

Várkonyi Anikó, Kardos Péter

FELHŐALAP ÉS FELHŐBORÍTOTSÁG RÖVID TÁVÚ ELŐREJELZÉSE NEURÁLIS HÁLÓZAT SEGÍTSÉGÉVEL

A numerikus előrejelzési modellek közvetlenül nem nyújtanak felhőzetre vonatkozó információkat, így ezeket kizárólag az utófeldolgozás során lehet – közvetett módon – előállítani. Ezek beválása azonban nem megfelelő, így az előrejelzők számára komoly kihívást jelent a felhőzet megfelelő pontosságú előrejelzése. Kutatásunk azt vizsgálja, hogy a felhőzet rövid távú előrejelzése vajon javítható-e modell kimeneti statisztikára épülő neurális hálózatokkal. Vizsgálatunk során a WRF modell hároméves operatív adatsorát vettük alapul. A neurális hálózatok által nyújtott teljesítmény nagy mértékben függ attól, hogy hogyan építjük fel a hálózatot. Különböző topológiával, aktivációs függvényekkel konstruált, más-más tanulási algoritmussal betanított neurális hálózatok közül a legjobban teljesítő hálózat kiválasztása vizsgálatunk legfontosabb feladata. A legjobban teljesítő neurális hálózatok eredményeit hasonlítottuk össze régebbi felhőzetmeghatározásra alkalmazott módszerekkel.

Kulcsszavak: neurális hálózatok, rövid távú előrejelzés, felhőalap magasság, repülésmeteorológia

A FELHŐALAP MAGASSÁGÁNAK MEGHATÁROZÁSA ÉS ELŐREJELZÉSE

A légiközlekedés számára az időjárás sokkal nagyobb befolyásoló tényező, mint a többi közlekedési ágazat számára. A köd, alacsony szintű felhőzet és intenzív csapadék megváltoztathatja a repülőgép működésének szabályszerűségeit, és így akár a leszállás veszélyessé is válhat [1]. A felhőzet pontos ismerete nagyon fontos a pilóták számára, hiszen a leszállás során az alacsony szintű felhőzet korlátozza a földi tereptárgyak láthatóságát, ezen kívül további veszélyt jelent, hogy néhány felhőfajtában jegesedés vagy turbulencia léphet fel [2]. A légiközlekedés szempontjából főként az 500 m alatti, 4 oktánál nagyobb borítottságú felhőzet jelent repülésbiztonsági kockázatot. Ilyenkor a pilóta a leszállás előtt röviddel látja csak meg a futópályát, így sokkal kevesebb ideje marad korrigálni, mint egy magasabb szintű felhőzet esetén. A fel- és leszállás során tehát a felhőzet az egyik kulcsfontosságú információ, ezért repülőtereken kiemelt fontosságú a felhőalap és a felhőborítottság pontos mérése és előrejelzése. A repülőtereken a felhőzettel kapcsolatos pontos adatokat felhőalap mérők, valamint repülésmeteorológiai észlelők biztosítják.

Számos tanulmány foglalkozik a szakirodalomban a felhőzet mennyiségének, illetve a felhőzet alapjának és a tetejének a meghatározásával. Rádiószondás [3] és műholdas adatokból [4][5] is egyaránt határozták már meg a felhőzet szintjének a magasságát. A műholdas adatokból származtatott felhőalap magasság becslés kifejezetten fontos, mivel a ceilométerek, radarok és lidarok mérései elég költségesek, illetve nagy területek lefedetlenek föld felszínén [5].

A meteorológusok számára a felhőalap és a látástávolság előrejelzése egyaránt komoly nehézségekbe ütközik, hiszen ezeket a paramétereket gyakran mikro-, illetve mezoskálájú folyamatok befolyásolják, amíg a meglévő megfigyelési és előrejelzési rendszer főként szinoptikus skálájú folyamatok vizsgálatát teszi lehetővé [6]. További nehezítő tényező, hogy felhőzetre

vonatkozó információ egy olyan időjárási változó, amely nem áll elő numerikus előrejelzési modellek közvetlen outputjaként, csupán utófeldolgozás során lehet előállítani.

A felhőalap magasságának rövid távú előrejelzését többféle statisztikai módszerrel is megkísérelték már. A rövid távú előrejelzések szempontjából kulcsfontosságú az előrejelzés előtti utolsó időlépcsőből származó adatok felhasználása, tehát a légkör aktuális állapotának ismerete [7]. Ez különösen igaz a látástávolság és az alacsonysztintű felhőzet előrejelzésénél, mert ezek rövid idő alatt is igencsak gyorsan képesek megváltozni. A modell alapú statisztika (MOS) esetén is fontos az utolsó időlépcsőből származó állapotváltozó értékek ismerete, mert így látható, hogy a modell outputjai és a tényleges felhőalap és a látástávolság között milyen a kapcsolat.

Az első modell alapú statisztikák egyike *Bocchieri & Glahn* (1972) munkája [6], amelyben megkísérelték a felhőalap előrejelzését. A módszer a lényege, hogy az előrejelző modell outputjai és az előrejelzendő állapotváltozó közötti statisztikai kapcsolatot tárja fel, és a regresszió előtt megszüri a használható változókat statisztikai összefüggés segítségével. Kategorikus és számszerű előrejelzéssel egyaránt foglalkoztak. A tanulmányban regressziós becslést adtak a felhőalap magasságára és a látástávolságra.

Egy másik módszer az ún. analógiás előrejelző rendszer, amely a jelen helyzet értékeire múltbeli hasonlóságokat keres egy klimatológiai adatbázisból, és az alapján próbál következtetni a látástávolság és a felhőalap jövőbeli alakulására [8].

