhez viszont nem elég, ha csak a légköri megfigyeléseket vesszük figyelembe, hiszen a megfigyelések mind térben, mind időben rendezetlenül helyezkednek el, nem illeszkedve a modell rácspontjaihoz. Ezért a megfigyeléseken kívül felhasználunk egy háttér mezőt is, amely származhat a modell egy korábbi előrejelzéséből, vagy akár egy rácspontokra interpolált éghajlati adatsorból is. A modellel dinamikailag konzisztens kezdeti mező előállításához szükséges még figyelembe vennünk a légkör dinamikai egyensúlyi folyamatait is, így elkerülhetjük, hogy a modell fizikájával, és dinamikájával nem összezsengő adatok később hibaként jelentkezzenek az előrejelzés során. Fontos információ még a megfigyelési adatokon és a háttérmezőn kívül ezen adatok megbízhatóságának mértéke, azaz hogy melyik érték mekkora hibával terhelt. Ez az információ segít eldönteni, hogy az analízis készítése során melyik adathoz igazítsuk inkább a kezdeti mezőt.

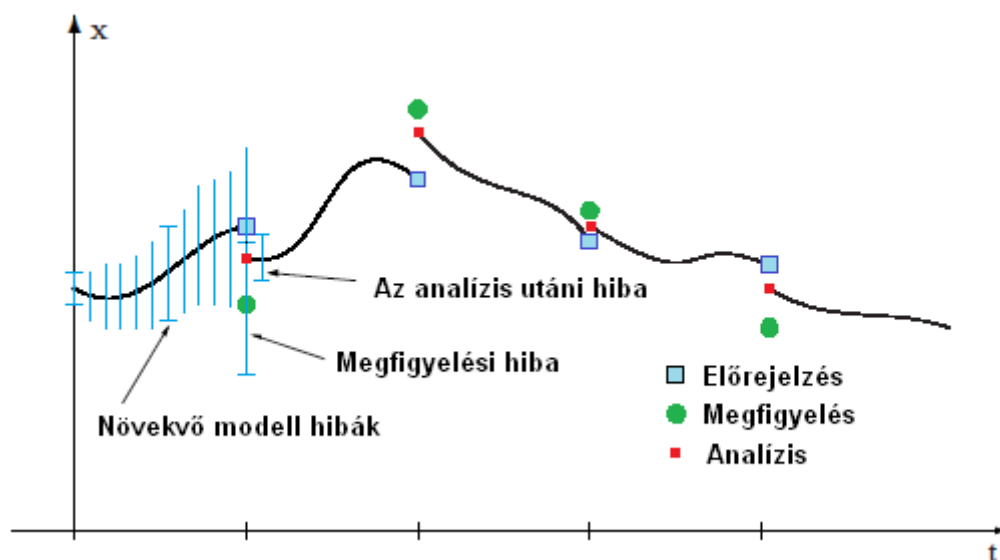
A fent említett információk felhasználásával különböző módszerekkel készíthetünk analízis mezőt. Az egyik ilyen alapvető adatasszimilációs módszer az optimális interpoláció (OI), mely a legkisebb négyzetek elvén alapul (Bouttier and Courtier, 1999). Egy másik megközelítési mód a variációs technika, amelyben egy $J(x)$ úgynevezett veszteségfüggvény minimumát keressük, ez a technika a Maximum-Likelihood módszeren alapszik.

Az adatasszimilációs módszerek többsége nem képes a háttér mező hibájának változását leírni, holott az előrejelzés hibája jelentősen függhet az adott szinoptikus helyzettől, vagy attól, hogy mennyi idő telt el az analízis időpontjától. Ezt a hatást a Kálmán-szűrő alkalmazásával lehet figyelembe venni.

Dolgozatomban az adatasszimilációs vizsgálataink során a Kálmán-szűrőt alkalmaztuk, ami egy olyan adatasszimilációs módszer, ahol az előrejelző modell segítségével számolják a háttér hiba időbeli fejlődését, ezáltal a módszer pontosabb analízis készítését teheti lehetővé.

4.1. A Kálmán-szűrő

A Kálmán-szűrő (vagy Kálmán Filter, KF) a legkisebb négyzetek módszerének továbbfejlesztése. A Kálmán-szűrő alkalmazásakor a háttér mezőt mindig a korábbi analízisből indított előrejelzés szolgáltatja, a lényegi különbség a többi adatasszimilációs módszerhez képest az, hogy a háttér mező hibáját időben fejlődő értéknek tekinti (Bouttier and Courtier, 1999). Így az analízis hibája is minden asszimilációs ciklusban más és más, attól függően, hogy a korábbi előrejelzés, azaz a háttér mező hibája hogyan alakult (4.1 ábra).



4.1 ábra. A Kálmán-szűrő alkalmazása (forrás: Cushman-Roisin and Beckers, 2009).

A Kálmán-szűrő módszerének megértéséhez először tisztázzuk az alapfogalmakat, és a legkisebb négyzetek módszerén alapuló analízis előállításának módját.

Alapfogalmak:

- x_t^t a valós állapot a t időpontban (a modellváltozók terében)
- x_b^t a háttér mező, azaz az előrejelzés a t időpontban
- x_a^t az analízis, vagyis a kezdeti feltétel a t időpontban

- y_o^t a megfigyelések vektora a t időpontban (általában kisebb dimenziójú, mint a modellváltozók tere)
- $\mathcal{H}: x \rightarrow y$ a megfigyelési operátor (a modell térből képez a megfigyelések terébe)
- $\varepsilon_a = x_a - x_t$ az analízis hiba
- $\varepsilon_b = x_b - x_t$ a háttér hiba
- $\varepsilon_o = y_o - \mathcal{H}(x_t)$ a megfigyelési hiba
- \mathbf{B} a háttér hiba kovariancia mátrix, $\mathbf{B} = E(\varepsilon_b \varepsilon_b^T)$
- \mathbf{R} a megfigyelési hiba kovariancia mátrix, $\mathbf{R} = E(\varepsilon_o \varepsilon_o^T)$
- \mathbf{A} az analízis hiba kovariancia mátrix, $\mathbf{A} = E(\varepsilon_a \varepsilon_a^T)$

ahol az $E()$ a várható érték számítását jelöli.

Ezen alapfogalmakon kívül, még szükségünk van pár alapfeltevésre. A módszer során lineáris analízis készítünk, azaz az analízist a háttérmező javított formájában keressük, ahol a javítás mértéke lineárisan függ a háttér mező, és a megfigyelések közti eltéréstől. Az analízisről továbbá feltesszük, hogy a lehető legjobban megközelíti a valós állapotot, azaz optimális. Az optimális analízis eléréséhez szükséges még feltennünk, hogy a háttér mező, és a megfigyelések hibájának várható értéke nulla, tehát nincs szisztematikus hiba:

$$E(\varepsilon_b) = 0 \text{ és } E(\varepsilon_o) = 0.$$

Ez a feltevés a gyakorlatban nehezen megvalósítható. Azonban abban az esetben, ha a háttér mező, vagy a megfigyelések szisztematikus hibája ismert, akkor a hibák korrigálása után elérhető a fenti feltevés. Abban az esetben viszont, amikor a hibát nem tudjuk kijavítani, az analízisünk nem lesz optimális. Az alapfeltevések közé tartozik még, hogy a megfigyelések és a háttér mező hibája korrelálatlan:

$$E(\varepsilon_o \varepsilon_b) = 0.$$

Ennek a feltevésnek a teljesülése könnyen belátható, ha belegondolunk, hogy a háttérmező és a megfigyelések hibáit egymástól teljesen független folyamatok okozzák.

A megfigyelési operátorról szükséges feltennünk, hogy lineáris. A gyakorlatban viszont sokszor előfordul, hogy \mathcal{H} nem lineáris, ilyenkor a háttér mező környezetében linearizáljuk. Ezt a közelítést tangens lineáris hipotézisnek hívjuk, ilyenkor a \mathcal{H} értékét az első fokú Taylor-sorának segítségével számítjuk ki:

$$\mathcal{H}(x_b + \delta x) = \mathcal{H}(x_b) + \mathbf{H}\delta x + O(\delta x^2) \quad (4.1)$$

$$\mathbf{H}_{ij} = \frac{\partial y_i}{\partial x_j}, \quad \lim_{\delta x \rightarrow 0} \frac{O(\delta x^2)}{\delta x^2} = 0$$

ahol \mathbf{H} a lineáris operátor, δx pedig a perturbáció a modellváltozók terében, és $O(\delta x^2)$ jelöli, hogy a maradék tagok, másodrendben tartanak a nullához. Tehát a linearizált megfigyelési operátor mátrixában az ij -edik elem azt mutatja, hogy a j -edik modellváltozó kis megváltozása milyen hatással van a megfigyelési vektor i -edik elemére. A hipotézis csak akkor alkalmazható, ha minden modellváltozó kis perturbációjára nézve (ahol a perturbációk nagysága a háttér hiba nagyságrendjébe esik) tudjuk, hogy a \mathcal{H} magasabb rendű deriváltjai elhanyagolhatóak. A tangens lineáris közelítés fennállásakor tehát a háttér mező környezetében a \mathcal{H} operátort lineárisnak tekintjük, azaz

$$\mathcal{H}(x) - \mathcal{H}(x_b) = \mathbf{H}(x - x_b) \quad (4.2)$$

Összefoglalva a fenti feltételeket, az analízis legjobb, lineáris, bias mentes, vagy más néven szisztematikus hiba nélküli becslését keressük, amely közelítés angol neve Best Linear Unbiased Estimator (BLUE). A módszer egyenletei, azaz a BLUE a következő alakban írhatóak fel (4.3, 4.4 és 4.6).

$$x_a = x_b + \mathbf{K}(y_o - \mathcal{H}(x_b)) \quad (4.3)$$

$$\mathbf{K} = \mathbf{B}\mathbf{H}^T(\mathbf{H}\mathbf{B}\mathbf{H}^T + \mathbf{R})^{-1} \quad (4.4)$$

Az 4.3 egyenlet a lineáris közelítést írja le, ahol a \mathbf{K} a nyereség mátrix azt jelenti, hogy a megfigyelések, és a háttér mező eltérését mekkora súllyal vegyük figyelembe, azaz a megfigyeléshez, vagy a háttér mezőhöz húzza közelebb a modell az analízis értékét. Az analízis hiba kovariancia mátrixának alakja:

$$\mathbf{A} = (\mathbf{I} - \mathbf{K}\mathbf{H})\mathbf{B}(\mathbf{I} - \mathbf{K}\mathbf{H})^T + \mathbf{K}\mathbf{R}\mathbf{K}^T \quad (4.5)$$

ami az optimális esetben, tehát amikor \mathbf{K} a 4.4-es egyenlet szerint írható fel, lerövidül a következő alakra (4.6)

$$\mathbf{A} = (\mathbf{I} - \mathbf{K}\mathbf{H})\mathbf{B} \quad (4.6)$$

ahol \mathbf{I} az egységmátrix. A 4.6 egyenlet alapján belátható, hogy az analízis hibája kisebb lesz a háttér mező hibájánál. Látszik tehát, hogy az adatasszimilációval javítottunk a háttér mezőn, azaz a megfigyelési adatok figyelembevételével pontosabbá tudjuk tenni a következő előrejelzésünket azáltal, hogy a kezdeti feltételek közelebb kerülnek a valós állapothoz.

A Kálmán-szűrő alkalmazásakor szintén a BLUE-t használjuk, csak kiegészítjük még egy egyenlettel, ami a háttér hiba kovariancia mátrix időbeli fejlődését írja le. Ehhez definiálnunk kell még pár fogalmat:

- $\mathcal{M}_{t \rightarrow t+1}$: $x_b^{t+1} = \mathcal{M}_{t \rightarrow t+1}(x_a^t)$ a modell operátor

- $\mathbf{M}_{t \rightarrow t+1}$ a modell operátor linearizáltja, a tangens lineáris hipotézis szerint:

$$\mathbf{M}_{t \rightarrow t+1 ij} = \frac{\partial x_i^{t+1}}{\partial x_j^t}$$

- $\mathcal{E}_M = \mathcal{M}_{t \rightarrow t+1}(x_t^t) - x_t^{t+1}$ a modell hiba
- $\mathbf{Q} = E(\mathcal{E}_M \mathcal{E}_M^T)$ a modell hiba kovariancia mátrix.

Feltesszük továbbá még, hogy az analízis és a modell hiba korrelálatlan

$$E(\mathcal{E}_a \mathcal{E}_M) = 0.$$

A háttér hiba kovariancia mátrix időbeli fejlődésének leírásához a következő egyenletet

(4.7) fejtjük ki részletesebben.

$$\mathbf{B}^{t+1} = E(\varepsilon_b^{t+1} \varepsilon_b^{t+1 T}) \quad (4.7)$$

A háttér hiba a t+1-edik időpontban:

$$\varepsilon_b^{t+1} = x_b^{t+1} - x_t^{t+1} \quad (4.8)$$

$$\varepsilon_b^{t+1} = \mathcal{M}_{t \rightarrow t+1}(x_a^t) - \mathcal{M}_{t \rightarrow t+1}(x_t^t) + \mathcal{E}_M \quad (4.9)$$

feltesszük, hogy a hiba kis időtávon lineárisan fejlődik (4.10)

$$\varepsilon_b^{t+1} = \mathbf{M}_{t \rightarrow t+1}(x_a^t - x_t^t) + \mathcal{E}_M \quad (4.10)$$

$$\varepsilon_b^{t+1} = \mathbf{M}_{t \rightarrow t+1} \varepsilon_a^t + \mathcal{E}_M \quad (4.11)$$

Ha a 4.11-es egyenletet jobbról megszorozzuk a transzponáltjával, és annak vesszük a várható értékét, akkor az úgy nevezett Lyapunov egyenlethez (4.12) jutunk (Cushman-Roisin and Beckers, 2009) :

$$E(\varepsilon_b^{t+1} \varepsilon_b^{t+1 T}) = \mathbf{M}_{t \rightarrow t+1} \mathbf{A}^t \mathbf{M}_{t \rightarrow t+1}^T + \mathbf{Q} \quad (4.12)$$

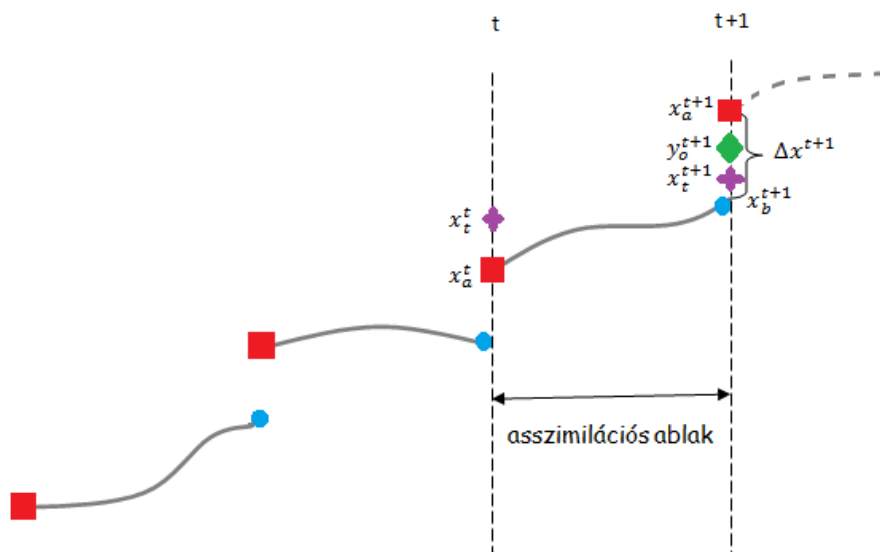
azaz a \mathbf{B} mátrix időbeli fejlődését felírhatjuk úgy, mint:

$$\mathbf{B}^{t+1} = \mathbf{M}_{t \rightarrow t+1} \mathbf{A}^t \mathbf{M}_{t \rightarrow t+1}^T + \mathbf{Q} \quad (4.13).$$

A 4.13-as egyenlet, és a BLUE együttes alkalmazásával jutunk tehát a Kálmán-szűrő módszeréhez. Abban az esetben, amikor vagy a \mathcal{H} vagy az \mathcal{M} , vagy egyik operátor sem lineáris, akkor a módszert kiterjesztett Kálmán-szűrőként (Extended Kálmán Filter, EKF) emlegetjük, és ilyenkor a tangens lineáris hipotézis alkalmazásával linearizáljuk az operátorokat. A \mathcal{H} esetében a háttér mező, az \mathcal{M} esetében pedig az analízis mező környezetében közelítjük az operátort az érintő mentén. A Kálmán-szűrőnek létezik egy egyszerűsített változatként (Simplified Extended Kálmán Filter, SEKF) nevezett alakja is, amelynél a hiba fejlődésére vonatkozó egyenletet kihagyjuk a számításokból. Tehát az SEKF tulajdonképpen egy optimális interpoláció, ahol a \mathbf{B} értéke vagy végig konstans, vagy

valamelyik modellváltozótól függ, de ekkor sem fejlődik időben, csak minden asszimilációs ciklusban újraszámolódik.

