

FELHŐZÖTTSEGMÉRÉS, OPTIKAI FELHŐFELISMERŐ ALGORITMUSOK ÖSSZEHASONLÍTÁSA – 2. RÉSZ

Horváth Gábor, Egri Ádám, Blahó Miklós

Környezetoptika Laboratórium, Biológiai Fizika Tanszék, Eötvös Loránd Tudományegyetem

Barta András, Barta Pál

Estrato Kutató és Fejlesztő Kft., Budapest

Horváth Ákos

Rutherford Appleton Laboratory, Remote Sensing Group, Oxford

Karl Bumke

GEOMAR – Helmholtz-Zentrum für Ozeanforschung, Kiel

Andreas Macke

Leibniz-Institut für Troposphärenforschung, Leipzig

Eredmények

Az általunk vizsgált 50 Atlanti-óceáni égbolton a felhőborítottság 20–100% között változott. A 3. ábra az első belső borítón egy részben felhős ég I intenzitásának, p polarizációfokának és α polarizációs szögének mintázatait mutatja a spektrum vörös (650 nm), zöld (550 nm) és kék (450 nm) tartományában. Mint látható, 10° -nál alacsonyabb napállás mellett a polarizációfok a zeniten áthúzódó, a szoláris-antiszoláris meridiánra merőleges széles, felhőtlen sávban magas ($p > 50\%$), míg a felhőfény mindenütt csak gyengén poláros ($p < 10\%$). A polarizációs szög mintázata tükröszimmetrikus a szoláris-antiszoláris meridiánra a hullámhossztól függetlenül. Ezek a robusztus α -mintázatok a felhők miatt is csak kissé módosultak.

A 4. ábra a felhődetekció egy eredményét mutatja, amelynek alapjául a 3. ábra intenzitás- és polarizációs mintázatai szolgáltak. A 4.a ábrán az égbolt szín- és intenzitás mintázata (azonos a 3. ábráéival) látható, míg a 4.b ábrán a konszenzusos felhőmaszk, amit három emberi észlelő együttesen határozott meg. A 4.c ábra a vizsgált felhődetekciós algoritmusok legjobbika, a PNN detektor által felismert felhőmaszkot mutatja, míg a 4.d ábra az utóbbi eltéréseit a konszenzusos felhőmaszkhoz képest.

Az 5. ábra az első belső borítón a felhődetekció egy másik eredményét mutatja egy majdnem teljesen borult égbolt esetén, amikor a napeleváció 16° volt, a felhőzöttség pedig 96% a konszenzusos felhőmaszk szerint.

A vizsgált 13 felhődetekciós algoritmus által hibásan detektált képpontok arányának a 10 véletlenszerűen választott tesztkészletre vett átlagát a 3. táblázat

foglalja össze. Az RBD, HTA, RBR, WD, WDAI, WSDS és k NN algoritmusok átlagos hibája hasonló volt: 18,57 és 23,58% közti. A csak a polarizációfokot használó p RG és p DG algoritmusok voltak a legpontatlanabbak 29,94 és 42,88%-os hibával. A polarizációfokot használó neurális hálózaton alapuló Sp NN algoritmus hibája 23,82% volt, ami így nem adott jobb eredményt a nem-neurális hálózaton alapuló algoritmusokhoz képest. A polarizációs információkat nem használó neurális hálózaton alapuló SINN és NNN algoritmusok a 16,05 és 16,32%-os hibájukkal jobb eredményt értek el a nem-neurális hálózaton alapuló algoritmusoknál. A minden lehetséges (polarizációs, globális és nem-optikai) adatot felhasználó PNN algoritmus érte el a legkisebb, 15,32% hibát. A WSDS algoritmus 1,00% szórása volt a legkisebb, míg a p DG és p RG-é a legnagyobb: 2,69 és 2,35%. A többi algoritmus szórása 1,09 és 1,61% közé esett.