Több kutatás során is megkísérelték már a neurális hálózattal történő felhőalap magasság előrejelzést. Az Egyesült Államok parti részein például a nyári hónapokban kialakuló stratus felhőzet magasságának és a horizontális látástávolságban történő romlásának mértékének előrejelzésére használták ezt a nemlineáris statisztikai modellt [9]. Az előző témához hasonló kutatást végeztek a San Francisco-i Nemzetközi Repülőtéren is [10]. Az éjszaka képződő stratiform felhőzet feloszlásának pontos idejét határozták meg neurális hálózat segítségével.

NEURÁLIS HÁLÓZATOK

A neurális hálózat egy olyan számítási mechanizmus, amely a biológiai idegrendszer felépítésének és működésének analógiájára lett kialakítva [11]. A biológiai idegrendszer fő tulajdonsága, hogy kicsiny alapegységekből van felépítve, és az egységek között sok a kapcsolat. Ezen kívül még fontos a tanulás képessége is. A mesterséges neurális hálózatok is rendelkeznek ezekkel a főbb tulajdonságokkal.

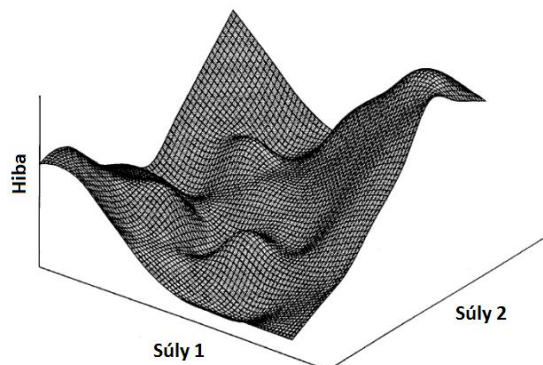
A neurális hálózatok lényege, hogy nem a jelenséget próbálják meg modellezni, hanem kizárólag a bemenő és a kimenő adatokat tekintik. Ez nagyon előnyös is lehet, hiszen adott esetben a jelenség megértésére nincs szükség, a működéshez elegendő csupán megfelelő mennyiségű adat.

A neurális hálózatok alkalmazása igen széles körben elterjedt. Felhasználási területe kiterjed az olyan közvetlen meteorológiai paraméterek, mint például a hőmérséklet [12], napi csapadék [13] vagy a felhőzet és látástávolság [9] meghatározásától, a légszennyezettségen [14] át, a megújuló energiákon alapuló energiatermelés [15] előrejelzéséig.

A neurális hálózat elsődleges jelentőséggel bíró tulajdonsága, hogy környezetéből képes tanulni, és a tanulási folyamaton keresztül javítható a teljesítménye. A tanulás folyamata során


az egyes neuronokhoz tartozó súlyok kalibrációja történik úgy, hogy a hálózat a legjobb teljesítményre legyen képes. Ideális esetben a neurális hálózatnak a tanulási folyamat minden egyes ismétlése után jobbnak kell lennie [16].

A hálózat tanítása során első lépésként megadunk kezdeti súlyokat, majd az outputot végigáramoltatjuk a hálózaton a súlyok megváltoztatása nélkül. Az így kapott outputot összevetjük a tényleges kimeneti értékkel, és hibát végigáramoltatjuk a hálózaton, majd a súlyokat megváltoztatjuk úgy, hogy ennek a hibának az értéke a legkisebb legyen, tehát egy többdimenziós hibafüggvény minimumát keressük (1. ábra). Ezt a lépéssorozatot hiba visszaáramoltatási módszernek (back-propagation algorithm) nevezik.



1. ábra A neurális hálózat két súlyához tartozó hibafelület [17]

A tanulási folyamat során figyelni kell a túltanulás elkerülésére (2. ábra). A túltanulás azt jelenti, hogy a neurális hálózat túlzottan illeszkedik a tanító pontokhoz, ami rontja a hálózat általánosító-képességét. Ez főként akkor következhet be, ha a hálózat szabadságfoka a tanító pontokhoz képest túl nagy [18].



2. ábra A tanulás során a négyzetes hibákat ábrázoló görbék [18]

VERIFIKÁCIÓS INDEXEK

Az eredmények értékeléséhez a különböző kategóriákra verifikációs indexeket használtunk, amelyeket az ún. kontingencia táblázat segítségével lehet kiszámítani (3. ábra). Ebben a táblázatban négyféle variáció létezik: a referencia kategória (METAR, felhőalap mérős adatsor) egybeesik neurális hálózat által számított kategóriával (a: helyes találat), a referencia kategória más kategóriába esik, míg a neurális hálózattal számított érték megegyezik a vizsgált kategóriával (b: hibás riasztás, c: téves elvetés), és az utolsó variáció, az egyik szerint sem esett a vizsgált kategóriába (d: helyes elvetés).