Inkrementumnak (Δx) hívjuk azt az értéket, amit a háttérmezőhöz adva megkapjuk az analízist, ez a 4.3-as egyenlet jobb oldalának második tagja. Jelen esetben az inkrementumot az analízis időpontjában adjuk hozzá a háttérmezőhöz, tehát az asszimilációs ablak végén (4.2 ábra). Létezik olyan alkalmazása is a Kálmán-szűrőnek (Draper et al., 2009), ahol az ablak elejének időpontjára számítják ki az inkrementum értékét, ilyenkor a modell operátor újbóli alkalmazásával kapják meg a végső analízis értéket.



4.2 ábra Az analízis készítése t+1 időpontban.

Az analízis hiba kovariancia mátrix értékének levezetése során belátható a \mathbf{K} optimális értékének alakja, illetve a BLUE és a Kálmán-szűrő feltételezéseinek együttes alkalmazásával a \mathbf{B} időbeli fejlődésére vonatkozó egyenletet is megkapjuk (lásd Függelék).

Az adatasszimiláció sikerességét a korábban említett feltevéseken kívül befolyásolja még az is, hogy milyen gyakran állnak rendelkezésre a mérési adatok. Ez határozza meg, hogy két analízis között mennyi idő teljen el. Itt érdemes megemlíteni két szélsőséges esetet, melyekben az adatasszimiláció nem jól alkalmazható (Cushman-Roisin and Beckers, 2009).

Az egyik problémás helyzet az, amikor két adat asszimilálása között olyan rövid idő telik el, hogy a modellváltozók, és hibáik még alig változtak meg. Ilyenkor a modell egy konstans modellnek tekinthető ($\mathbf{M} \sim \mathbf{I}$), aminek következtében

$$\mathbf{B}^{t+1} \cong \mathbf{A}^t + \mathbf{Q} \quad (4.14).$$

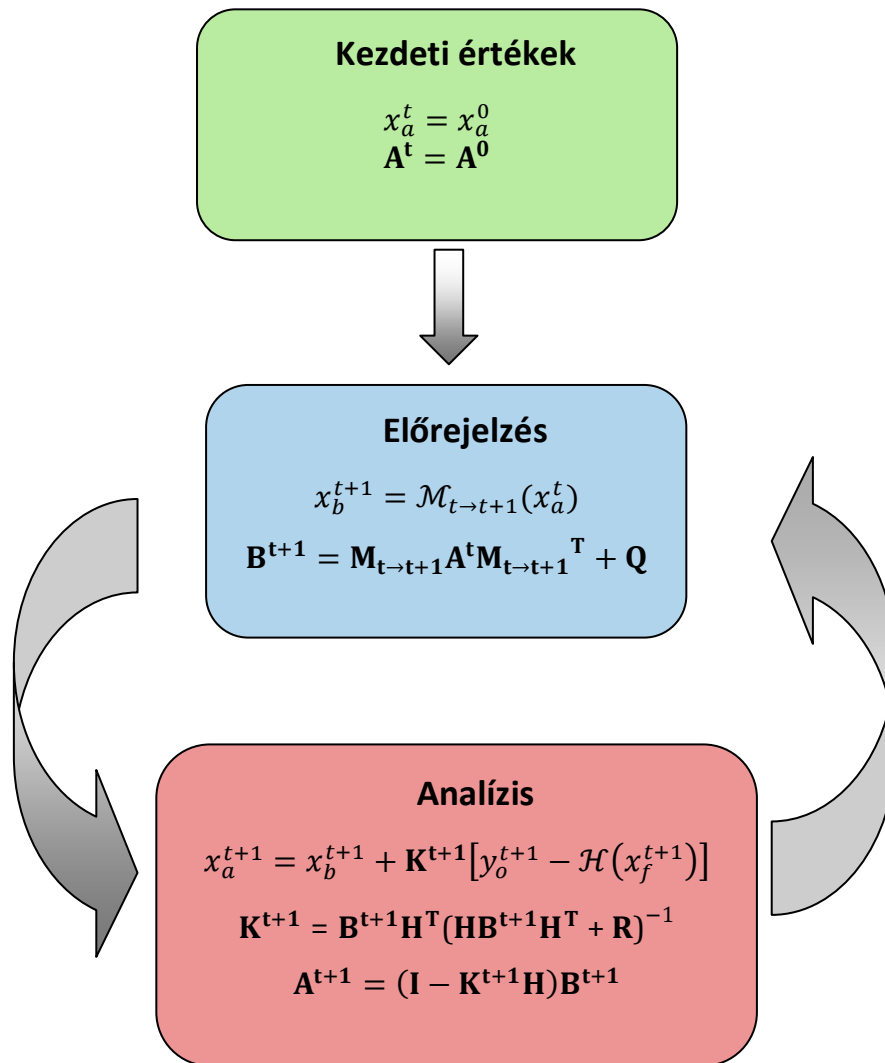
Tehát a módszer lényegi része, miszerint a háttér mező hibája függ a modell állapotától, kimarad.

A másik problémás eset, az előzőnek pont az ellentettje, azaz amikor két analízis készítése között olyan hosszú idő telik el, hogy a nem lineáris modellek már elérik az előrejelző képességük határát. Ilyenkor az előrejelzés tulajdonképpen egy random érték, és a háttér mező hibája tisztán a modell hiba ($\mathbf{M} \sim \mathbf{0}$), ekkor

$$\mathbf{B}^{t+1} \cong \mathbf{Q} \quad (4.15).$$

Ezen hibákat úgy tudjuk elkerülni, ha figyelembe vesszük az asszimilációs ciklusok közötti idő beállításánál a modellezni kívánt folyamat időskáláját.

A 4.3 ábrán látható a Kálmán-szűrő algoritmusának összefoglalása, amit két fő részre lehet osztani. Az egyik az előrejelzés készítésének fázisa, amikor nem csak a modellváltozók, hanem a háttér hiba kovariancia mátrix fejlődését is kiszámítjuk, majd következik az analízis elkészítése a korábbi előrejelzés, a megfigyelések és a hibák figyelembevételével. Ez után az analízis birtokában ismét előrejelzést készítünk, és ismételjük a korábbi lépéseket így haladva időben előre.



4.3 ábra. A Kálmán-szűrő algoritmus.

4.2. A Kálmán-szűrő alkalmazása a SURFEX-ben

A SURFEX-en belül az adatasszimilációt egy asszimilációs program, és egy azt vezérlő script végzi el. A script vezérli a feladatok elvégzését egy asszimilációs cikluson belül, beolvassa az adatokat, a szükséges modellváltozókat kiírja, egyszóval irányítja az adatasszimiláció folyamatát.

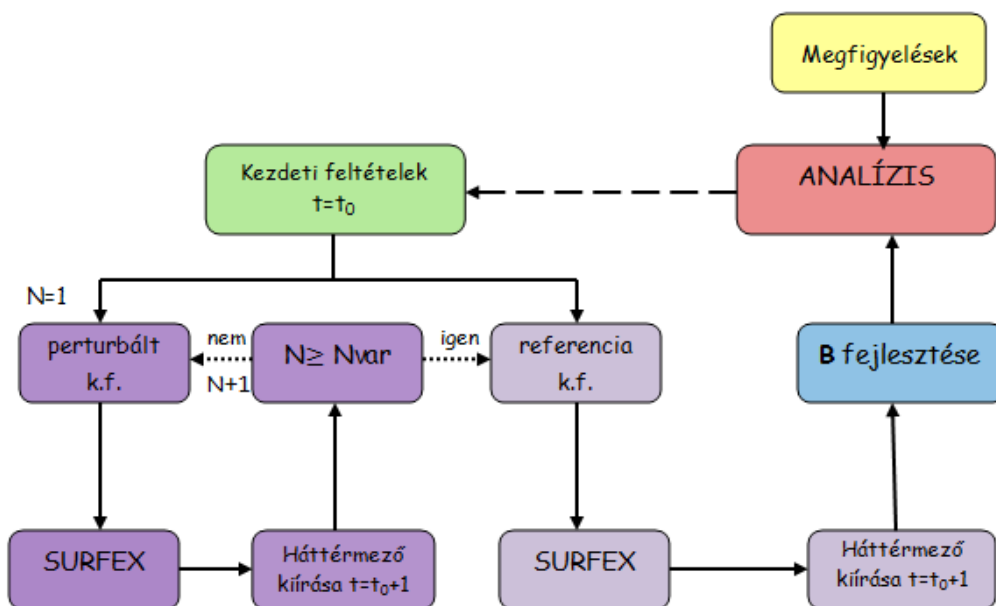
Az adatasszimiláció első lépéseként a script beolvassa a korábbi analízis eredményét, ami az új asszimilációs ciklus kezdeti feltételeit adja (4.4 ábra zöld doboz). Ez után előállítja a perturbált kezdeti feltételeket. A perturbált kezdeti feltételeket úgy állítja elő, hogy minden asszimilálni kívánt modellváltozó kezdeti értékét külön-külön kis mértékben megváltoztatja. A perturbált kezdeti feltételek alkalmazásával kapott

eredmények a modell operátor véges különbséges közelítéssel számolt Jacobi mátrixának előállításához szükségesek (4.16).

$$\mathbf{M}_{t \rightarrow t+1, ij} = \frac{\partial x_i^{t+1}}{\partial x_j^t} \cong \frac{x_i^{t+1}(x + \delta x_j) - x_i^{t+1}(x)}{\delta x_j^t} \quad (4.16)$$

A script tehát lefuttatja a perturbált kezdeti feltételekkel ($x + \delta x_j$) a modellt (4.4 ábrán a SURFEX feliratú doboz), és a szükséges modellváltozókat kiírja, hogy később felhasználhatóak legyenek. Ezt a ciklust annyiszor végzi el, ahány féle perturbált kezdeti feltétel van, tehát ahány változót asszimilálunk (4.4 ábra Nvar, sötét lila ciklus).

A perturbált modellfuttatások elvégzése után az adatasszimilációs rendszer elvégzi a referencia (perturbálatlan kezdeti feltételek) futtatást is, melynek eredményeit szintén eltárolja (4.4 ábra, világos lila dobozok). A perturbált és referencia futások eredményeinek felhasználásával előállítja az $\mathbf{M}_{t \rightarrow t+1}$ linearizált modell operátort. A tangens lineáris modell operátor a modellváltozók számával megegyező rangú mátrix lesz, ennek felhasználásával fejlesztjük a \mathbf{B} értékét (4.13) (4.4 ábra, kék doboz). Ezen lépések elvégzése után az analízis előállítása következik, ami folyamán a program beolvassa a megfigyelési adatokat, kiszámolja az \mathbf{R} , a \mathbf{Q} és a \mathbf{K} mátrixokat, végül az inkrementum kiszámítása után elkészíti az analízist (4.4 ábra, piros doboz). Az adatasszimilációs ciklus végén az analízis értékét, és az analízis hiba kovariancia mátrixot kiíratjuk, hogy ezekből indulhasson ki a következő asszimilációs ciklus.



4.4 ábra A SURFEX-ben alkalmazott EKF lépéseinek folyamatábrája.

Annak következtében, hogy a háttér és az analízis hiba kovariancia mátrixokat minden asszimilációs ciklusban újra kell számolni, illetve amiatt, hogy a modell operátor linearizálása miatt egy asszimilációs cikluson belül többször le kell futtatni a modellt, a módszer igen költségessé válik, ezért csak kis dimenziójú rendszereknél érdemes alkalmazni (Fisher, 2001).

Az adatasszimiláció során kulcsfontosságú elem a megfigyelési operátor, amely kapcsolatot teremt a megfigyelési tér és a modell tér között. A megfigyelési operátor a modell térből képez a megfigyelési térbe, tehát a mi esetünkben a modell LAI, illetve w_2 értékeit kell a megfigyelési tér LAI illetve SWI értékeivé alakítani. Ez a transzformáció a LAI-nál az egységoperátor, de a w_2 esetében is leírható egy lineáris összefüggéssel (3.1). A bonyodalmat a \mathcal{H} operátornál az jelenti, hogy mint azt már a SURFEX bemutatásánál említettük, a SURFEX 12 parcellára osztja a természetes felszínt a vegetációtípusok szerint. Így a modell térben a rácsponthoz nem egy, hanem 12 érték tartozik, mintha a rácsponton belül még 12 rácspont lenne. Tehát a \mathcal{H} operátornak 12 értékhez kell hozzárendelnie egyet, ezért valamiféle átlagolásra van szükség. A rácspont átlagos értékét a parcella hányadok (f_p) felhasználásával számítja ki (4.17).

$$\bar{y} = \sum_{p=1}^{12} f_p \mathcal{H}^p(x_p) = \mathcal{H}(x) \quad (4.17)$$

A linearizált megfigyelési operátor ilyenkor parcellánként különböző (4.18), amellet a feltétel mellet, hogy a parcellák egymástól függetlenek (4.19).

$$\mathbf{H}_{ij}^p = \frac{\partial \bar{y}_i}{\partial x_j^p} = f_p \frac{\partial y_i^p}{\partial x_j^p} \quad (4.18)$$

$$\frac{\partial y_i^p}{\partial x_j^m} = 0 \quad \text{ha } p \neq m \quad (4.19)$$

A SURFEX adatasszimilációs rendszerében lehetőség van az EKF, és egyszerűsített változatának az SEKF-nek a használatára is. Az SEKF beállításnál a \mathbf{B} értékét nem fejlesztjük időben, csak minden asszimilációs ciklus elején egy állandó összefüggés szerint meghatározzuk. A meghatározott érték lehet egy teljesen állandó konstans, vagy függhet a LAI-tól (Barbu et al., 2011), azon elgondolás alapján, hogy minél nagyobb a LAI értéke, annál nagyobb hibával terhelt a háttérmező.