Az egyes emberi megfigyelők által felismert felhőmaszkok hibája a konszenzusos felhőmaszkhoz viszonyítva (vagyis azon képpontok aránya, amelyek esetén a megfigyelő nem értett egyet a csoport konszenzussal) 3,32, 3,31 és 2,74% volt az 50 tesztmérésre átlagolva. Megjegyezzük, hogy az összes képpont 90%-át mindhárom megfigyelő azonos módon detektálta, és legalább 93%-ban egyetértett bármely két megfigyelő.

A hibásan detektált képpontoknak a 10 véletlenszerűen választott tesztkészletre vett arányát külön-külön a 4. táblázat foglalja össze. Mint látható, a neurális hálózaton használó algoritmusok jobban teljesítettek a többinél, nemcsak átlagosan, hanem minden egyes tesztkészlet esetén is.

A cikk 1. részének (*Fizikai Szemle*, 2015. július–augusztusi szám) 2. táblázata az általunk vizsgált négy neurális hálózat (NN) alapú felhődetekciós algoritmus bemeneti paramétereit tartalmazza, ahol az egyes paraméterek használatát a PNN, NNN, SINN és Sp NN algoritmusokban \times jelzi. Az NNN és PNN algoritmusok globális paramétereket is felhasználnak, amelyek a képek egészére vonatkoznak, míg a WSDS, SINN, Sp NN, NNN és PNN algoritmusok nem-optikai paramétereket is figyelembe vesznek, mint például a napmagasság és a Naptól mért relatív azimutszög. A 3. táblázat összehasonlító statisztikái

Köszönjük a német Alfred Wegener Intézetnek a Polarstern kutatóhajó ANT-XXVII/1 expedícióján való részvételünk lehetőségét. Kutatómunkánkat az OTKA K-105054 (*Égbolt-polarimetria a felhők felismerésére és a polarimetrikus viking-navigációnak kedvező meteorológiai viszonyok vizsgálatára*) pályázat támogatta. Horváth Gábor köszöni a német Alexander von Humboldt Alapítvány műszeradományát és egy három hónapos kutatási ösztöndíját (3.3-UNG/1073032 STP, 2013 június 1. – augusztus 31., Regensburgi Egyetem). Köszönjük Farkas Alexandra doktorandusz segítségét az angol cikkünk magyarra fordításában.





4. ábra. Példa egy felhődetekcióra a 3. ábra mérésének használatával. a) Az égbolt fényképe. b) Konszenzusos felhőmaszk (fehér: felhő, szürke: tiszta ég, fekete: tereptárgyak). c) A PNN algoritmus által detektált felhőmaszk (fehér: felhő, szürke: tiszta ég, fekete: tereptárgyak). d) A konszenzusos felhőmaszk és a PNN algoritmus által felismert felhőmaszk közti különbségek. Középszürke: helyesen felhőnek vagy tiszta égnek detektált képpontok. Sötétszürke: hibásan tiszta égnek detektált felhők. Világosszürke: hibásan felhőnek detektált tiszta ég.

alapján megállapítható, hogy a nem-neurális hálózatot használó algoritmusok közül a WDS algoritmus hibája a legkisebb, ami arra utal, hogy a nem-optikai paraméterek javíthatják a felhődetekció pontosságát.

Elemzés

A k NN, SINN, S pNN, NNN és PNN felhődetekciós algoritmusok a mesterséges intelligencia módszerekhez tartoznak, amelyek képesek feldolgozni, figyelembe venni a másként nehezen felfedezhető összefüggéseket. A nem mesterséges intelligencia algoritmusok (RBR, WD, WDAI, WDS) utánozhatnak olyan összefüggéseket, amelyeket egy szakértő felhős mérés-

sek elemzésével fel tud tárni, de rejtett kapcsolatokat nem tudnak felismerni, különösen a polarizációval kapcsolatosakat nem, hiszen a fény polarizációját az emberi szem nem látja.