		METAR/ felhőalap mérő adatai		
	Felhőzet kategória egyezik	igen	nem	
Neurális hálózat	igen	a	b	
	nem	c	d	
				$n=a+b+c+d$

3. ábra A vizsgálatban alkalmazott kontingencia táblázat

A tanulmány során az alábbi verifikációs indexeket használtuk fel [19][20]:

1. a POD (Probability Of Detection) index megmutatja, hogy a bekövetkezett események közül milyen arányban volt helyes az előrejelzés. Értéke 0 és 1 közötti lehet, az ideális értéke 1;

$$POD=a/(a+c) \quad (1)$$

2. a FAR (False Alarm Ratio) index arról az arányról tájékoztat, hogy az előrejelzett események milyen aránya volt téves (túlbiztosított). Értéke 0 és 1 között változhat, az ideális értéke a 0. A POD és a FAR indexet együtt kell vizsgálni;

$$FAR= b/(a+b) \quad (2)$$

3. az ETS (Equitable Threat Score) a TS index klimatológiai érzékenységét hivatott javítani egy random gyakoriság (*ar*) megadásával. Ezt a random értéket úgy adják meg, hogy feltételezik, az előrejelzések teljesen függetlenek a megfigyeléstől és az előrejelzés csak véletlenül fogja visszaadni a megfigyelést. Az ETS index értéke $-1/3$ -tól 1-ig változik, ideális értéke 1;

$$ETS=(a-ar)/(a+b+c-ar) \quad (3)$$

$$ar=(a+b)(a+c)/n \quad (4)$$

4. a HSS (Heidke Skill Score) index az egyik leggyakrabban használt mutató ahhoz, hogy összefoglaljuk egyben a 2×2 -es kontingencia táblázatot. A HSS megadja a helyes előrejelzések arányát, miután korrigálták azt a random helyes találatokkal. Nagyon érzékeny a túlbiztosított (b) és az alulbiztosított (c) prognózisok arányára. Értéke mínusz végtelentől 1-ig változik, a megfelelő értéke az 1.

$$HSS=2(ad-bc)/\{(a+c)(c+d)+(a+b)(b+d)\} \quad (5)$$

FELHASZNÁLT ADATOK ÉS MÓDSZEREK

Jelen kutatás során modell alapú statisztikai eljárást alkalmaztunk. A GFS globális modell adatai alapján inicializált WRF numerikus modell 2013-as, 2014-es és 2015-ös adatsora szolgált adatforrásként. Ezek utófeldolgozás-mentes, natív változói a modellnek. Napi két inicializációval indult modell adatait használtuk, minden időpontra 2 modellfutási adat állt rendelkezésre. Egy 00 és egy 12 UTS-s futás, órás időlépcsőben, minden futás esetén 96 óráig álltak rendelkezésre adatok. A WRF modell felfutási idejét figyelembe véve egy adott futás 4. és 28. időlépcső közti időszakát használtuk fel. A felhasznált három éves adatsor alatt a WRF konfigurációs beállításai nem változtak. Ez azért fontos információ számunkra, mert a neurális hálózat ilyen modellbeállítások mellett tanult, így változtatások esetén a neurális hálózat újratanítására lenne szükség.

A modell adatok közül felszíni és különböző modellszintbeli változókat egyaránt felhasználtunk a neurális hálózat tanuló adatsorának elkészítéséhez, majd a hálózat teszteléséhez. A felszíni változók közül 10 m-es szélesség *u* és *v* komponense, 2 m-es hőmérséklet, keverési

arány és felszíni légnyomás álltak rendelkezésre. Vertikálisan a 250 m-es és az 500 m-es szint adatait használtuk fel, hiszen ezek esnek az általunk vizsgált tartományba. Mindkét szinten a keverési arányt, szélességet u és v komponenset és hőmérsékletet használtuk fel.

A valós felhőzetről az információ két adatforrásból származott. Első esetben a Liszt Ferenc Nemzetközi Repülőtéren a 13R pályaküszöbnél üzemelő felhőalaplómérő nyers adatait használtuk fel. Ebben az esetben a felhőborítottságról nem, csupán a felhőzet alapjának a magasságáról kapunk információt.

Második esetben a Liszt Ferenc Nemzetközi Repülőtéren dolgozó észlelők közreműködésével szolgáltatott METAR táviratban található felhőzetinformáció volt az adatforrás. Ez esetben a kategorizálás során a felhőzet borítottságát is figyelembe tudtuk venni, hiszem a táviratban a felhőalap magasság mellett a felhőzet mennyiségét is megadják. A METAR táviratban több szintre is találunk a felhőzetről információt, ilyen esetben mi a repülés szempontjából fontosabb információt vettük figyelembe, tehát az 5 okta feletti és az 1500 láb alatti felhőzetet, ha előfordult ilyen.

A felhőzet adatokat három kategóriába soroltuk az alábbi kritériumok szerint:

- 1-es kategória (1500 láb feletti felhőalap, METAR referencia adatok esetén 4 okta alatt);
- 2-es kategória (1500 és 900 láb közötti felhőalap, METAR referencia adatok esetén 5 okta felett);
- 3-as kategória (800 láb alatti felhőalap, METAR referencia adatok esetén 5 okta felett).

Első lépésként a tanulóadatsort építettük fel. Az input adatok a nap és az óra szinuszfüggvénnyel átalakított értékei, illetve a WRF modell outputjai (vertikálisan két szintre keverési arány, szél és hőmérséklet, illetve felszíni adatok) voltak. A tanulóadatsor kimenő adatai pedig a METAR, illetve a felhőalap mérő által mért értékek három kategóriába besorolva. A METAR és a felhőalap mérős adatsorra is külön-külön adatsor készült, hiszen a hiányzó adatok eltérőek voltak mindkét esetben. Az outputokat binomiális klasszifikációval is átalakítottuk a METAR-os adatsor esetén.