5. Eredmények

Ebben a fejezetben a SURFEX-el elvégzett vizsgálatainkkal foglalkozom. A fejezet első felében a modell általános viselkedését mutatom be, az általunk vizsgált paraméterek, a GPP és a LAI függvényében. A fejezet második részében pedig az adatasszimilációs vizsgálataink eredményeit ismertetem.

5.1. A SURFEX általános vizsgálata

A SURFEX vizsgálatánál egy évre futtattuk le a modellt offline módon. Az offline futtatás költségkímélő, mert ilyenkor a felszíni modell nincs közvetlenül összekapcsolva a légköri modellel. A felszín folyamatai a légköri kényszereken keresztül függenek az időjárástól. A légköri kényszereket vizsgálataink során az ALADIN modellből vettük.

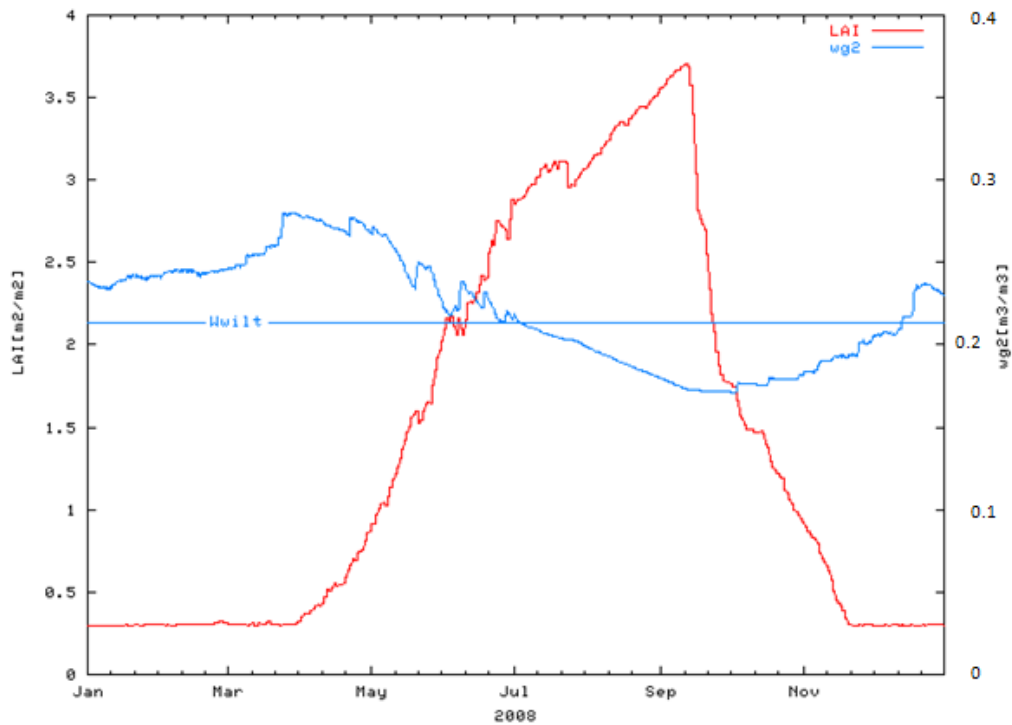
A légköri kényszer megválasztásánál megvizsgáltuk a modell viselkedését más kényszerek használatakor is. Mérésekből származó csapadék, és sugárzási kényszereket vizsgáltunk. A sugárzási kényszer értékeket LandSAf mérésekből, a csapadék kényszereket pedig a felszíni mérőhálózat, illetve radar mérésekből vettük. Azért a csapadék és a sugárzás értékeit cseréltük ki, mert ezek jelentősen befolyásolják a LAI és a GPP alakulását. A kényszerek vizsgálatakor azt tapasztaltuk, hogy habár az eredmények különböztek a különböző kényszerek használatakor, de a modell későbbiekben részletezett hibás viselkedése a mérésekből származó kényszereknél is előfordult. Tehát a hibákat nem az ALADIN kényszerek esetleges pontatlansága okozta.

Vizsgálatainkat egy rácspontra vonatkozóan végeztük, a 2008-as évre. A vizsgált rácspont a hegyhátsáli mérőállomáshoz közeli rácspont volt, de a vegetáció összetétele szerint két különböző beállítást használtunk. Az első, kevésbé összetett beállítás csupán egyetlen parcellát tartalmaz a tizenkettőből, mégpedig a mérsékeltövi füves területhez tartozó 10-es parcellát. Ez a felszín a hegyhátsáli mérőállomás kertjében található füves területnek feleltethető meg. A beállítás használata azért volt célszerű és indokolt, mert a rendelkezésünkre álló felszíni LAI illetve GPP mérések, hasonló füves területre vonatkoznak. A másik beállításnál a rácspont vegetációjának összetételét az ECOCLIMAP adatbázis alapján határoztuk meg, itt már szerepelt a 10-es parcellán kívül a lombhullató

erdőket reprezentáló 4-es, a túlevelű erdőt jelentő 5-ös, a C3-as és a C4-es mezőgazdasági növényeket képviselő 7-es, illetve 8-as parcella is. Ennek a beállításnak a futtatása összetettebb számolást jelent a modell számára. Az EOCLIMAP adatbázis szerinti beállítás tesztelése azért fontos, mert ez alapján lehet majd kiterjeszteni a modell futtatását 2 dimenzióba, akár az ország egész területére.


5.1.1. Fűves terület

A fűves területre futtatott modell eredmények vizsgálata közben feltűnt számunkra, hogy a LAI értéke enyhén növekszik olyan esetekben is, amikor a talajnedvesség a hervadási pont (w_{wilt}) alá csökken. Ez azt jelenti, hogy a modellben akkor is van fotoszintézis, amikor a növény számára kedvezőtlenek a körülmények, és el kéne száradnia. Azért, hogy a problémát jobban meg tudjuk vizsgálni, egy szélsőséges esetet állítottunk elő. Ez azt jelenti, hogy a légköri kényszereket úgy módosítottuk, hogy július elejétől egészen szeptember végéig ne essen semmiféle csapadék. Ez a változtatás nagyon durva, és nem konzisztens a többi légköri mezővel, hiszen más, nedvességgel kapcsolatos értéken nem változtattunk, de a kísérlet céljának megfelelt. A hosszú csapadékmentes időszak eredményeként a talajnedvesség tartósan a hervadási pont alá csökkent. Ennek ellenére a LAI értéke tovább növekedett, és csak a vegetációs időszak végén, a többi légköri kényszer együttes megváltozásának hatására kezdtek el elhervadni a növények (5.1 ábra).

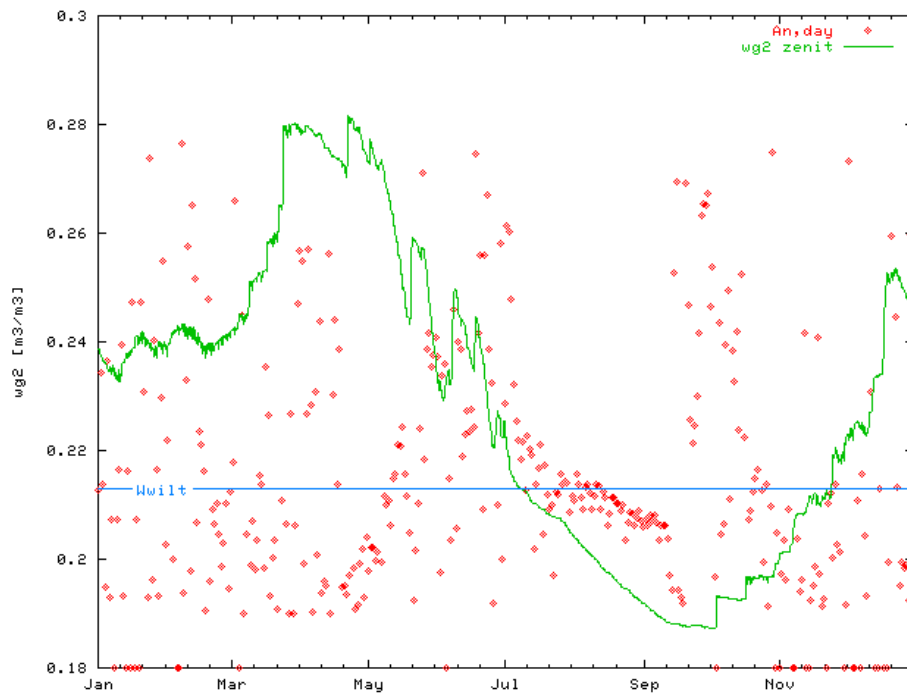


5.1 ábra. A LAI, és a w_2 (az ábrán w_{g2}) alakulása az extrém száraz légköri kényszerek esetén.

A probléma megoldására több vizsgálatot is elvégeztünk, aminek eredményeként arra a következtetésre jutottunk, hogy a hiba oka kapcsolatos lehet a sugárzással. Kiderült, hogy a problémát részben az okozta, hogy a 6 órás légköri kényszerek használatakor a sugárzási értékeket a mérési időpontok között a modell egy lineáris interpolációval közelítette. Ennek eredményeként napkelte előtt, és napnyugta után is érte sugárzás a felszínt, ami nagyban megnövelte az asszimilált CO₂ értékét. Ezen hibát az interpoláció módosításával lehetett megoldani, mégpedig úgy, hogy a napmagasságot (zenit szög) is figyelembe vettük a sugárzási értékek interpolációjakor. Az 5.2-es ábrán látható, hogy ennek eredményeként a LAI értéke már nem növekedett tovább, amikor a w_2 a hervadási pont alá csökkent. Ebben az esetben a LAI csökkenése úgy alakult ki, hogy a növény továbbra is fotoszintetizált (5.3 ábra), de az elhalás üteme nagyobb volt, mint a növekedésé. Az, hogy a növény még mindig képes volt CO₂ asszimilálására, a valósággal ellentmondó viselkedés, ugyanis a valóságban a harmatpont elérése után a növény már nem képes fotoszintetizálni, ami, a modellben úgy jelenik meg, hogy az asszimilált CO₂ mennyisége lecsökken nullára.



5.2 ábra. A LAI és a w_2 (az ábrán w_{g2}) alakulása az extrém száraz légköri kényszerek esetén, a sugárzási kényszerek helyes alkalmazásakor.

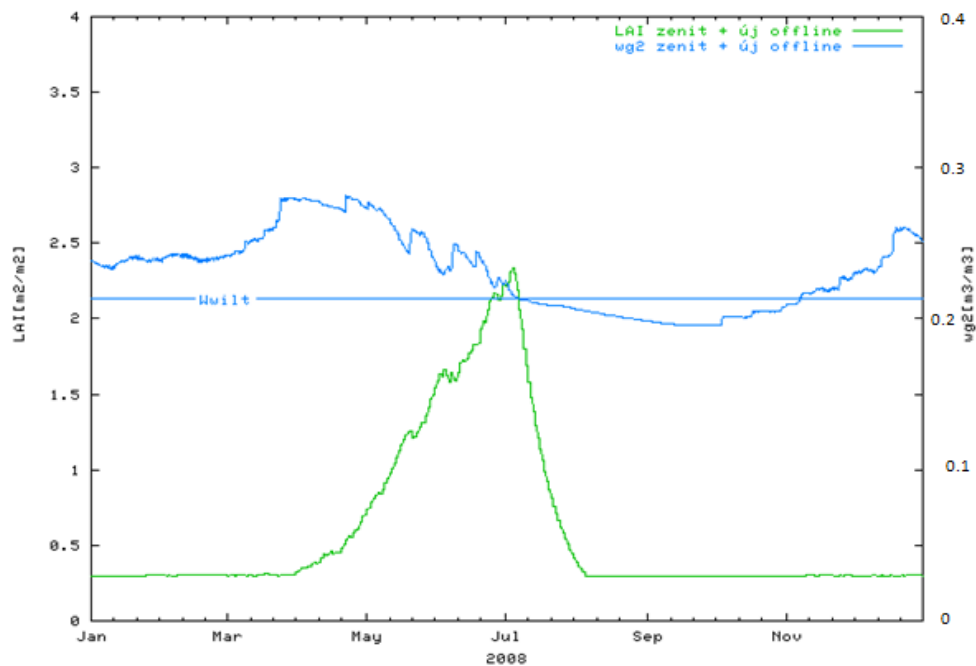


5.3 ábra. A w_2 (az ábrán w_{g2}) és a napi asszimilált CO_2 ($A_{n,\text{day}}$) értékek alakulása az extrém száraz légköri kényszerek esetén, a sugárzási kényszerek helyes alkalmazásakor.

Az CO_2 asszimiláció problémájára felhívtuk a francia fejlesztő központ figyelmét is. A CNRM-nél a problémára azt a megoldást találták, hogy megváltoztatták a modellben a szárazságtűrő növények talajnedvesség stresszel szembeni viselkedését.


Az ISBA-A-gs eredeti változatában a légyszárú szárazság tűrő növények (ilyen a 10-es parcella füves vegetációja is) mezofill vezetőképessége soha nem csökkent nullára (2.2 ábra zöld szaggatott vonal), ami azt eredményezte, hogy kedvezőtlen körülmények között is képes volt a növényzet CO_2 asszimilációra. Ezen változtattak a francia kutatóközpontban úgy, hogy igen erős szárazság esetén a szárazság tűrő növények mezofill vezetőképessége is lecsökkenjen nullára (2.2 ábra zöld vonal). Ennek a változtatásnak köszönhetően a LAI értéke a harmat pont elérése után rögtön lecsökkent, sőt túlságosan erős is volt a modellben az elhalás mértéke. Ezért ahhoz, hogy a modell viselkedése megfelelő legyen, a növények elhalásának parametrizálását (2.11) is meg kellett kicsit változtatni. Nevezetesen az időfüggő várható hasznos élettartamot (τ) növelték meg 5 napról 15-re. Ezáltal a növényzet már nem tudott olyan hirtelen elhalni, és a modell viselkedése közelebb került a valósághoz.

A sugárzási kényszerek helyes alkalmazásával, és a modell új verziójával (új offline program) kapott eredmények (5.4 ábra) már megfeleltek az elvárásoknak.



5.4 ábra. A LAI, és a w_2 (az ábrán w_{g2}) alakulása az extrém száraz légköri kényszerek esetén, az új modell verzió, és a sugárzási kényszerek helyes alkalmazásakor.