Ugyanakkor a felügyelt módon tanított felhődetekciós algoritmusok akkor a leghatékonyabbak, ha kellően nagyszámú bemenettel tanítjuk őket. Például a 3. és 4. táblázat jól mutatja, hogy bár a k NN egy mesterséges intelligencia algoritmus, a hibája hasonló a nem mesterséges intelligencia algoritmusok hibájához. Ez a k NN algoritmus általunk használt megvalósításának volt köszönhető, amelyben csupán a három különböző színcsatornában (R, G, B) mért I_R , I_G , I_B fényintenzitást használtuk bemenetként. A vizsgált esetben egy $256 \times 256 \times 256$ -os színtömböt használtunk, ami 16 MB

memóriát jelent, ha a tömb minden eleme 1 bájtos. Ugyanakkor a k NN által használt memória mérete gyorsan nő a bemeneti paraméterek számával: n bemeneti paraméter esetén 256^n bájt.

A WDAI és PNN algoritmusok polarizációs információkat használnak, míg a többi csak fotometrikus információkat. Az NNN és PNN algoritmusok globális paramétereket is használnak, amelyek a kép egészére vonatkoznak, míg a többi csak lokális információkat, amelyek csak a vizsgált képpontra vagy annak közvetlen környezetére jellemzőek. A WDS, NNN és PNN algoritmusok figyelembe vesznek nem-optikai jellemzőket is, míg a többi csak optikai jellemzőket használ. Az NNN és PNN algoritmusok rendelkeznek a legkisebb hibával (3. táblázat), mivel ezek mesterséges intelligencia algoritmusok nagyszámú bemenő para-

felhődetekciós algoritmus	átlagos hiba (%)	szórás (%)	polarizációs adatok használata	globális paraméterek használata	nem-optikai paraméterek használata
RBD	23,58	1,40			
WD	21,46	1,45			
RBR	21,64	1,41			
k NN	19,63	1,14			
HTA	20,78	1,61		×	
WDAI	19,80	1,21			
WDS	18,57	1,00			×
p DG	42,88	2,69	×		
p RG	29,94	2,35	×		
S pNN	23,82	1,15	×		×
SINN	16,32	1,12			×
NNN	16,05	1,24		×	×
PNN	15,32	1,09	×	×	×

A 10 tesztkészlet 25 mérését ugyanaból az ANT-XXVII/1 expedíción gyűjtött 50 mérésből választottuk ki véletlenszerűen. Az egyes algoritmusok által használt polarizációs információkat, globális paramétereket, nem-optikai paramétereket × jelöli.

A 13 felhődetekciós algoritmus által hibásan detektált képpontok aránya a 10 véletlenszerűen választott tesztkészletre külön-külön

No.	RBD	WD	RBR	kNN	HTA	WDAI	WDS	pDG	pRG	SpNN	SINN	NNN	PNN
1.	23,01	20,37	20,61	19,37	19,35	19,43	18,24	38,77	27,33	22,93	16,04	16,03	15,71
2.	23,69	24,01	24,24	21,25	23,05	21,73	20,16	47,94	32,84	25,19	17,98	18,46	15,56
3.	21,88	20,06	20,40	18,34	19,06	18,68	17,92	41,51	27,71	22,43	15,21	14,95	13,47
4.	24,05	22,76	22,93	20,76	22,56	21,05	19,39	43,64	32,22	24,61	17,89	16,85	16,52
5.	20,89	21,85	22,02	19,38	20,94	19,65	18,28	44,20	29,48	23,26	15,77	15,40	15,54
6.	24,95	22,36	22,31	21,06	21,94	21,12	19,96	42,14	30,69	25,26	17,51	17,19	16,42
7.	22,29	19,39	19,58	18,46	18,39	18,60	17,95	39,95	28,14	22,79	15,70	14,34	15,01
8.	21,55	20,30	20,58	18,18	20,19	18,68	17,22	41,88	27,79	23,24	15,84	15,05	14,23
9.	20,59	21,11	21,18	19,28	20,08	18,59	17,58	43,09	29,31	23,15	14,79	15,64	14,13
10.	22,92	22,35	22,54	20,16	22,19	20,52	18,95	45,73	33,86	25,38	16,46	16,59	16,59
AV	22,58	21,46	21,64	19,63	20,78	19,80	18,57	42,88	29,94	23,82	16,32	16,05	15,32
SD	1,40	1,45	1,41	1,14	1,61	1,21	1,00	2,69	2,35	1,15	1,12	1,24	1,09