Ezután a hálózat megkonstruálása és betanítása következett. A tanulási algoritmusok és az aktivációs függvények különböző kombinálásával kellett a legjobban teljesítő, konvergens hibaértéket adó konstrukciókat kiválasztani. A két bevált tanulási algoritmus az RPROP és a QUICKPROP voltak, míg az aktivációs függvények közül a szimmetrikus Gauss és a szimmetrikus szigmoid függvények bizonyultak a legjobbnak. Az ezek segítségével konstruált hálózatok a következők voltak:

- 1_Gauss_szimm_QUICKPROP/ 1_szigmoid_szimm_RPROP: Olyan hálózatok, amelyeknek tanulóadatsorában a felhőalap mérő adatai szerepeltek;
- 2_Gauss_szimm_QUICKPROP/ 2_szigmoid_szimm_RPROP: Olyan hálózatok, amelyeknek tanulóadatsorában a METAR-os adatok szerepeltek;
- 3_Gauss_szimm_RPROP/ 3_szigmoid_szimm_QUICKPROP: Olyan hálózatok, amelyeknek tanulóadatsorában a METAR-os adatok szerepeltek binomiális klasszifikációval átalakítva;
- 4_szigmoid_szimm_RPROP: Olyan hálózat, amelynek tanulóadatsorában a 2-es és a 3-as kategória összevonásra került, tehát két kategóriát tanult hálózat.

A hálózat nevében az első számjegy a hálózat számát jelöli, amely az outputok alapján lett elkülönítve, a második és a harmadik tag jelöli az alkalmazott aktivációs függvényt, a negyedik tag pedig a tanulás során használt algoritmusról nyújt információt.

A hálózatok betanulását követően a vizsgálat a teszteléssel folytatódott. Jelen kutatás során két különböző időszakra teszteltük mind a 7 különböző neurális hálózatot. Két olyan időszak kiválasztása volt a cél, amelyek során a felhőzet általánosságban eltérően szokott alakulni. Az első időszak egy január elsejétől február végéig, a második időszak egy augusztus elsejétől november elejéig tartó tesztidőszak volt.


A kapott értékeket a 3. fejezetben említett verifikációs indexek segítségével értékeltük ki. Az így kapott eredményeket a szakirodalomban fellelhető felhőzetbecslési módszerek által nyújtott adatok, illetve a részecskemódszerrel kiszámított felhőalap magasságokra kapott verifikációs indexek értékeihez hasonlítottuk.

Elsőként a harmatpont és a hőmérséklet különbségét alapul vevő képletet számítottuk ki, amely a hőmérséklet függvényében írja le a felhőképződéshez szükséges harmatpont deficitet [21]. Ennek az összefüggésnek egy közelítését is használtuk, amely a harmatpont deficit helyett a relatív nedvességet használja fel a felhőzet meghatározásához. Egy másik összefüggést is alkalmaztunk a felhőalap magasságának meghatározására, amely nem a hőmérséklet alapján ír le kritériumot a felhőzet megjelenésére, hanem a levegő nyomása alapján.

Ezen kívül a neurális hálózat eredményeit még a részecske módszer segítségével számított felhőalapokkal is összevetettük. A módszer lényege, hogy azt feltételezzük, hogy a felszínről induló részecske száraz adiabatikus hőmérsékleti gradiens mentén mozog mindaddig, amíg nincs kondenzáció, tehát telítetlen a levegő [22]. Mivel a levegő a felfelé emelkedés közben hűl, ezért a relatív nedvessége növekszik, majd amikor eléri a telítettség állapotát, akkor megindul a gőz cseppfolyós állapotba való átmenete. Ezt a szintet, ahol ez az átmenet bekövetkezik, emelési kondenzációs szintnek nevezzük, és itt jelenik meg a felhőzet.

EREDMÉNYEK

Az első időszak (téli) vizsgálatához a felhőalap mérő adatait, és az 1_sigmoid_szimm_RPROP hálózat (4. ábra) kalkulált értékeit használtuk fel. Az ábrán szemléletesen látható a hálózat jó teljesítménye különösen, ha figyelembe vesszük, hogy a feladata csupán a kategória előrejelzése volt, azaz annak meghatározása, hogy a 0–1, 1–2, vagy a 2–3 tartományba esik a felhőzet magassága.




4. ábra Az 1_sigmoid_szimm_RPROP hálózat által számított értékek összehasonlítása a felhőalap mérő által mért értékekkel az 1. időszakra

A következő diagramon a második időszakra (nyári végi-őszi) figyelhetjük meg a 2_sigmoid_szimm_RPROP hálózat (5. ábra) eredményeit a METAR-ban található

felhőzetinformáció kategorizált értékeivel összevetve. Ebben az időszakban sokkal kevesebb esetben volt 3-as kategóriába eső felhőalap magasság az első időszakhoz képest.

A diagramokon látható, hogy a neurális hálózat által szolgáltatott nyers eredmények jól követik a felhőzet időbeli alakulásának tendenciáját. Amikor a 3-as kategóriába esett a felhőalap mérő által mért érték vagy a METAR-os felhőzetinformáció, akkor a neurális hálózat által kalkulált értékek is magasabbak voltak.