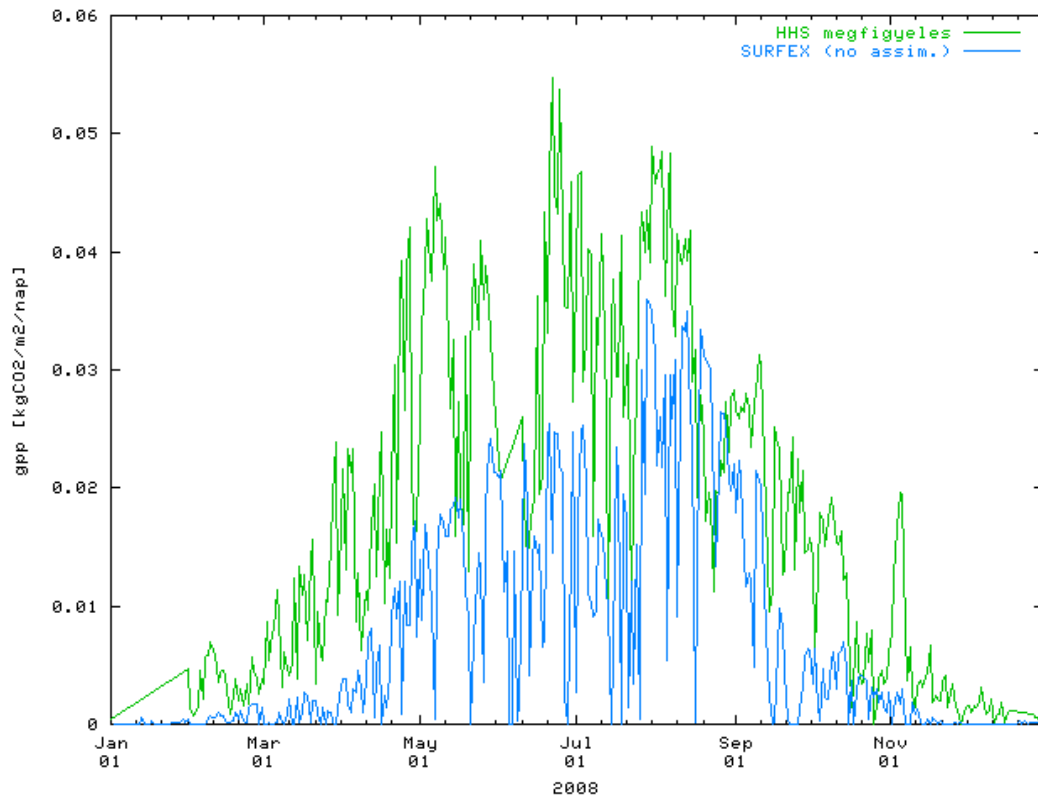
A SURFEX-et a további vizsgálataink során a zenit szög figyelembevételével interpolált sugárzási kényszerrel, és a modell újabb verziójával használtuk. Az új beállításokkal futtatott LAI, és GPP eredmények az 5.5-ös, és az 5.6-os ábrán láthatóak.



5.5 ábra. A LAI alakulása a hegyhátsáli rácsponton, a füves területen, a felszíni mérések és a SURFEX alapján, 2008-ban.

Az 5.5-ös ábrán a LAI-ra vonatkozó értékek láthatóak, zölddel a felszíni megfigyelések értéke a mérési hibával együtt feltüntetve, kékkel pedig a SURFEX, ISBA-A-gs sémája által számolt eredményei. A felszíni mérésekkel kapcsolatban tudjuk, hogy a 2008-as évben május 30-án és augusztus 18-án lekaszálták a fűvet, aminek hatása a LAI értékekben is meglátszik. Ez a hatás a modell futtatásánál nem volt figyelembe véve, ezért a két eredmény jelentősen eltér egymástól. Annyit azonban megállapíthatunk, hogy tavasszal túl lassú a LAI növekedése a valósághoz képest. A két kaszálás közötti időszakban pedig, ami a vegetációs időszak közepére esik, a modell fölülbecsli a LAI értékét. A modell ezen általános tulajdonságai, az összetett vegetációra vonatkozó vizsgálatainknál szembetűnőbben látszanak. A modell szisztematikus hibáinak kijavítására megoldást jelenthet az adatasszimiláció.

Emellett az olyan külső behatások, mint a kaszálás, vagy akár egy erdőtűz figyelembevétele is az adatasszimiláció használatával lehetséges.



5.6 ábra. A GPP alakulása a hegyhátsági rácsponton, a füves területen, a felszíni mérések és a SURFEX alapján, 2008-ban.

A GPP-re kapott eredmények az 5.6-os ábrán láthatóak, ahol ismételtén zöld jelzi a megfigyelések, és kék a SURFEX eredményeit. Az ábráról jól leolvasható, hogy a modell eredményei a felszíni mérések alatt maradnak. A miénkhez hasonló eredményt kaptak a francia, és az olasz kutatók is, amiből arra következtethetünk, hogy a GPP alulbecslését nem a mi speciális beállításaink, hanem a modell parametrizációjának pontatlansága okozza.

A GPP számításában szerepet játszik a napi asszimilált CO_2 értéke és a LAI is, hiszen a LAI felhasználásával integrálja a modell a levelek skáláján kiszámított nettó CO_2 asszimiláció értékét a teljes növényzetre. A GPP becslésének hibáját tehát okozhatja a CO_2 asszimiláció (A_n) számításának hibája, és vagy a növényzetre való összegzés helytelensége. Az A_n értéke legfőképp a sugárzástól és a levegő nedvességétől függ. A levegő nedvessége a mezofill vezetőképesség, és a levélben lévő CO_2 koncentráción

keresztül jelentősen befolyásolja a CO₂ asszimilációt. A fotoszintetikusan aktív sugárzástól pedig egy exponenciális összefüggésen keresztül függ a fotoszintézis mértéke, ahol a növényzet légzése is figyelembe van véve, de csak egy igen egyszerű egyenlet alapján. Az ezeket a kapcsolatokat leíró egyenletek hibája, vagy a bennük szereplő vegetációtípustól függő állandók helytelen értéke mind-mind kihathat a GPP értékére. A növényzetre való összegzésben fő hibaforrás lehet a LAI helytelen értéke, illetve szintén a sugárzás, ugyanis a modellben az A_n integrálásakor figyelembe van véve a növényzeten áthaladó sugárzás gyengülése. A modell hibáját tehát sok, egymással összekapcsolódó folyamat okozhatja, amelyek közül egyelőre nem tudjuk, hogy melyik a hibás.

A GPP értékek hibáján az asszimiláció bevezetése javíthat, hiszen a LAI, és a talajnedvesség asszimilálásával a LAI értékek pontosabbá válnak, ami a fent említett módon kihat a GPP értékére is.

5.1.2. Összetett vegetáció

Az összetett vegetációjú beállítás vizsgálatok a SURFEX offline futtatásából származó LAI értékeket a LandSAF LAI adatokkal hasonlítottuk össze, hiszen mindkét adatsor a rácspont vegyes vegetációjára számított átlagos LAI értékeket tartalmaz.

Az összetett vegetációra vonatkozó átlagos LAI értéket a modell úgy állítja elő, hogy a parcellák egymástól függetlenül számított LAI értékeiket (LAI_p) átlagolja a parcella hányadok figyelembevételével (f_p) (5.1).

$$\overline{LAI} = \sum_{p=1}^{12} f_p LAI_p \quad (5.1)$$

Az 5.7-es ábrán a hegyhátsági rácspont LAI_p értékei láthatóak, melyek menete, és nagysága is igen változatos. A rácspontban a parcella hányadok értékei:

$$f_4 = 19.1\%$$

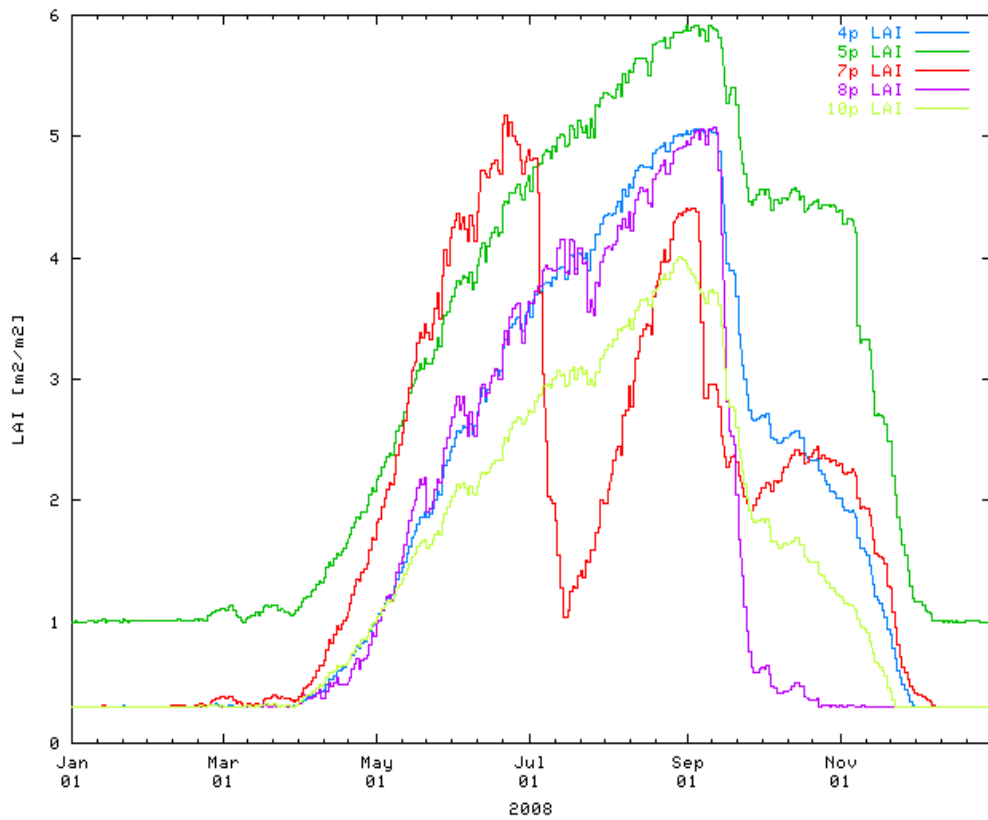
$$f_5 = 3.7\%$$

$$f_7 = 54.6\%$$


$$f_8 = 11.8\%$$

$$f_{10} = 10.6\%.$$

A parcella hányadokból kiolvasható, hogy a rácspontban a 7-es parcella, azaz a C3-as mezőgazdasági növények dominálnak. Ez az átlagos LAI értékének a kialakulásában is észrevehető (5.8 ábra).



5.7 ábra. A LAI értéke parcellánként a hegyhátsági rácsponton, a SURFEX alapján, 2008-ban.



5.8 ábra. A LAI átlagos értéke a hegyhátsági rácsponton, műholdas mérések és a SURFEX alapján, 2008-ban.

Az 5.8-as ábrán a modell és a mért értékek összehasonlítása alapján jól látható, hogy a modell a vegetációs időszak döntő hányadában felül, a téli, tavaszi időszakban, pedig alulbecsli a LAI értékét. Ezek a viszonylag nagy eltérések alátámasztják az asszimiláció szükségességét.

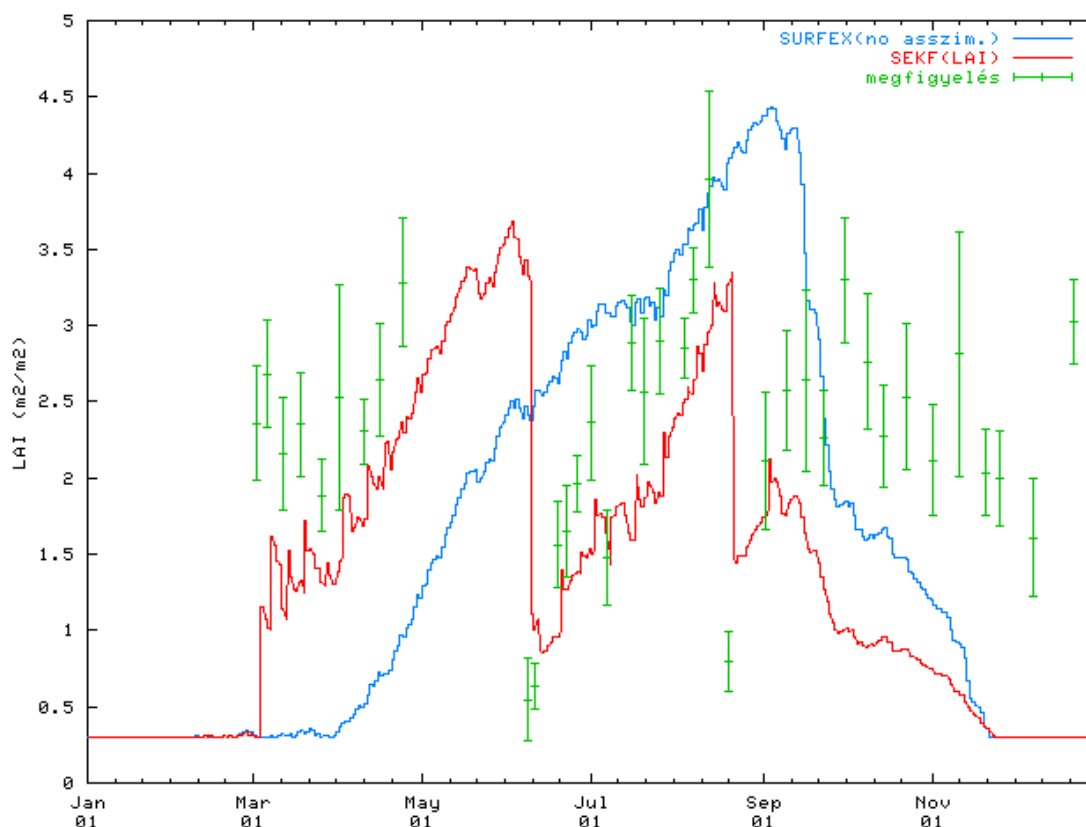
5.2. Az adatasszimilációs vizsgálatok

Az adatasszimilációval kapcsolatos vizsgálataink is szétbonthatóak két részre. Első lépésként az egyszerűbb, egy parcellás beállításon végeztünk el adatasszimilációt. Ekkor az asszimiláció végrehajtásához rendelkezésünkre álltak a felszíni mérésekből származó LAI és talajnedvesség mérések, amelyeket átalakítottunk SWI értékekké. Az adatasszimiláció eredményeit pedig a független mérésnek tekinthető GPP értékekhez hasonlítottuk.

Az összetett vegetációra végzett adatasszimilációs vizsgálatainknál a fő szempont az asszimilációs módszer vizsgálatára, és a rendszer korrekt működtetésére helyeződött. Kipróbáltuk a LAI asszimilálásánál az SEKF és az EKF módszert, amelyet korábban még nem vizsgáltak összetett vegetációjú beállításnál. A kezdeti asszimilációs futtatásaink alkalmával azt tapasztaltuk, hogy a modell sokszor összeomlott és leállt. Így először ezt a problémát kellett megoldanunk.