Az átlag (AV) és szórás (SD) az utolsó két sorban a 3. táblázatból származik. Minden tesztkészletre és az átlagos hibára is a legkisebb hibát félkövér betűkkel szedték.

méterrel, köztük nem-optikai és globális paraméterekkel is. A PNN algoritmus ezen kívül polarizációs információkat is használ, ami megmagyarázza, hogy miért ad jobb eredményt az NNN algoritmusnál.

A PNN és NNN algoritmusok eredményei közti különbség kicsi. Ugyanakkor a PNN algoritmus jobb teljesítménye nem meglepő, mivel több információt használ. A kiértékeléshez 50 eltérő égbolt mért polarizációs mintázatait használtuk úgy, hogy 10 különböző módon választottunk ki belőlük 25 algoritmustanító eget és a maradék 25 égen teszteltük az adott algoritmust. Ezzel csökkentettük annak esélyét, hogy egy gyengébb algoritmus egy adott mérési készlethez jobban alkalmazkodjon, mint egy egyébként jobban teljesítő algoritmus, és ezzel tévesen kisebb hibát érjen el. Mivel az NNN és PNN detektorok ugyanazon méréseket használták, a képminőség nem magyarázhatja a PNN algoritmus jobb eredményeit.

A 13 bemutatott felhődetekciós algoritmus eléggé szerteágazó volt. Hangsúlyozzuk, hogy a vizsgáltaknál összetettebb algoritmusok, például azok valamilyen kombinációja, jobb eredményeket érhet el. Például azt vizsgálva, hogy az egyes algoritmusok pontossága miként függ a Nap relatív pozíciójától vagy a horizont fölötti magasságtól, összeállítható egy olyan kombinált algoritmus, amely az egyes rész-algoritmusok eredményeit különböző súlyokkal veszi figyelembe az égbolt különböző tartományaiban. Célunk az volt, hogy összevegyünk számos nem-neurális hálózat alapú algoritmust, amely az emberi megfigyelő felhődetektáló módszerét utánozza a égbolton vagy a mért polarizációs mintázatokon. Továbbá megvalósítottuk a PNN neurális hálózatot, amely sok bemeneti paramétert használ úgy, hogy a kimenet bemenettől való függése nincs előre meghatározva.

Az Atlanti-óceáni expedíció során a Nap ritkán közelítette meg a zenitet, még az Egyenlítő környékén is csak délben és rövid időre. Ugyanakkor a zenitet közelítő napmagasságok mellett az ég általában tiszta volt, így e méréseket nem tudtuk használni felhődetekciós algoritmusok tanítására és tesztelésére. Nagy napmagasságok esetén a polarizációfok és polarizációs szög mintázatai nagymértékben különböznek az alacsonyabb napmagasság mellettiekétől, így ekkor külön algoritmusokra lehet szükség. Mivel a felhasznált méréseknél a napmagasság 4° és 40° közé esett, ezt a különleges esetet nem tudtuk vizsgálni, e probléma körülményeire külön kutatást igényel. Korábbi tapasztalataink alapján a napkitakaró tárcsa és a Polarstern felépítményei által kitakart területek nagysága meghaladja a hibásan felhősnek detektált területek nagyságát. Emiatt a tesztkészletből kihagytuk a tiszta égboltokat tartalmazó méréseket, ami nem befolyásolta a felhődetekciós algoritmusok fejlesztését.