5. ábra A 2_sigmoid_szimm_RPROP hálózat által számított értékek összehasonlítása a METAR-ban található felhőalap értékekkel a 2. időszakra

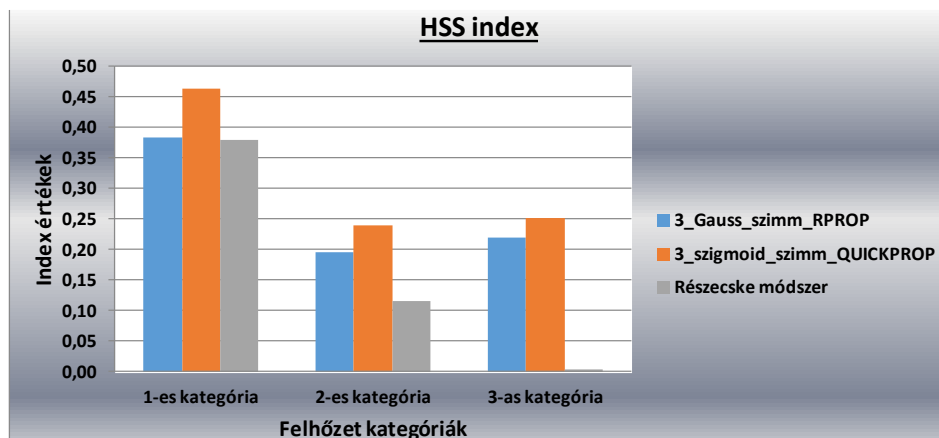
A feljebb ismertetett két hálózat verifikációs indexeit megvizsgálva az látszik, hogy a 2-es kategória elkülönítése esetén teljesített mind a két hálózat a leggyengébben. A következőben két olyan hálózat bemutatása következik, amelyek viszonylag egyenletesen teljesítettek mind a három kategória esetén. Ilyen hálózatok a 3_Gauss_szimm_RPROP és a 3_sigmoid_szimm_QUICKPROP. Ezek olyan neurális hálózatok, amelyek outputjai binomiális klasszifikáció segítségével át lettek alakítva, így a modellnek három outputja volt. A kategorizálás ebben az esetben úgy történt, hogy a maximális érték kiválasztása a három output közül döntött a felhőzet kategóriáról. A második időszakra vonatkozó verifikációs indexeket szemlélve (6. ábra) látható, hogy 3_Gauss_szigmoid_QUICKPROP hálózat eredményei jobbnak bizonyultak erre az időszakra. Itt az 1-es kategória esetén 0,45 feletti, még a 2-es és a 3-as kategória esetén 0,24–0,25 körüli HSS index értékek jöttek ki.

2. időszakra számított indexek értékei			
3_Gauss_szimm_RPROP a maximum értékeket véve			
	1-es kategória	2-es kategória	3-as kategória
HSS	0,38	0,20	0,22
POD	0,94	0,27	0,31
FAR	0,45	0,56	0,37
ETS	0,24	0,11	0,12
3_sigmoid_szimm_QUICKPROP a maximum értékeket véve			
	1-es kategória	2-es kategória	3-as kategória
HSS	0,46	0,24	0,25
POD	0,89	0,38	0,36
FAR	0,39	0,58	0,37
ETS	0,30	0,14	0,14

6. ábra A 3_Gauss_szimm_RPROP és a 3_sigmoid_szimm_QUICKPROP hálózatok eredményeire számított verifikációs indexek értékei az 2. időszakra

Ezen hálózatok esetén már egyértelműen látszik a verifikációs indexek vizsgálatánál, hogy a neurális hálózat mind a három kategória esetén sokkal pontosabb előrejelzést szolgáltatott az előző fejezetben ismertetett négy összehasonlításra használt módszer bármelyikénél. Ezek közül a legjobban a részecske módszer teljesített (7. ábra), amelynek a második időszak során az 1-es kategóriára kalkulált HSS index értéke megegyezik a 3_Gauss_szimm_RPROP hálózat eredményeire számított

HSS indexével, azonban a másik két kategória esetén alacsonyabbak a HSS index értékei. A repülés szempontjából legfontosabb legalacsonyabb szintű felhőzet esetén (3-as kategória) kifejezetten alacsony, 0 körüli a részecske módszer eredményeire számított HSS index értéke.



7. ábra A 3_Gauss_szimm_RPROP, 3_szigmoid_szimm_QUICKPROP és a részecske módszer eredményeire számított HSS index értékei a 2. időszakra

Az eddigi esetekben a neurális hálózatok számára a legnagyobb problémát a 2-es és a 3-as kategória elkülönítése jelentette. A továbbiakban ezt a két kategóriát összevontan kezeljük, mert így a légiközlekedési szempontból kritikus 1500 láb alatti felhőzetről tudunk információt szolgáltatni. A következőkben áttekintjük, hogy ebben a feladatban melyik hálózatok teljesítettek a legjobban.

Az első időszak vizsgálata során a 3_Gauss_szimm_RPROP esetén kifejezetten magas HSS index értékek láthatóak (8. ábra), mind a két kategória esetén a 0,6 körüli. Ennél a hálózatnál mind a négy vizsgált index értéke kiemelkedően jó. A repülés szempontjából meghatározóbb 2-es kategória esetén 0,95 körüli a POD index, 0,1 alatti a FAR index, és 0,42-es az ETS index értéke a téli időszakra nézve.

A 3_szigmoid_szimm_QUICKPROP hálózat csak kicsivel teljesített rosszabbul, mint az előbb említett 3_Gauss_szimm_RPROP, a HSS és a POD index esetén egy tizedes eltérés, a FAR és a ETS index esetén csupán pár százados a különbség. A HSS index értékei mind a két kategóriára 0,5 körüliek voltak. Itt is a 2-es kategória esetén optimálisabbak a vizsgált indexek értékei.