5.2.1. Fűves terület

A fűves területen végzett adatasszimiláció elvégzésekor többféle beállítást is megvizsgáltunk. Először azt néztük meg, hogy milyen hatással van az adatasszimiláció a LAI alakulására. Az 5.9-es ábrán a LAI SEKF módszerrel végzett asszimilációjának eredményei láthatóak az adatasszimiláció nélküli futtatáshoz és a megfigyeléshez viszonyítva. Ennél a futtatásnál a **B** és az **R** mátrix értéke is a LAI értékével arányosan változott, és egy nagyságrendbe estek.




5.9 ábra A LAI értéke az asszimiláció használatakor és nélküle, illetve a megfigyelések értékei. Az SEKF(LAI) jelölés az asszimiláció módját, és a zárójelben, az asszimilált változót jelöli.

Az 5.9-es ábrán jól látható, hogy milyen jelentősen befolyásolta a modell eredményeit az adatasszimiláció. A LAI értékei így már tudták valamelyest követni a kaszálások által változó LAI értékeket, és a tavaszi alul illetve nyári felülbecslésen is javított az adatasszimiláció.

A LAI értékek összehasonlításakor viszont nem szabad elfelejteni, hogy a LAI méréseket is felhasználtuk az adatasszimilációhoz. Az adatasszimilációt objektívan egy független, az asszimilációban nem szereplő, de annak eredményeivel összefüggő változó vizsgálatával tudjuk leellenőrizni; ilyen változó lehet a GPP.

Az adatasszimiláció hatását a GPP-re nézve az 5.10-es ábrán láthatjuk. Itt már nem olyan egyértelmű az értékek javulása. Tavasszal, a modell közelebb, nyáron viszont még távolabb került a megfigyeléstől, mint az adatasszimiláció nélküli futtatásnál. Ennek oka a LAI és a GPP kapcsolatában keresendő. A tavaszi időszakban ugyanis, a korábbi LAI alulbecslést az adatasszimiláció kijavította, és magasabb LAI értékeket eredményezett,

amelyek hatására a modell alapvetően alulbecsült GPP értéke szintén megnövekedett, ezzel közelebb kerülve a valósághoz. Nyáron ezzel szemben a LAI adatasszimiláció nélküli eredményei túl magasak voltak, így az asszimiláció hatására lecsökkentek, ami a GPP eleve alulbecsült értékében is csökkenést idézett elő.



5.10 ábra A GPP értéke az asszimiláció használatakor és nélküle, illetve a megfigyelések értékei. Az SEKF(LAI) jelölés az asszimiláció módját, és a zárójelben, az asszimilált változót jelöli.


A GPP, és LAI viselkedése alapján elmondható, hogy a GPP alulbecslését valószínűleg nem a LAI pontatlansága okozza, hanem a levél szintű CO₂ asszimiláció helytelen parametrizálása.

Az adatasszimiláció eredményeinek pontosságát több változó asszimilálásának bevezetésével fokozhatjuk. Az általunk bevezetett második változó a talajnedvesség értékekre vonatkozó SWI. A talajnedvesség helyes inicializálása azért fontos a vegetáció szempontjából, mert a talajban a növények számára hozzáférhető víz mennyisége nagyban befolyásolja a növekedésüket. Ezen kívül a talajnedvesség a látens, és a


szenzibilis hőáram szétválasztásában is fontos szerepet játszik, amely változók szintén hatással lehetnek a növények viselkedésére, a hőmérsékletet, avagy a vízgőzáró befolyásoló szerepük miatt.

A hegyhátsági mérések közötti talajnedvesség értékeket az asszimiláció elvégzéséhez átalakítottuk SWI értékekké a 3.2-es egyenlet alapján. Az egyik ok, amiért SWI értékeket használtunk a közvetlen w_2 mérések helyett az, hogy a mért w_2 értékeknél előfordult, hogy jelentősen meghaladták a modell által leírható w_2 értékeket, amit valószínűleg az okozhat, hogy a modell által használt talajtextúra eltér a valóságtól. Az SWI értéke viszont kevésbé függ a talajtextúrától, ezért célszerű volt a w_2 adatokat a minimális és maximális értékeik alapján SWI-vé átskálázni. Így a modellből és a mérésekből származó SWI értékek már összehasonlíthatóak voltak. Az SWI használata melletti másik érv pedig az volt, hogy a műholdas adataink, amelyeket a későbbiekben más rácspontokra is kiterjesztett adatasszimiláció során használnánk, SWI értékek. Ezért azt találtuk célszerűnek, ha az adatasszimilációs rendszert olyan beállítások mellett teszteljük, amelyeket a későbbi futtatások során is fel lehet használni.

Az 5.11-es ábrán látható a modell adatasszimiláció nélküli futásából származó SWI értékek összehasonlítva a mért SWI értékekkel, illetve az SWI és LAI mérések asszimilálásával végzett futtatás eredményei. Az ábrán jól látszik, hogy az adatasszimiláció nélküli modell eredmények és a mérések között jelentős az eltérés, de az adatasszimiláció hatására a modell menete megváltozik, és a mérések közvetlen közelébe kerül. Ebből arra következtethetünk, hogy a talajnedvesség parametrizációja viszonylag pontos, hiszen jó kezdeti értékből kiindulva a modell képes a valóságot jól követni. A LAI parametrizációja ezzel szemben sokkal bizonytalanabb, hisz ott láthattuk, hogy a megfigyelések asszimilálásának hatására se tudott a modell a megfigyelésekkel annyira együtt mozogni, mint itt az SWI értékek.




5.11 ábra. A mért, az adatasszimiláció nélkül és az adatasszimilációval együtt modellezett SWI értékek 2008-ban.



5.12 ábra. A LAI értékek alakulása, a LAI, illetve a LAI és az SWI asszimilálásakor az SEKF módszerrel, 2008-ban.

A második változó bevezetése az adatasszimiláció során jelentősen befolyásolta a modell LAI eredményeit. Az 5.12-es ábrán láthatjuk, hogy az SWI asszimilálásának hatására az év végi LAI alulbecslés sokat javult, és a nyári LAI értékek is közelebb kerültek a megfigyelésekhez. Tehát ez alapján megállapíthatjuk, hogy a SWI adatok felhasználása segíti a modell LAI értékeinek pontosítását.


A GPP értékeken (5.13 ábra) nem változtat olyan jelentősen az SWI bevezetése, mint a LAI-nál. A GPP-nél a legszembetűnőbb javulás szeptemberben látszik, ami egybeesik a LAI értékek változásával. A szeptember utáni időszakban az év végéig megfigyelhető egy enyhe javulás a GPP értékeiben, de az év végi értékeknél már nem olyan jelentős. Ez valószínűleg annak köszönhető, hogy késő ősszel és télen a növényzet már nem fotoszintetizál olyan aktívan, ezáltal a LAI értékének megváltozása már nem befolyásolta annyira a GPP alakulását.



5.13 ábra. A GPP értékének alakulása, a LAI, illetve a LAI és az SWI asszimilálásakor az SEKF módszerrel, 2008-ban.

Az eddigiekben csak az SEKF módszert használtuk, LAI függő háttér hiba kovariancia mátrixszal. Most nézzük meg, hogy hogyan alkalmazható az adatasszimiláció során az EKF módszer. Az 5.14-es ábrán összehasonlítottuk az SEKF, illetve EKF módszer LAI eredményeit. Mindekét esetben felhasználtuk az adatasszimilációhoz a hegyhátsági LAI, illetve SWI méréseket. Az 5.14-es ábrán a különbségek behatóbb vizsgálatának kedvéért feltüntettük még a két módszerrel kapott **B** mátrixok azon elemeinek alakulását, ami a LAI-ra vonatkozik, illetve az EKF módszer **M** modell operátorának szintén a LAI-ra vonatkozó értékei közül az 1-nél nagyobbakat. Az **M** operátor értékei azt jelzik, hogy a modell mennyire stabil, azaz egy adott változó kis változása az asszimilációs ablak elején, mekkora változássá nőné ki magát az analízis időpontjára. Az **M** linearizált modell operátort használjuk a **B** mátrix időbeli fejlődésének modellezésére is, tehát ha az **M** értéke jelentősen eltér az egységtől, akkor a háttér mező hibája is jelentősebben megváltozik, ezekben az esetekben különülhet el igazán az SEKF és az EKF módszer.

A LAI értékek vizsgálatakor látható, hogy nincs a két módszer között számottevő különbség, csupán egy-két helyen térnek el egymástól, de a menetük alapvetően nem különbözik. Kisebb eltérés figyelhető meg a tavaszi időszakban, amikor az SEKF-el kapott LAI értékek közelebb vannak a megfigyelésekhez, mint az EKF eredményei. Ennek magyarázatát a **B** értékekben találjuk, ugyanis ebben az időszakban az SEKF módszer **B** értékei majdnem végig meghaladják az EKF módszer **B** értékeit. Ennek az a következménye, hogy nagyobb hibával kezeljük a háttér mezőt az SEKF esetén, ezért a modell az asszimiláció során jobban a megfigyelések felé húz.




5.14 ábra. A LAI értékek és a **B** mátrix LAI-ra vonatkozó tagjainak (ábra alján) összehasonlítása az SEKF és az EKF módszer használatakor, két változó asszimilálásánál, 2008-ban. Az ábrán feltüntetett **M** értékek az EKF módszer során előállított **M** modell operátor LAI-ra vonatkozó elemének 1-nél nagyobb értékű elemei.

Az egyetlen jelentős eltérés a két eredmény között szeptember elején tapasztalható. Ekkor a nyár végére igen megnövekedett LAI értékek miatt az SEKF módszer LAI függő **B**-je viszonylag magas értéket vett fel, így amikor az augusztus végén bekövetkezett kaszálás utáni LAI mérésnél a LAI drasztikusan lecsökkent, az analízist a modell a **B** nagy értéke miatt inkább a megfigyeléshez húzta. Ennek következtében szeptembertől viszont már nem tudta annyira megközelíteni a valóságot. Ebből is látszik, hogy nem számolhatunk a modellben közvetlenül a megfigyelés értékével, egyrészt mert a megfigyelésnek is van hibája másrészt lehet, hogy a modell dinamikájával össze nem egyeztethető értéket kapunk. Valamint az is látszik, hogy a fentiek miatt nem szabad túl nagy **B**-t választani.

Az 5.15-es ábrán ugyanezen beállítások GPP eredményei szerepelnek. Itt is az látható, hogy az SEKF, és az EKF módszer igen hasonló eredményeket adott. A két módszer

eredményeinek statisztikai vizsgálatánál azt mondhatjuk el, hogy a modell eredmények és a megfigyelések közötti bias az EKF módszernél kisebb (EKF $bias = -0,0089$, SEKF $bias = -0,0097$), a korreláció viszont kis mértékben nagyobb az SEKF módszernél (SEKF $corr = 0,399$, EKF $corr = 0,358$).



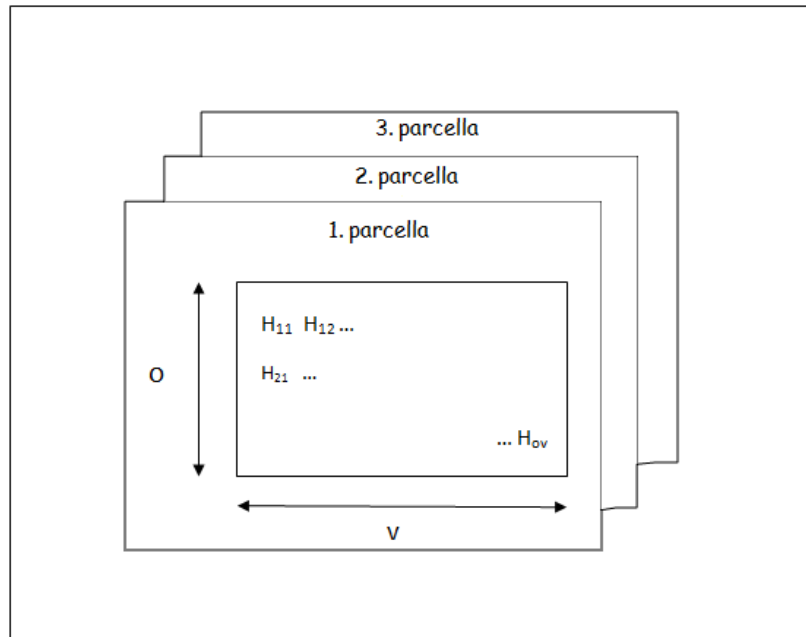
5.15 ábra. A GPP értékek az SEKF és az EKF módszer használatakor, két változó asszimilálásánál, illetve a mérések alapján 2008-ban.

Az ábrák alapján elmondhatjuk, hogy a két módszer igen hasonló eredményt adott, mely a **B** értékek hasonló alakulásának köszönhető. Az EKF módszer mellett szól az, hogy ennél a módszernél a **B** értékét a modell maga határozza meg, az SEKF módszernél viszont a külső beállításoktól jelentősen függ a **B** alakulása. Az EKF módszer tehát jól leírja a **B** változását, de a nagyságában szerepet játszik a **Q** mátrix értéke is, amely egyelőre szintén egy külső beállítás eredménye. Tehát az SEKF módszernél bizonytalanságot visz a rendszerbe a **B** értékének megválasztása, az EKF módszernél pedig a **Q** értékének megválasztása, ami szintén kihat a **B** nagyságának alakulására.

5.2.2. Összetett vegetáció

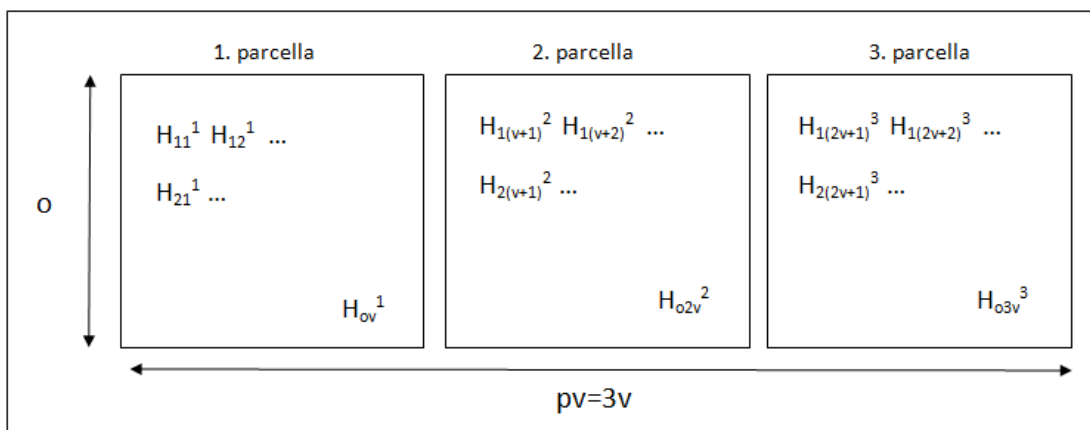
A SURFEX több parcellás asszimilációs futtatásai során azt tapasztaltuk, hogy olyan esetekben, amikor a **B** értéke nagy volt, a modell leállt, mert negatív LAI értékeket eredményezett az adatasszimiláció. A **B** értékének megnövekedését az EKF alkalmazásakor okozhatja a modell operátor nagy értéke, illetve a nagy modell hiba, amelyet az időben fejlesztett **B**-hez hozzáadunk. Az SEKF beállításnál a **B** értékét mi határozzuk meg, illetve a LAI-tól függő esetben egy összefüggést definiálunk. Ezekben az esetekben is előfordulhat, hogy a **B** értéke nem megfelelő, és az asszimiláció során a modell leáll. A nagy **B** értékek azt eredményezik, hogy mivel a háttér mező hibája nagy, a modell a megfigyelés közelébe próbál kerülni. A megfigyelésünk viszont az átlagos LAI-ra vonatkozik, tehát a modellben is az átlagot kell változtatnunk. Az átlagos LAI változtatását a parcellákon meghatározott értékek változtatásával éri el a modell. A problémát részben az okozta, hogy a modell az adatasszimiláció során külön kezelte a parcellák értékeit. Így fordulhatott elő az, hogy olyan esetben, amikor az átlagot csökkenteni kellett, a csökkentés eléréséhez a modell egy parcella értékét csökkentette jelentősen, a többi parcella figyelembe vétele nélkül. A nem kiegyenlített változtatás pedig negatív LAI-hoz vezetett, ami fizikailag valótlan mennyiség, ezért a modell leállítását okozta.