Az égboltfény α polarizációs szöge nem használható felhődetekcióra, mert annak mintázata nagyon robusztus, még felhős viszonyok között is. Létezik azonban olyan felhődetekciós algoritmus, ami figyelembe veszi az égbolt α -mintázatát is [2]. Ugyanakkor kizárólag az α változásait figyelembe véve rossz felhődetekciós pontosságot lehet csak elérni, ezért az algoritmusainkban nem használtuk ezt a paramétert.

A Polarstern hajónak mint mozgó platformnak megvolt az a hátránya, hogy a polarimetriához szükséges három polarizációs felvételt a forgóanalizátoros képalkotó műszerünkkel egymásután elkészítve, a hajó billegéséből adódóan mozgási műtermékekhez vezethetett. Néhány mérésünk minősége valóban csökkent e jelenség miatt. Ugyanakkor az 50 tesztmé-

rés kiválasztásakor különös figyelmet fordítottunk arra, hogy kihagyjuk azon méréseket, amelyeken a kiértékelés után ilyen mozgási műtermékek adódtak. Elméletben ez a jelenség elkerülhető, ha a polarimetriához szükséges három felvételt azonos időben készítjük el. A valóságban egy ilyen megközelítés a következő nem-triviális problémákat veti fel: (i) A legfontosabb a három kamera optikai tengelye tökéletes párhuzamosságának biztosítása. (ii) Egy másik nehézség, hogy a három kamera érzékelője kissé eltérő választ ad azonos fényintenzitásokra még akkor is, ha azonos típusúak, ami keresztkalibrációt igényel. Felhasználhatók lettek volna a hajó belső szenzorainak adatai, amelyek megadják a hajó pontos állásszögét, hogy ezzel korrigáljuk az egyes képek irányítottóságát. Ugyanakkor ez nagyon pontos szinkronizációt igényelt volna a hajó belső rendszerével. Ehelyett egyszerűen kihagytuk azon méréseket, amelyeken a kiértékeléskor hiba keletkezett a hajó elmozdulása miatt.

Következtetések

Azt találtuk, hogy a neurális hálózaton alapuló felhődetekciós algoritmusok voltak a legjobbak a 13 vizsgált közül, és hogy a globális paraméterek (például a fényintenzitás átlaga és varianciája), a nem-optikai információk (például a relatív nappozíció) és a polarimetrikus információk (különösen a polarizációfok) növelhetik a felhőfelismerés pontosságát. Ugyanakkor, mint azt az NNN és PNN algoritmusok hibái közti kis különbség mutatja, a polarizáció csak kismértékben növeli a pontosságot. Fontos azonban hangsúlyozni, hogy a polarizációs információkból más mennyiségekre is következtethetünk, mint például a felhőalap magasságára vagy az aeroszol koncentrációjára, amely mennyiségek mérése fotometrikus úton nem lehetséges. A polarizáció segíthet a felhőtípusok osztályozásában is, például elkülöníteni a jégfelhőket a vízfelhőktől, vagy akár a jégfelhők mikrofizikai jellemzőinek (részecskeméret és -alak) meghatározásában.



3. *ábra.* Az 50 égbolypolarimetriás mérés egyike, amelyeket a felhődetekciós algoritmusok optimalizációjára, tanítására és tesztelésére használtunk. E mérés 10° napeleváció mellett és a konszenzusos felhőmaszk szerint 61%-os felhőzöttségénél készült. A Polarstern kutatóhajó megfigyelőornya, kéménye és egyéb felépítményei kitakarták az égbolt egy részét a horizont közelében.



5. *ábra.* Ugyanaz, mint a 3. *ábra*, de itt egy majdnem teljesen borult égboltra. A napeleváció 16° volt, a felhőzöttség pedig (a konszenzusos felhőmaszk szerint) 90%.