Ugyanezen hálózatokat a nyár végi-őszi időszakra is megvizsgáltuk. Ebben az időszakban a 3_szigmoid_szimm_QUICKPROP hálózat (9. ábra) verifikációs indexeinek értékei jobbnak bizonyultak, mint a téli időszakban kiemelkedően jól teljesítő 3_Gauss_szimm_RPROP hálózat index értékei. A 3_szigmoid_szimm_QUICKPROP hálózat esetén a téli és a nyári időszakban is hasonló HSS index értéket kaptunk (a téli időszakra 0,49, nyár végi-őszi időszakra 0,46), csupán 3 százados volt mind a két kategória esetén az eltérés. Tehát ez a hálózat egyenletesebben teljesített a két vizsgált időszakra, mint a 3_Gauss_szimm_RPROP hálózat, ahol több mint 2 tizedes az eltérés a két időszakra vizsgált HSS index értékek esetén (téli időszakra 0,59, nyár végi-őszi időszakra 0,38). A másik négy összehasonlító módszerrel kalkulált felhőalapra számolt indexekkel összevetve megállapítható, a neurális hálózatok jobban teljesítettek ebben az esetben is. A négy módszer közül most is a részecske módszer teljesített a legjobban. A HSS és ETS indexekre kapott értékei (10. ábra) az első időszak során körülbelül 0,1-el maradtak el a 3_Gauss_szimm_RPROP hálózatétól, a 3_szigmoid_szimm_QUICKPROP hálózatával pedig közel megegyeztek. A második időszak

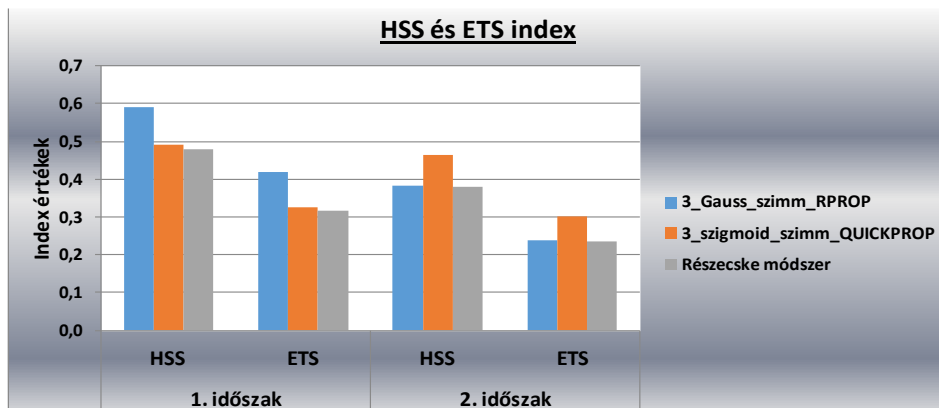
során a részecske módszer szintén 0,1-el maradt el a 3_sigmoid_szimm_QUICKPROP hálózat eredményeire számított indexek értékeinél, és a 3_Gauss_szimm_RPROP hálózatával majdnem megegyező index értékei voltak. Összességében mind a két időszak során az egyik hálózat felülmúlta az összehasonlító módszerek közül legjobban teljesítő részecske módszert, a másik hálózatra számított indexek értékei pedig majdnem megegyezők voltak vele.

1. időszakra számított indexek értékei				
	3_Gauss_szimm_RPROP a maximum értékeket véve		3_sigmoid_szimm_QUICKPROP a maximum értékeket véve	
	1-es kategória	2-es kategória	1-es kategória	2-es kategória
HSS	0,59	0,59	0,49	0,49
POD	0,61	0,94	0,56	0,91
FAR	0,26	0,10	0,37	0,11
ETS	0,42	0,42	0,32	0,32

8. ábra A 3_Gauss_szimm_RPROP és a 3_sigmoid_szimm_QUICKPROP hálózatok eredményeire számított verifikációs indexek értékei az 1. időszakra

2. időszakra számított indexek értékei				
	3_Gauss_szimm_RPROP a maximum értékeket véve		3_sigmoid_szimm_QUICKPROP a maximum értékeket véve	
	1-es kategória	2-es kategória	1-es kategória	2-es kategória
HSS	0,38	0,38	0,46	0,46
POD	0,94	0,49	0,89	0,61
FAR	0,45	0,08	0,39	0,11
ETS	0,24	0,24	0,30	0,30

9. ábra A 3_Gauss_szimm_RPROP és a 3_sigmoid_szimm_QUICKPROP hálózatok eredményeire számított verifikációs indexek értékei az 2. időszakra




10. ábra A 3_Gauss_szimm_RPROP, 3_sigmoid_szimm_QUICKPROP és a részecske módszer eredményeire számított HSS és ETS index értékei az 1. és 2. időszakra

A 4_sigmoid_szimm_RPROP hálózat tanulóadatsorában csak két kategória szerepelt. A verifikációs indexek kalkulálása során nem konkrét küszöbértékekre történt a számítás, hanem azt vizsgáltuk, hogy a küszöbérték megválasztásától hogyan függenek a verifikációs indexek értékei.

A küszöbértékek variálása során az ETS és a HSS indexeket vizsgáltuk (11. ábra). Látható, hogy a két index értékei hasonló tendenciát mutatnak a küszöbértékek függvényében. A maximum értéküket is ugyanannál a küszöbértéknél veszik fel. Ez az első időszakban mindkét index esetén körülbelül 1,2-nél (pontosan 1,199-nél) található. Itt a HSS index értéke 0,33 körüli, az ETS index értéke 0,2 körüli. A második időszak indexeinek vizsgálatakor szembetűnő, hogy az indexek értékeinek a küszöbértékektől való függésének tendenciája teljesen eltérően alakult az első időszakétól. Ebben az esetben az 1-es küszöbérték környékén egy nagy ugrás következik be mind a két index értékében. A HSS index 0,98-as küszöbértéknél 0,08-as értéket vett fel,

majd 3 századdal növelve a küszöbértéket, 1,01-nél már 0,4 feletti értéke volt. Ez jól érzékelteti, hogy az eredmények mennyire érzékenyek a küszöbértékek megválasztására. A második időszak során a HSS és az ETS index is a maximumát 1,116-nál vette fel. Itt a HSS index értéke 0,65 és az ETS index értéke pedig 0,48 volt. Tehát a téli időszakhoz képest a HSS és az ETS index értéke is körülbelül 0,3-el volt magasabb, ezért általánosságban elmondható, hogy ez a hálózat a nyári időszak során jobban teljesített.