A probléma tehát a megfigyelés és a modell értékei közötti kapcsolat kezelésben volt, ezt pedig a megfigyelési operátor határozza meg. A megfigyelési operátor alakja a modell eredeti verziójában úgy volt definiálva, mint egy 3 dimenziós mátrix, ahol minden rácsponton, minden parcellához tartozott egy \mathbf{H}^p operátor (5.16 ábra). A parcellák \mathbf{H}^p operátorai $o \times v$ -dimenziós mátrixok voltak ($\mathbf{H}^p \in \mathbb{R}^{o \times v}$), ahol o a megfigyelési vektor dimenziója, v pedig az asszimilált modellváltozók vektorának dimenziója. Ez alapján \mathbf{H} -t egy $o \times v \times p$ -dimenziójú téglatestként lehetne ábrázolni, ahol p a parcellák száma.



5.16 ábra. A \mathbf{H} operátor eredeti alakja (példa 3 parcellára).

Ennél az elgondolásnál a \mathbf{B} és a \mathbf{K} mátrix is hasonló struktúrájú, azaz a parcellák elvannak különítve egymástól. Ez, mint ahogy azt tapasztaltuk, azt eredményezi, hogy a parcellák közötti kapcsolattal nem számol a modell az adatasszimiláció során. A parcellák közötti függetlenség problémáját a \mathbf{H} mátrix átstrukturálásával oldottuk meg, nevezetesen átírtuk a mátrixot egy $o \times pv$ dimenziójú mátrixszá (5.17 ábra).

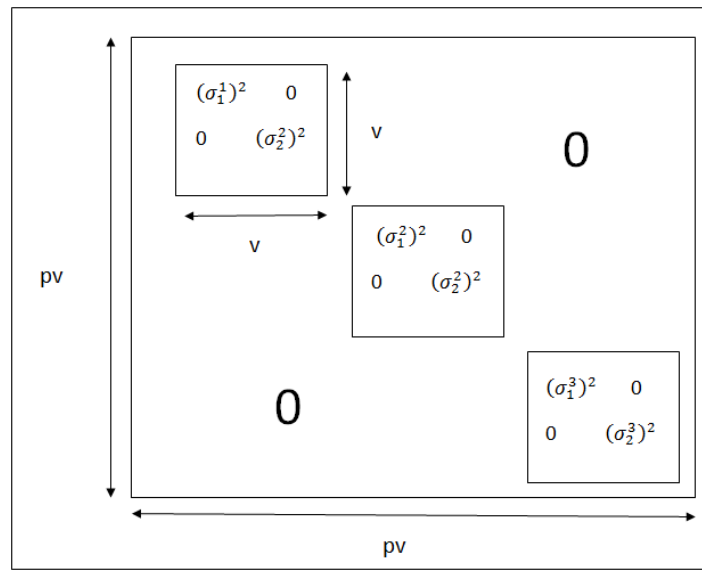


5.17 ábra. A \mathbf{H} operátor átalakított alakja (példa 3 parcellára).

A 5.17-es ábrán látszik, hogy a parcellánkénti külön \mathbf{H}^p mátrix ugyanúgy megmaradt, mint a korábbi verzióban (5.16 ábra), csak a teljes \mathbf{H} mátrix elrendezése változott.

$$\mathbf{H}_{11}^1 = f_{p1} \frac{\partial y_1^1}{\partial x_1^1} \quad (5.2).$$

Az 5.2-es egyenlet az 5.17-es ábrán látható elemek magyarázataként, a linearizált modell operátor egyik elemét fejezi ki, pontosabban azt, hogy az 1-es megfigyelési változó értéke az 1-es parcellán hogyan változik, ha az 1-es modellváltozó 1-es parcellabeli értékét perturbáljuk, mindez beszorozva a parcella hányaddal. Ennél az újfajta felosztásnál a \mathbf{B} és a \mathbf{K} szerkezetét is meg kellett változtatnunk. A \mathbf{B} az új elgondolás szerint egy $pv \times pv$ -dimenziójú mátrix, az első időlépcsőben ráadásul diagonális is (5.18 ábra), a keresztkorrelációs tagokat a \mathbf{B} fejlődése során számítjuk ki.



5.18 ábra. A \mathbf{B} mátrix felépítése és értékei az első időpontban (példa 3 parcellára).

A \mathbf{K} mátrix a 4.4-es egyenlet alapján pedig egy $pv \times o$ -dimenziójú mátrix. Összefoglalva tehát, ha x_a és $x_f \in \mathbb{R}^{pv}$, illetve $y_o \in \mathbb{R}^o$, akkor a mátrixok:

$$\mathbf{H} \in \mathbb{R}^{o \times pv}$$

$$\mathbf{B} \in \mathbb{R}^{pv \times pv}$$

$$\mathbf{R} \in \mathbb{R}^{o \times o}$$

$$\mathbf{K} \in \mathbb{R}^{pv \times o}$$

$$\mathbf{M} \in \mathbb{R}^{pv \times pv}$$

$$\mathbf{Q} \in \mathbb{R}^{pv \times pv}.$$

Fontos megjegyezni, hogy ha a mátrixok általunk bevezetett alakjával számolunk, akkor a \mathbf{K} -ban szereplő $(\mathbf{H}\mathbf{B}^t\mathbf{H}^T + \mathbf{R})$ mátrix elemeiben a mátrixok megfelelően összeszorozott

elemei parcellákra összegezve jelennek meg. Tehát, amikor ennek a mátrixnak az inverzét vesszük a **K** egyenletében (4.4), akkor minden parcellát figyelembe veszünk a súlyok megállapításánál.

Az **M** mátrix ilyenkor egy $pv \times pv$ -dimenziójú blokk diagonális mátrix, azaz csak az átlóban elhelyezkedő, $v \times v$ -dimenziójú blokkokban van értéke, ami abból adódik, hogy a parcellák fejlődése a modellben továbbra is egymástól függetlenül történik. Tehát ha az egyik parcellán megváltoztatom a kezdeti értéket, az csak az adott parcellára lesz hatással, a többire nem.

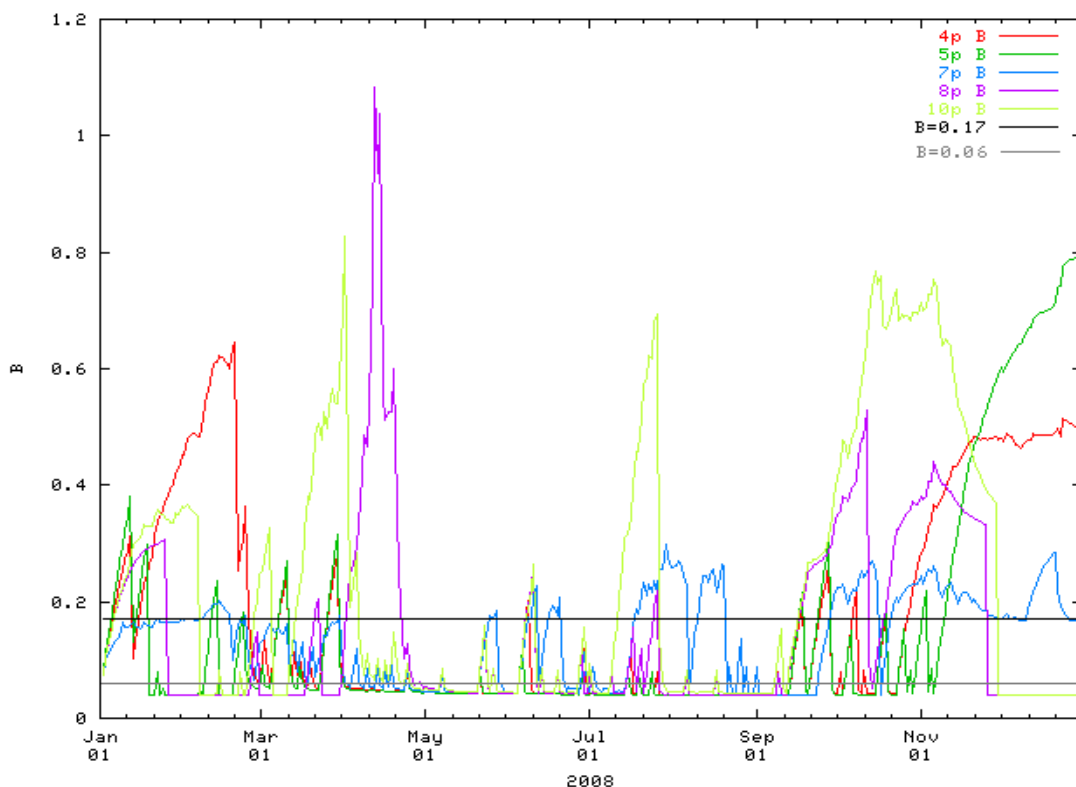
Az **A** mátrixot a 4.5-ös egyenlet alapján számoljuk, amiben a **K**, és **H** mátrixok általános mátrixok. Ezáltal az **A** ugyan szimmetrikus mátrix lesz, de nem diagonális, ami kihat a **B** értékére is, hiszen $\mathbf{B} = \mathbf{MAM}^T + \mathbf{Q}$. Tehát ez alapján, habár **M** és **Q** diagonális, **B** nem marad diagonális, hanem megjelennek benne a keresztkorrelációs tagok is. Ez számunkra jó hír, mert a keresztkorrelációs tagok eddig el voltak hanyagolva, így viszont maga a modell számítja ki őket, amivel javít a hibabecsléseinken.

A parcellák közötti összefüggés figyelembevételével az adatasszimilációs rendszer sokkal stabilabbá vált. Az összeomlások előfordulását viszont így sem sikerült teljesen megszüntetnünk. Így is előfordult, igaz ritkábban, hogy a **B** értéke túl nagyra nőtt, és az adatasszimiláció leállt. Ezen probléma kezelésére egyelőre egy olyan beállítást vezettünk be az adatasszimilációs programba miszerint, ha az inkrementum hozzáadásával a LAI értéke az előre definiált minimális LAI értéke alá csökkenne, akkor a csökkenést a program csak a minimum eléréséig engedje. Ennek a mesterséges változtatásnak a hatását ezután figyelembe vettük a **K** mátrix kiszámításakor is, hogy a számításaink konzisztensek maradjanak. Ezt a megoldást nem lehet véglegesnek tekinteni. Úgy gondoljuk, hogy a probléma teljes megoldását az jelentené, ha az EKF módszerben sikerülne meghatározni a **Q** mátrix pontos értékét. A **Q** mátrix becslésének megvalósítása egy igen bonyolult feladat, a statisztikai és diagnosztikai hiba becslési kísérleteink nem vezettek eredményre. Ennek a feladatnak a megoldása túlmutat a dolgozat korlátain.

A fent említett problémák miatt a több parcellás adatasszimilációs kísérleteinket igyekeztünk leegyszerűsíteni, hogy a rendszer működését jobban átlátva tudjuk azt megvizsgálni. Ezért kezdetben csak egy változót, a LAI-t asszimiláltuk, és az EKF módszernél az eddig LAI függő **R** és **Q** mátrixot egy konstans értékkel helyettesítettük. Az SEKF módszernél pedig leegyszerűsítettük a szintén LAI függő **R**-t és **B**-t, egy konstans

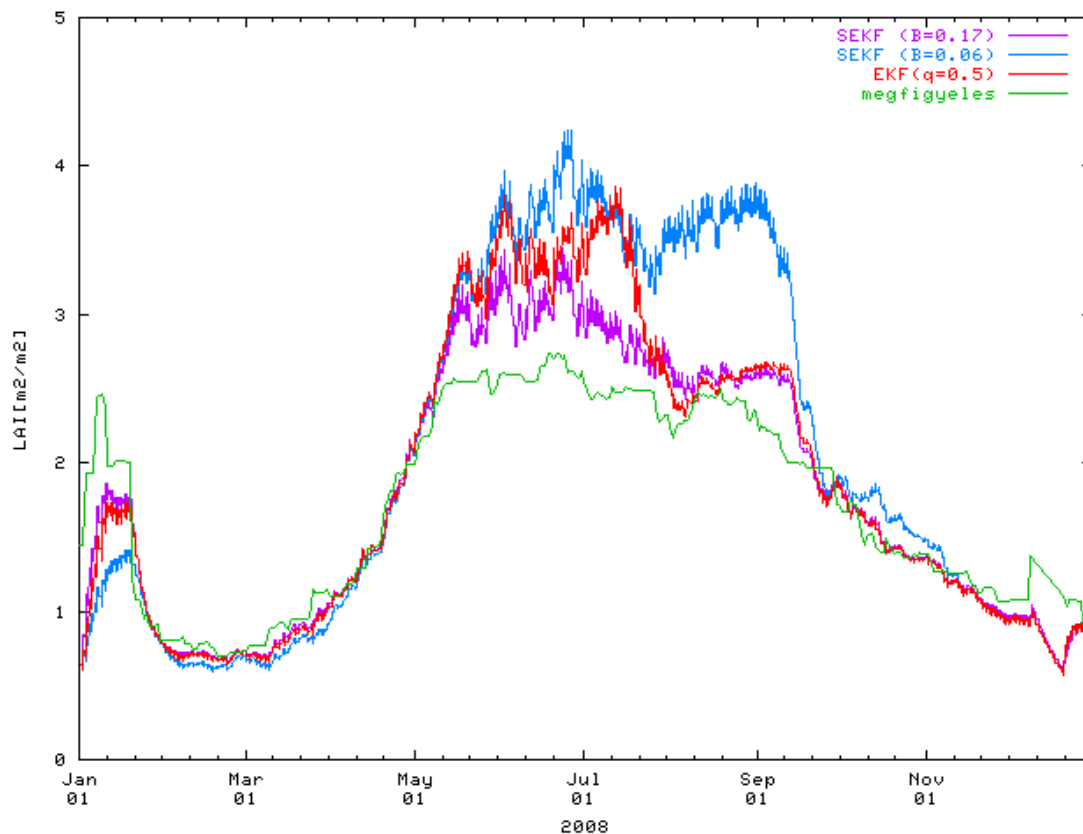
értékekre. Az SEKF módszer konstans \mathbf{B} értékeit, az EKF futtatás \mathbf{B} értékei alapján határoztuk meg, hogy hasonló nagyságrendbe essenek, és így össze tudjuk hasonlítani az idő függő \mathbf{B} , és a sokkal egyszerűbb konstans \mathbf{B} hatását az asszimilációra.