11. ábra A 4_sigmoid_szimm_RPROP hálózat eredményeire számított verifikációs indexek értékei az 1. és 2. időszakra a küszöbérték megválasztásától függően

ÖSSZEFOGLALÁS

Az eredményekből egyértelműen látszik, hogy a neurális hálózat által szolgáltatott értékek mindig jobban közelítették a valóságot, mint a szakirodalomban fellelhető módszerek segítségével számított értékek. Miután modell alapú statisztikára építettük fel a hálózatot, ezért fontos szem előtt tartani, hogy a modell hibája is befolyásolhatta a számítások eredményeit. A neurális hálózattal történő előrejelzés egyik nagy előnye, hogy a modell szisztematikus hibáit a hálózat képes megtanulni, és így képes a nyers előrejelzésen javítani. A legtöbb általunk vizsgált hálózat egészen megbízható információt adott a felhőzetre vonatkozóan, továbbá a diagramokon látható volt, hogy a neurális hálózat képes lekövetni a felhőzet időbeli változásait is. A 2-es és 3-as kategóriájú felhőzet esetén a hálózat által számított értékek is átlagosan magasabbak voltak, mint az 1-es kategóriájú felhőzet esetén.

A különböző topológiával rendelkező, eltérő tanulási algoritmust és aktivációs függvényt alkalmazott neurális hálózatok vizsgálatok során kiderült, hogy a két különböző vizsgált időszakban más-más hálózat teljesített jobban, illetve rosszabbul. A három különböző kategóriára történt számítás esetén a 3_sigmoid_szimm_QUICKPROP hálózat bizonyult a legjobbnak, de ez is főként csak a nyár végi-ősz időszakban adott elfogadhatóan jó eredményeket mind a három kategóriára egyaránt. Minden hálózat esetén a 2-es kategóriához tartozó verifikációs index értékek voltak a legrosszabbak, hiszen ezt nehezen tudta a hálózat elkülöníteni a 3-as kategóriától, és gyakran nagyon hasonló értékeket számított erre a két kategóriára.

A 2-es és a 3-as kategória összevonása szinte az összes hálózat esetén javulást hozott a verifikációs indexek értékeiben. A legjobban teljesítő hálózatnak ebben az esetben a 3_Gauss_szimm_RPROP hálózat bizonyult, amelynek a téli időszak vizsgálata során az eredményeire számított HSS index 0,6 körüli értéket vett fel mind a két kategória esetén. Említésre méltó még a 3_sigmoid_szimm_QUICKPROP hálózat is, amely mind a két időszak esetén viszonylag jól és egyenletesen teljesített.

4_szigmoid_szimm_RPROP hálózat értékeire számított verifikációs indexek értékeinek a küszöbértékektől való függésének vizsgálatakor szembeűnő volt, hogy a téli és a nyári időszak során eltérő tendenciát mutattak a verifikációs indexek értékei. Máshol vették fel a maximumot, illetve amíg a téli időszak során egy viszonylag egyenletesen felfutó majd lecsengő görbét kapunk, addig a nyári időszakban ugyanez a görbe egy hirtelen felfutást, majd egyenletes leívelést mutatott. Ebből látszik, hogy érdemes nem egy fix küszöbérték megválasztása az egész év során, hanem mindig egy évszaktól függő küszöbérték kiválasztása.

A további terveink közt szerepel még a cikkben szereplő hálózatkonstrukciók előrecsatolt változatainak a vizsgálata és eredményeik értékelése.