Az 5.19-as ábrán az EKF módszerrel kapott \mathbf{B} mátrix értékei vannak ábrázolva parcellánként. Ezek az értékek a parcellákra vonatkozó szórásnégyzeteket jelentik. Az ábrán látható, hogy a \mathbf{B} értékek igen különbözőek a parcellákon, de alapvetően azonos évi menetet követnek, azaz télen és tavasszal sokkal nagyobb a változékonyságuk, mint nyáron. Az ábrán látható fekete vonal ($\mathbf{B}=0.17$) az SEKF módszer konstans \mathbf{B} értékét jelöli, ami az EKF által adott \mathbf{B} értékek átlaga. A szürke vonal pedig az EKF-ből származó \mathbf{B} értékek egyik leggyakrabban előforduló értéke ($\mathbf{B}=0.06$). Ezt az állandót azért használtuk, mert úgy találtuk, hogy az átlagos \mathbf{B} értékét túlságosan felhúzták a kiugró értékek, és az EKF \mathbf{B} értékei valójában nem az átlag, hanem egy sokkal kisebb érték körül változnak.



5.19 ábra. A háttérhiba kovariancia mátrix szórásnégyzeteinek értéke az EKF módszer szerint (parcellánként) és az SEKF szerint (két konstans).


A 5.19-as ábra beállításai szerint kapott LAI eredmények, amelyeknél a LandsAF műholdas LAI méréseket asszimiláltuk, az 5.20-es ábrán láthatóak.



5.20 ábra. A mért és asszimilációval kapott LAI értékek, az EKF és két SEKF beállítás futtatásakor, 2008-ban.


Az 5.20-es ábrán látszik, hogy az EKF módszerrel kapott eredmények a két SEKF módszer eredményei között húzódnak. Ez is jelzi, hogy mennyi bizonytalanság van az SEKF módszer külsőleg beállított B értékeiben. A viszonylag magas $B=0.17$ -es beállítás a megfigyelésekhez, a kicsinek tekinthető $B=0.06$ -os beállítás, pedig a háttér mezőhöz húzta közelebb a modellt.

Az adatasszimiláció eredményein itt is javíthatunk a talajnedvesség asszimilálásának bevezetésével (5.21 ábra). Az összetett vegetációra vonatkozó beállításnál a műholdas SWI értékeket használtuk az adatasszimilációhoz. Ezek a mérések, ugyanúgy mint a LandSAF LAI mérései az egész rácspontra vonatkoznak, tehát a vegetációtípusok átlagára. Az 5.21-es ábra LAI értékeinek vizsgálatánál megállapítható, hogy az SWI bevezetése sokat javított az adatasszimiláció eredményén. Itt az EKF módszert használtuk, konstans R és Q értékek mellett.



5.21 ábra. A mért és a LAI, illetve a LAI és az SWI felhasználásával EKF módszerrel asszimilált LAI értékek, 2008-ban.

A fejlődés szemléltetése céljából vessük össze a legjobb eredményt adó asszimilációs futtatás, azaz az 5.20-as ábrán szereplő két változós EKF futtatás eredményét, az adatasszimiláció nélkül futtatott modell eredményeivel és a megfigyelésekkel (5.21 ábra). Az 5.21-es ábra alapján elmondhatjuk, hogy az adatasszimiláció az év minden szakaszában javított a LAI értékeken.



5.21 ábra. A LAI értékei a LAI és az SWI asszimilálása után az EKF módszerrel, az asszimiláció nélküli futtatások és a mérések alapján, 2008-ban.

Összességében tehát megállapíthatjuk, hogy mind az egy, mind a több parcellás beállítás esetén jobb eredményeket értünk el a LAI és az SWI együttes felhasználásával, mint a LAI egyedüli asszimilálásánál. Az SEKF és az EKF módszer eredményei nem különböztek sokban egymástól, de mindkét módszer igen érzékeny a **B** értékére. Az SEKF módszernél ez a bizonytalanság közvetlenül a **B** meghatározásánál, az EKF módszernél pedig a **Q** mátrix bizonytalan becslésén keresztül kerül elő. Mindemellett úgy gondoljuk, hogy az EKF módszerben több lehetőség rejlik, és ennek a módszernek a helyes alkalmazásával lehet majd működtetni a több parcellára vonatkozó adatasszimilációs rendszert, amely a későbbiekben a 2 dimenziós futtatások során szükséges.

6. Összefoglalás

A dolgozatomban bemutattam, és megvizsgáltam a SURFEX modell természetes felszínt modellező, CO₂-re érzékeny ISBA-A-gs sémáját. A vizsgálataim tárgya a fotoszintézis modellezésének eredményeként létrejövő GPP és LAI értékek voltak, amelyek egy éven belüli változását vizsgáltam. A kiválasztott év 2008 volt, erre az időszakra rendelkezésünkre álltak mind felszíni, mind műholdas mérési adatok a kiválasztott, hegyhátsági rácspontra vonatkozóan.

A modellt különböző vegetációjú beállítások mellett offline módon futtattuk, először egy kezdeti értékből kiindulva egy évre vonatkozó légköri kényszerek felhasználásával, majd napi LAI, illetve SWI értékek asszimilálásának közbeiktatásával. A felhasznált adatasszimilációs módszer az EKF, illetve az SEKF volt.

A modell füves területre vonatkozó adatasszimiláció nélküli futtatásánál egy olyan modell hibát észleltünk, amely a vegetáció valósággal ellentmondó viselkedésére utalt. Ezt a hibát több lépésben, először a sugárzási kényszerek helyes interpolálásának alkalmazásával, majd a francia fejlesztőközpont által javasolt modellváltoztatások figyelembevételével javítottuk ki. A modell ezen változtatások utáni eredményei alapján megállapítottuk, hogy hibákkal ugyan, de a modell képes a LAI és a GPP évi változásának követésére. A modell a LAI értéket tavasszal jellemzően alul, nyáron pedig felül becsli, a GPP-re viszont egész évben túl alacsony értékeket ad.

Az eredményeken nagyban javított a LAI asszimilálásának bevezetése, és még tovább javított az eredményeken az SWI és a LAI együttes asszimilációja. Az egyszerű vegetációjú füves terület vizsgálatai rámutattak, hogy a GPP alulbecslése valószínűleg nem a LAI, és ezáltal nem a teljes növényzet figyelembevételének hibás modellezéséből, hanem inkább az egy levélre vonatkozó CO₂ asszimiláció számításának hibájából adódik. Az SEKF és az EKF módszer eredményei nagyon hasonlóak voltak. Mindkét rendszer igen érzékeny a **B** mátrix értékére, az SEKF módszer füves területre vonatkozó alkalmazásakor a **B** értéket nem teljesen konstans, hanem LAI függő értéknek tekintettük.

Az összetett vegetációjú rácspontra a LAI asszimilálása az SEKF és az EKF módszerrel korábban még nem volt alkalmazva. Ennek következtében ezeknek a beállításoknak a kezdeti használatakor sok hiba lépett fel, amelyeket a modell adatasszimilációval foglalkozó részének jelentős módosítása révén tudtunk megoldani. Az adatasszimilációs

rendszeren elvégzett változtatásaink hatására a rendszer sokkal stabilabbá vált, de így is előfordulhat még a modell leállításával járó modell hiba. Ennek a problémának egyelőre egy nem végleges, félig empirikus megoldása került a modellbe. A korrekt megoldást úgy gondoljuk, hogy az EKF módszeren belül a helyes \mathbf{Q} mátrix alkalmazása adná meg. Mindemellett úgy találtuk, hogy a \mathbf{B} megfelelő megválasztásakor az SEKF és az EKF módszer igen hasonló eredményeket ad, de azt gondoljuk, hogy az EKF alkalmazásában több lehetőség rejlik.

Az EKF alkalmazása felé mutat az egyszerű vegetációnál kipróbált SEKF módszer LAI függő \mathbf{B} mátrixa is, ami ugyan nem változik az időben, de a LAI éves menetén keresztül mégis változó értékeket vesz fel. Ezen kívül az adatasszimilációs rendszer stabil futtatását is az EKF alkalmazásától várnánk, a helyes \mathbf{Q} mátrix megtalálása után. Nem beszélve az EKF módszer fő elméleti előnyéről, a vizsgált felszíni folyamatok modellezhetőségétől függő háttér hiba kovariancia mátrixról.

7. Köszönetnyilvánítás

Elsősorban témavezetőmnek, Kullmann Lászlónak szeretném megköszönni a rengeteg rám áldozott idejét, és szakértő témavezetését. Köszönettel tarozom az Országos Meteorológiai Szolgálatnak, a SURFEX modell használatáért, és a modellfuttatás számítógépes szükségleteinek biztosításáért.

Köszönöm belső konzulensem segítségét, és köszönöm Haszpra Lászlónak és Barcza Zoltánnak, hogy a hegyhátsáli mérési adataikat rendelkezésemre bocsátották.

A diplomamunkát az Európai Unió Hetedik Keretprogram GEOLAND2 projekt keretén belül végeztük el, a szerződés száma 218795.

A diplomamunka továbbá az Európai Unió támogatásával és az Európai Szociális Alap társfinanszírozásával jöhetett létre, a támogatási szerződés száma TAMOP 4.2.1./B-09/1/KMR-2010-0003.

8. Irodalomjegyzék

Albergel, C., Rüdiger, C., Pellarin, T., Calvet, J.-C., Fritz, N., Froissard, F., Suquia, D., Petitpa, A., Pigué, B., and Martin, E., 2008. From near-surface to root-zone soil moisture using an exponential filter: an assessment of the method based on in-situ observations and model simulations. *Hydrol. Earth Syst. Sci.*, 12, 1323–1337., doi:10.5194/hess-12-1323-2008

Balsamo, G., Bouyssel, F., Noilhan, J., 2004. A simplified bi-dimensional variational analysis of soil moisture from screen-level observations in a mesoscale numerical weather-prediction model. *Q. J. R. Meteorol. Soc.*, 130, 895–915 doi: 10.1256/qj.02.215

Barcza, Z., Haszpra, L., Kondo, H., Saigusa, N., Yamamoto, S., Bartholy, J., 2003. Carbon exchange of grass in Hungary. *Tellus B*, 55, 187-196.

Barbu, A.L., Calvet, J.-C., Mahfouf, J.-F., Albergel, C., Lafont, S., 2011. Assimilation of Soil Wetness Index and Leaf Area Index into the ISBA-A-gs land surface model: grassland case study. *Biogeosciences Discussions*, 8, 1831-1877., doi:10.5194/bgd-8-1831-2011

Baret, F., Hagolle, O., Geiger, B., Bicheron, P., Miras, B., Huc, M., Berthelot, B., Nino, F., Weiss, M., Samain, O., Roujean, J.L., and Leroy, M., 2007. LAI, FAPAR, and FCover CYCLOPES global products derived from Vegetation. Part 1 : principles of the algorithm. *Remote Sensing of Environment*, 110, 305-316.

Bhumralkar, C.M., 1975. Numerical experiment on the computation of ground surface temperature in an atmospheric general circulation model. *J. Appl. Meteor.*, 14, 1246-1258.

Blackadar, A.K., 1976. Modeling the nocturnal boundary layer. *Proc. Third Symp. on Atmospheric Turbulence, Diffusion and Air Quality*, Boston, *Amer. Meteor. Soc.*, 46-49.

Boone, A., Calvet, J.-C., and Noilhan, J., 1999. Inclusion of a third soil layer in a land surface scheme using the force-restore method. *J. Appl. Meteor.*, 38, 1611–1630.

Bouttier, F., and Courtier, P., 1999. Data assimilation concepts and methods. ECMWF, *Meteorological Training Course Lecture Series*

Brut, A., Rüdiger, C., Lafont, S., Roujean, J.-L., Calvet, J.-C., Jarlan, L., Gibelin, A.-L., Albergel, C., Le Moigne, P., Soussana, J.-F., Klumpp, K., Guyon, D., Wigneron, J.-P. and

Ceschia, E., 2009. Modelling LAI at a regional scale with ISBA-A-gs: comparison with satellite-derived LAI over southwestern France. *Biogeosciences*, 6, 1389-1404.

Deardorff, J.W., 1977. A parameterization of ground surface moisture content for use in atmospheric prediction models. *J. Appl. Meteor.*, 16, 1182-1185.

Calvet, J.-C. and Noilhan, J., 2000. From near-surface to root-zone soil moisture using year-round 25 data. *J. Hydrometeor.*, 1, 393-411.

Calvet, J.-C., and Soussana, J.-F., 2001. Modeling CO₂-enrichment effects using an interactive vegetation SVAT scheme. *Agric. For. Meteorol.*, 108, 129-152.

Calvet, J.-C., J. Noilhan, J.-L. Roujean, P. Bessemoulin, M. Cabelguenne, A. Olioso, and J.-P. Wigneron, 1998. An interactive vegetation SVAT model tested against data from six contrasting sites. *Agric. For. Meteorol.*, 92, 73-95.

Calvet, J.-C., Gibelin, A.-L., Van den Hurk, B., 2008. 'Scientific Documentation of ISBA-A-gs in SURFEX (Version 4)' Issue No 1.1, CNRM/Météo-France, KNMI.

Cushman-Roisin, B., and Beckers, J.-M., 2009. Chapter 22 Data Assimilation, In: Introduction to Geophysical Fluid Dynamics - Physical and Numerical Aspects, *International Geophysics Series*, vol. 98, Academic Press

Fisher, M., 2001. Assimilation Techniques: Approximate Kalman Filters and Singular Vectors, ECMWF, *Meteorological Training Course Lecture Series*

Garrigues, S., Lacaze, R., Baret, F., Morisette, J.T., Weiss, M., Nickeson, J., Fernandes, R., Plummer, S., Shabanov, N.V., Myneni, R., and Yang, W., 2008. Validation and Intercomparison of Global Leaf Area Index Products Derived From Remote Sensing Data. *Journal of Geophysical Research*, 113, G02028, doi:10.1029/2007JG000635

Gibelin, A.-L., Calvet, J.-C., Roujean, J.-L., Jarlan, L., Los, S. O., 2006. Ability of the land surface model ISBA-A-gs to simulate leaf area index at the global scale: comparison with satellites products. *J. Geophys. Res.* 111, D18102.

Gibelin, A.-L., Calvet, J.-C. and Viovy, N., 2008. Modelling energy and CO₂ fluxes with an interactive vegetation land surface model Evaluation at high and middle latitudes, *Agric. For. Meteorol.*, 148, 1611-1628., doi: 10.1016/j.agrformet.2008.05.013

Goudriaan, J., van Laar, H.H., Van Keulen, H. and Louwerse, W., 1985. Photosynthesis, CO₂ and plant production. In: Day, W. and Atkin, R.K. (Eds.), *Wheat growth and modelling*. NATO ASI Series, Plenum Press, New York, Series A, 86, 107-122.

Haszpra, L., Barcza, Z., Davis, K. J., Tarczay, K., 2005. Long-term tall tower carbon dioxide flux monitoring over an area of mixed vegetation. *Agric. For. Meteorol.*, 132, 58-77. doi: 10.1016/j.agrformet.2005.07.002

Masson, V., 2000. A physically-based scheme for the urban energy budget in atmospheric models. *Boundary-Layer Meteorology*, 94, No.3, 357-397. doi: 10.1023/A:1002463829265

Masson V., Champeaux, J.-L., Chauvin, F., Meriguet, C. and Lacaze, R., 2003. A global database of land surface parameters at 1km resolution in meteorological and climate models. *J. Climate*, 16, 1261-1282.

Mironov, D., Golosov, S., Heise, E., Kourzeneva, E., Ritter, B., Scheider, N. and Terzhevik, A., 2005. FLake- A Lake Model for Environmental Applications. Proc. of the 9th Workshop on Physical Processes in Natural Waters, 4 - 6 September 2005, Folkard, A. and Jones, I., Eds., Lancaster University, UK, 73. (PDF)

Lemaire, G. and Gastal, F., 1997. N uptake and distribution in plant canopies. In: Lemaire, G. (Ed.), *Diagnosis of the Nitrogen Status in Crops*. Springer, Berlin, pp. 343.

Le Moigne, P., 2009. 'SURFEX scientific documentation'. Issue No.1. CNRM, Météo-France: Toulouse, France.

Noilhan, J., and Planton, S., 1989. A simple parameterization of land surface processes for meteorological models. *Mon. Wea. Rev.*, 117, 536-549.

Reichstein, M., Flage, E., Baldocchi, D., Papale, D., Aubinet, M., Berbigier, P., Bernhofer, C., Buchmann, N., Gilmanov, T., Granier, A., Grünwald, T., Havránková, K., Ilvesniemi, H., Jonous, D., Knohl, A., Laurila, T., Lohila, A., Loustau, D., Matteucci, G., Meyer, T., Miglietta, F., Ourcival, J.-M., Pumpanen, J., Rambal, S., Rotenberg, E., Sanz, M., Tehunen, J., Seufert, G., Vaccari, F., Vesala, T., Yakir, D., Valentini, R., 2005. On the separation of net ecosystem exchange into assimilation and ecosystem respiration: review and improved algorithm. *Global Change Biology*, 11, pp 1424–1439., doi: 10.1111/j.1365-2486.2005.001002.x

Voogt, M., van den Hurk, B.J.J.M. and Jacobs, C., 2006. The ECMWF land surface scheme extended with a photosynthesis and LAI module tested for a coniferous site, KNMI publication: WR-06-02, 3/1/2006, 22, De Bilt, The Netherlands, <http://www.knmi.nl/publications/fulltexts/agrformetd0600207.pdf>

[1] Product User Manual, Vegetation Parameters, SAF/LAND/UV/PUM_VEGA/2.1, 2008

[2] AccuPAR LP-80 PAR/LAI ceptometer Operator's Manual Version 6,
Decagon Devices, Inc.

[3] CS615 Water Content Reflectometer, version: 8221-07, Campbell Scientific Inc.

9. Függelék

Nézzük meg részletesebben, hogy a Kálmán-szűrő esetében hogyan vezethető le az analízis hiba kovariancia mátrix, aminek kapcsán az is belátható, hogy mi \mathbf{K} optimális értéke, illetve hogy hogyan illik bele a képbe az időben fejlődő \mathbf{B} . A levezetést Bouttier és Courtier (1999) levezetésének segítségével végeztem el.

Az analízist a $t+1$ -edik időpontban az asszimilációs ablak végén számítjuk ki, tehát a hibája is ekkor érdekel minket. A $t+1$ -edik időpontban a hibák a következőképpen írhatóak fel:

$$\begin{aligned}\varepsilon_a^{t+1} &= x_a^{t+1} - x_t^{t+1} \\ \varepsilon_a^{t+1} &= x_a^{t+1} - \mathcal{M}_{t \rightarrow t+1}(x_t^t) + \varepsilon_M\end{aligned}\tag{9.1}$$

$$\begin{aligned}\varepsilon_b^{t+1} &= x_b^{t+1} - x_t^{t+1} \\ \varepsilon_b^{t+1} &= \mathcal{M}_{t \rightarrow t+1}(x_a^t) - \mathcal{M}_{t \rightarrow t+1}(x_t^t) + \varepsilon_M\end{aligned}\tag{9.2}$$

$$\begin{aligned}\varepsilon_o^1 &= y_o^1 - \mathcal{H}_1(x_t^{t+1}) \\ \varepsilon_o^{t+1} &= y_o^{t+1} - \mathcal{H}(\mathcal{M}_{t \rightarrow t+1}(x_t^t) - \varepsilon_M)\end{aligned}\tag{9.3}$$

A célunk az, hogy ε_a^{t+1} értékét a 9.1-es egyenletről eltérő módon fejezzük ki, amihez felhasználjuk azt, a BLUE-nál (4. fejezet) már említett alapfeltevést, miszerint lineáris analízist készítünk. A lineáris feltevés szerint az analízist a háttérmező javított alakjában keressük, ahol a háttérmezőhöz hozzáadott érték megfelel az inkrementumnak. Az inkrementum pedig lineárisan függ a megfigyelés, és a háttérmező eltérésétől. Ezek szerint tehát a 4.3-as egyenletről kiindulva az inkrementum felírható a 9.4-es, 9.5-as és 9.6-os egyenlet alakjában is.

$$\Delta x^{t+1} = x_a^{t+1} - x_b^{t+1}\tag{9.4}$$

$$\Delta x^{t+1} = \varepsilon_a^{t+1} - \varepsilon_b^{t+1}\tag{9.5}$$

$$\Delta x^{t+1} = \mathbf{K}^{t+1}[y_o^{t+1} - \mathcal{H}(\mathcal{M}_{t \rightarrow t+1}(x_a^t))]\tag{9.6}$$

A 9.5-ös és a 9.6-os egyenletről megkapjuk a 9.7-ast

$$\varepsilon_a^{t+1} - \varepsilon_b^{t+1} = \mathbf{K}^{t+1}[y_o^{t+1} - \mathcal{H}(\mathcal{M}_{t \rightarrow t+1}(x_a^t))]\tag{9.7}$$

amit úgy alakítunk át egy egyszerű bővítéssel, hogy már csak hibák szerepeljenek benne (9.9).

$$\begin{aligned}\varepsilon_a^{t+1} - \varepsilon_b^{t+1} &= \mathbf{K}^{t+1}[y_o^{t+1} - \mathcal{H}(\mathcal{M}_{t \rightarrow t+1}(x_t^t) - \varepsilon_M) + \mathcal{H}(\mathcal{M}_{t \rightarrow t+1}(x_t^t) - \varepsilon_M) - \\ &\quad - \mathcal{H}\mathcal{M}_{t \rightarrow t+1}x_t\end{aligned}$$

$$\varepsilon_a^{t+1} - \varepsilon_b^{t+1} = \mathbf{K}^{t+1}[\varepsilon_o^{t+1} - \mathbf{H}(\mathbf{M}_{t \rightarrow t+1} \varepsilon_a^t + \varepsilon_M)] \quad (9.9)$$

A 9.9-as egyenletből egy átrendezéssel megkapjuk ε_a^{t+1} értékét, és 9.2-es egyenletet (9.10) illetve a linearizált modell operátort felhasználva (9.11) jutunk el ε_a^{t+1} végső alakjához (9.12).

$$\varepsilon_a^{t+1} = \varepsilon_b^{t+1} + \mathbf{K}^{t+1}[\varepsilon_o^{t+1} - \mathbf{H}(\mathbf{M}_{t \rightarrow t+1} \varepsilon_a^t - \varepsilon_M)] \quad (9.9)$$

$$\varepsilon_a^{t+1} = \mathcal{M}_{t \rightarrow t+1}(x_a^t) - \mathcal{M}_{t \rightarrow t+1}(x_t^t) + \varepsilon_M + \mathbf{K}^{t+1}[\varepsilon_o^{t+1} - \mathbf{H}(\mathbf{M}_{t \rightarrow t+1} \varepsilon_a^t - \varepsilon_M)] \quad (9.10)$$

$$\varepsilon_a^{t+1} = \mathbf{M}_{t \rightarrow t+1} \varepsilon_a^t + \varepsilon_M - \mathbf{K}^{t+1} \mathbf{H}(\varepsilon_a^t + \varepsilon_M) + \mathbf{K}^{t+1} \varepsilon_o^{t+1} \quad (9.11)$$

$$\varepsilon_a^{t+1} = (\mathbf{I} - \mathbf{K}^{t+1} \mathbf{H})(\mathbf{M}_{t \rightarrow t+1} \varepsilon_a^t + \varepsilon_M) + \mathbf{K}^{t+1} \varepsilon_o^{t+1} \quad (9.12)$$

A 9.12-es egyenletet felhasználva megkapjuk az analízis hiba kovariancia mátrixot a t+1-edik időpontban (9.13).

$$\mathbf{A}^{t+1} = E(\varepsilon_a^{t+1} \varepsilon_a^{t+1T}) = (\mathbf{I} - \mathbf{K}^{t+1} \mathbf{H})(\mathbf{M}_{t \rightarrow t+1} \mathbf{A}^t \mathbf{M}_{t \rightarrow t+1}^T + \mathbf{Q})(\mathbf{I} - \mathbf{K}^{t+1} \mathbf{H})^T + \mathbf{K}^{t+1} \mathbf{R} \mathbf{K}^{t+1T} \quad (9.13)$$

Az \mathbf{A}^{t+1} értéke itt a \mathbf{K}^{t+1} -től függ, tehát az optimális \mathbf{K}^{t+1} érték az lesz, amelynél \mathbf{A}^{t+1} értéke minimális, hiszen az a célunk, hogy az analízis hibája a lehető legkisebb legyen. Ezt a szélsőérték keresési feladatot úgy végezzük el, hogy az \mathbf{A}^{t+1} mátrix nyomát, tehát a modellváltozók hibájának összegzett szórásnégyzeteit, minimalizáljuk. Ekkor a $Tr(\mathbf{A}^{t+1})$ -t, ami egy \mathbf{K}^{t+1} -től függő függvénynek tekinthető (9.14), \mathbf{K}^{t+1} körül sorba fejtjük (9.15 és 9.16). A minimum pedig ott lesz, ahol a függvény deriváltja nullával egyenlő (9.17).

$$Tr(\mathbf{A}^{t+1})(\mathbf{K}^{t+1}) = g(\mathbf{K}^{t+1}) \quad (9.14)$$

$$g(\mathbf{K}^{t+1} + \mathbf{L}) - g(\mathbf{K}^{t+1}) = g'(\mathbf{K}^{t+1})\mathbf{L} + O((\mathbf{L})^2) \quad (9.15)$$

(Az \mathbf{L} egy tetszőleges teszt mátrix.)

$$Tr(\mathbf{A}^{t+1})(\mathbf{K}^{t+1} + \mathbf{L}) - Tr(\mathbf{A}^{t+1})(\mathbf{K}^{t+1}) = d_{\mathbf{K}}[Tr(\mathbf{A}^{t+1})]\mathbf{L} + O((\mathbf{L})^2) \quad (9.16)$$

$$d_{\mathbf{K}}[Tr(\mathbf{A}^{t+1})] = 0 \quad (9.17)$$

A 9.16-os egyenletet kifejtve, és az \mathbf{L} -ben másodrendű tagokat elhanyagolva a 9.19-as egyenletet kapjuk.

$$d_{\mathbf{K}}[Tr(\mathbf{A}^{t+1})]\mathbf{L} = 2Tr(\{\mathbf{K}^{t+1}[\mathbf{H}(\mathbf{M}_{t \rightarrow t+1} \mathbf{A}^t \mathbf{M}_{t \rightarrow t+1}^T + \mathbf{Q})\mathbf{H}^T + \mathbf{R}] - \mathbf{M}_{t \rightarrow t+1} \mathbf{A}^t \mathbf{M}_{t \rightarrow t+1}^T + \mathbf{Q}\}\mathbf{H}^T + \mathbf{R})\mathbf{K}^{t+1T} - \mathbf{H}(\mathbf{M}_{t \rightarrow t+1} \mathbf{A}^t \mathbf{M}_{t \rightarrow t+1}^T + \mathbf{Q})\mathbf{K}^{t+1T} \quad (9.19)$$

A 9.19-as egyenlet alapján látható, hogy \mathbf{L} bármilyen megválasztása mellett a derivált nulla, ha (9.19)

$$[\mathbf{H}(\mathbf{M}_{t \rightarrow t+1} \mathbf{A}^t \mathbf{M}_{t \rightarrow t+1}^T + \mathbf{Q})\mathbf{H}^T + \mathbf{R}]\mathbf{K}^{t+1T} - \mathbf{H}(\mathbf{M}_{t \rightarrow t+1} \mathbf{A}^t \mathbf{M}_{t \rightarrow t+1}^T + \mathbf{Q})\mathbf{K}^{t+1T} = 0 \quad (9.19)$$

ami ekvivalens azzal, hogy (9.20)

$$\mathbf{K}^{t+1} = (\mathbf{M}_{t \rightarrow t+1} \mathbf{A}^t \mathbf{M}_{t \rightarrow t+1}^T + \mathbf{Q}) \mathbf{H}^T [\mathbf{H} (\mathbf{M}_{t \rightarrow t+1} \mathbf{A}^t \mathbf{M}_{t \rightarrow t+1}^T + \mathbf{Q}) \mathbf{H}^T + \mathbf{R}]^{-1} \quad (9.20).$$

Ha a 9.20-as egyenletbe behelyettesítjük a háttérhiba kovariancia mátrix $t+1$ -re vonatkozó képletét (9.21), akkor megkapjuk az optimális \mathbf{K} alakját (9.22) a BLUE-ban már ismert alakban (4.4), azzal a különbséggel, hogy itt a \mathbf{K} és a \mathbf{B} értéke is függ az időpont megválasztásától.

$$\mathbf{B}^{t+1} = \mathbf{M}_{t \rightarrow t+1} \mathbf{A}^t \mathbf{M}_{t \rightarrow t+1}^T + \mathbf{Q} \quad (9.21)$$

$$\mathbf{K}^{t+1} = \mathbf{B}^{t+1} \mathbf{H}^T [\mathbf{H} \mathbf{B}^{t+1} \mathbf{H}^T + \mathbf{R}]^{-1} \quad (9.22)$$

A fenti levezetésben tehát megmutattuk, hogy miként alkalmazható a Kálmán-filter elmélete a BLUE-val együtt, és hogy ekkor miként alakulnak a hiba kovariancia mátrixok, illetve a nyereség mátrix értéke.