FELHASZNÁLT IRODALOM

- [1] Gaumet, J.L., Heinrich, J.C., Cluzeau, M., Pierrard, P., Prieur, J., 1997: Cloud-Base Height Measurements with a Single-Pulse Erbium-Glass Laser Ceilometer, *Journal of Atmospheric and Oceanic Technology*, Vol. 15, 37-45.
- [2] Sándor, V., és Wantuch, F., 2005: Repülésmeteorológia, Országos Meteorológiai Szolgálat, Budapest, 272 p.
- [3] Chernykh, I.V., Eskridge, R.E., 1996: Notes and correspondence, Determination of Cloud Amount and Level from Radiosonde Soundings, *Journal of Applied Meteorology*, Vol. 35, 1362-1369.
- [4] Hanel, R.A., 1961: Determination of Cloud Altitude from a Satellite, *Journal of Geophysical Research*, Vol. 66, No. 4, 1300.
- [5] Kassianov, E., Long, C.N., Christy, J., 2005: Cloud-Base Height Estimation from Paired Ground-Based Hemispherical Observations, *Journal of Applied Meteorology*, Vol. 44, 1221-1233.
- [6] Bocchieri, J.R., Glahn, H.R., 1972: Use of Model Output Statistics for Predicting Ceiling Height, *Monthly Weather Review*, Vol. 100, No. 12, 869-881.
- [7] Vislocky, R.L., Fritsch, J.M., 1997: An Automated, Observations-Based System for Short-Term Prediction of Ceiling and Visibility, *Weather and Forecasting*, Vol. 12, 31-43.
- [8] Hansen, B., 2007: A Fuzzy Logic-Based Analog Forecasting System for Ceiling and Visibility, *Weather and Forecasting*, Vol. 22, 1319-1330.
- [9] Marzban, C., Leyton, S., Colman, B., 2006: Ceiling and Visibility Forecasts via Neural Networks, *Weather and Forecasting*, Vol. 22, 466-479.
- [10] Dean, A.R., Fiedler, B.H., 2001: Forecasting Warm-Season Burnoff of Low Clouds at the San Francisco International Airport Using Linear Regression and a Neural Network, *Journal of Applied Meteorology*, Vol. 41, 629-639.
- [11] Fazekas, I., 2013: Neurális hálózatok, Debreceni Egyetem, Informatikai Kar, Debrecen, 204 p.
- [12] Hayati, M., Mohebi, Z., 2007: Application of Artificial Neural Networks for Temperature Forecasting, *World Academy of Science, Engineering and Technology, International Journal of Electrical and Computer Engineering*, Vol:1, No:4, 662-666.
- [13] Hall, T., Brooks, H.E., Doswell III, C.A., 1999: Precipitation Forecasting Using a Neural Network, *Weather and Forecasting*, Vol. 14., 338-345.
- [14] Fernando, H.J.S., Mammarella, M.C., Grandoni, G., Fedele, R., Di Marco, R., Dimitrova, R., Hyde, P., 2012: Forecasting PM10 in metropolitan areas: Efficacy of neural networks, *Environmental Pollution*, 163 (2012), 62-67.
- [15] Filik, Ü.B., Filik, T., 2016: Wind Speed Prediction Using Artificial Neural Networks Based on Multiple Local Measurements in Eskisehir, 3rd International Conference on Energy and Environment Research, ICEER 2016, 7-11 September 2016, Barcelona, Spain, *Energy Procedia*, 107 (2017), 264-269.
- [16] Haykin, S., 1995: *Neural networks, A comprehensive foundation*, 2nd Edition, Pearson Education, Delhi, 823 p.
- [17] Gardner, M., és Dorling, S., 1998: *Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences*, *Atmospheric Environment*, 32, 2627-2636.
- [18] Altrichter, M., Horváth, G., Pataki, B., Strausz, Gy., Takács, G., Valyon, J., 2006: *Neurális hálózatok*, Hungarian Edition Panem Könyvkiadó Kft., Budapest, 433 p.
- [19] Ebert, E.E., McBride, J.L., 1997: *Methods for verifying quantitative precipitation forecast: application to the BMRC LAPS model 24-hour precipitation forecast*. BMRC Techniques development report No. 2., Melbourne, Australia, 87 p.
- [20] Nurmi, P., 2003: *Recommendations on the verification of local weather forecasts*. ECMWF Technical Memorandum, 430, 18 p.

- [21] Costa-Surós, M., Calbó, J., González, J.A., Long, C.N., 2014: Comparing the cloud vertical structure derived from several methods based on radiosonde profiles and ground-based remote sensing measurement, *Atmospheric Measurement Techniques*, 7, 2757-2773.
- [22] Götz, G., Rákóczi, F., 1988: *A dinamikus meteorológiai alapjai*. Tankönyvkiadó, Budapest, 484 p.

SHORT TERM FORECASTING OF CLOUD CEILING USING ARTIFICIAL NEURAL NETWORKS

Numerical weather prediction systems does not provide cloud information directly, these information can be assessed during post processing only in an indirect manner. However accuracy of these forecasts is not sufficient for operational usage, therefore appropriate prediction of cloud ceiling is a real challenge for the forecasters. Our research focuses on whether short term forecasts of cloud ceiling could be improved using model outputs statistic based artificial neural network method. Our research based on three years of WRF numerical model output which was initiated by GFS forecast as initial boundary and lateral condition. The performance of artificial neural network highly depends on network configuration, therefore choosing the appropriate topology, transfer function and the right learning algorithm is a crucial element. The results of the best artificial neural network configurations have been compared to some old cloud assessments methods.

Keywords: cloud ceiling, short term forecasting, neural networks, aviation meteorology

Várkonyi Anikó (MSc) Hallgató Eötvös Loránd Tudományegyetem Természettudományi Kar Meteorológiai Tanszék kisaaa93@gmail.com orcid.org/0000-0003-4319-2375	Várkonyi Anikó (MSc) Student Eötvös Loránd University Faculty of Science Department of Meteorology kisaaa93@gmail.com orcid.org/0000-0003-4319-2375
Kardos Péter Csoportvezető HungaroControl Magyar Légiforgalmi Szolgálat Zrt. Repülésmeteorológiai Részleg Peter.Kardos@hungarocontrol.hu orcid.org/0000-0001-8857-4102	Kardos Péter Head of Unit HungaroControl Hungarian Air Navigation Services Ltd. Aerodrome Meteorological Unit Peter.Kardos@hungarocontrol.hu orcid.org/0000-0001-8857-4102

A GINOP 2.3.2-15-2016-00007 „A légi közlekedés-biztonsághoz kapcsolódó interdiszciplináris tudományos potenciál növelése és integrálása a nemzetközi kutatás-fejlesztési hálózatba a Nemzeti Közszolgálati Egyetemen – VOLARE” című projekt az Európai Unió támogatásával, az Európai Regionális Fejlesztési Alap társfinanszírozásával valósul meg.

A kutatás a fenti projekt „UAS_ENVIRON” nevű kiemelt kutatási területén valósult meg.

