

Felhőalap és felhőborítottság rövid távú előrejelzése neurális hálózat segítségével

DIPLOMAMUNKA



Készítette:

Várkonyi Anikó

II. éves meteorológus MSc hallgató

Témavezetők:

Kardos Péter

HungaroControl Magyar Légiforgalmi Szolgálat Zrt., RMET csoportvezető

dr. Breuer Hajnalka

ELTE TTK, Meteorológiai Tanszék

Eötvös Loránd Tudományegyetem

Földrajz- és Földtudományi Intézet

Meteorológiai Tanszék

Budapest, 2018

Tartalomjegyzék

1. Bevezetés	3
2. Irodalmi áttekintés	5
2.1. Neurális hálózatok alkalmazása	5
2.2. Felhőalap becslése	13
3. Neurális hálózatok	16
4. Verifikációs indexek	23
5. Adatok	25
6. Neurális hálózat alkalmazása	27
6.1. A tanulóadatsor elkészítése	27
6.2. A hálózat megkonstruálása és betanítása	28
6.3. A hálózat tesztelése és az eredmények értékelése	29
7. Eredmények	31
7.1. A neurális hálózattal becsült felhőalap magasságok kategorikus verifikációja	31
7.2. Előrecsatolt hálózatok	40
7.3. Érzékenységvizsgálat a küszöbértékek variálásával	42
8. Esettanulmány	45
8.1. Téli időszak	45
8.2. Nyár végi-őszi időszak	48
8. Összefoglalás	51
9. Köszönetnyilvánítás	53
10. Irodalomjegyzék	54

1. Bevezetés

A numerikus előrejelzési modellek közvetlenül nem nyújtanak felhőzetre vonatkozó információkat. Ezeket kizárólag az utófeldolgozás során – közvetett módon – lehet előállítani. Beválásuk azonban nem megfelelően pontos, így az előrejelzők számára komoly kihívást jelent a felhőalap magasságának előrejelzése.

A légiközlekedés szempontjából főként az 500 m alatti, 4 oktánál nagyobb felhőborítottság 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 a felhőalap mérők, valamint a repülésmeteorológiai észlelők biztosítják.

Jelen diplomamunka célja annak vizsgálata, hogy neurális hálózat segítségével modell alapú statisztikát (MOS – modell output statistic) alkalmazva a felhőalap és a felhőborítottság rövidtávú alakulásáról lehetséges-e a meglévő módszereknél pontosabb információkat adni.

A neurális hálózatok által nyújtott teljesítmény nagymértékben 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 egyik fő feladata.

A neurális hálózat tanuladatsorának bemenő adataiként a 2013-as, 2014-es és 2015-ös évből származó felszíni WRF modell adatok (2 m-es léghőmérséklet, 2 m-es vízgőz keverési arány, 10 m-es szélesség u és v komponense, felszíni légnyomás), valamint a vertikálisan több szintre rendelkezésre álló potenciális hőmérséklet, vízgőz keverési arány, és szélkomponensek szolgáltak. A neurális hálózat eredménye a vizsgálat függvényében több különböző adat lehet. Vizsgálhatók a felhőalaplómérők által szolgáltatott nyers adatok, vagy a METAR táviratokban található, az észlelők közreműködésével készített felhőzetinformáció kategória-besorolásai is. A neurális hálózat viselkedését két időszakra is figyeltük, az egyik időszak egy nyár végi-őszi időszak, a másik egy téli időszak volt. A felhőzet alapjának magasságától és borítottságától függően 3 kategóriát hoztunk létre úgy, hogy mindegyik kategóriába beleessen legalább egy olyan szint, ahol van modell által szolgáltatott információ.

Az eredmények értékelését különböző kategorikus verifikációs indexek segítségével hajtottuk végre. Ezek közül jelen dolgozatban a HSS (Heidke Skill Score), a FAR (False Alarm Ratio), a POD (Probability Of Detection) és az ETS (Equitable Threat Score) indexeket számítottuk. Az így kapott index értékeket a szakirodalomban fellelhető módszerek (*Costa-Surós et al., 2014; Götz & Rákóczi, 1981*) segítségével kalkulált felhőalap értékekre számított kategorikus verifikációs index értékeivel vetettük össze.

2. Irodalmi áttekintés

2.1. Neurális hálózatok alkalmazása

A neurális hálózatok alkalmazása igen széles körben elterjedt. Felhasználási területe kiterjed az olyan közvetlen meteorológiai paraméterekre, mint a hőmérséklet (pl. *Hayati & Mohebi*, 2007), napi csapadék (pl. *Hall et al.*, 1999) vagy a felhőzet és látástávolság (pl. *Marzban et al.*, 2006, *Wang et al.*, 2009; *Nagy*, 2014; *Fricke*, 2017) meghatározásától, a légszennyezettségen (pl. *Fernando et al.*, 2012) át, a megújuló energiákon alapuló energiatermelés (pl. *Filik & Filik*, 2006) előrejelzéséig. A neurális hálózat alkalmazása jó megoldás lehet azon előrejelzések esetén, ahol olyan komplex rendszerekre kell előrejelzést készíteni, amelyek rosszul definiálhatóak vagy érhetők meg matematikai egyenletek segítségével. Ezen kívül olyan esetekben is jól használhatóak még, ahol problémát jelent a zajok kezelése, vagy a bemeneti adatok hiányosak (*Tokar & Johnson*, 1999).

Elmondható, hogy a becslések szerint az esetek 80%-ában a használt hálózat hiba visszaáramoltatásos (back-propagation) (*Abhishek et al.*, 2012) és hogy a hálózat a legtöbb esetben többrétegű. Az egyes módszerek közti különbséget leginkább a rétegek - a felhasznált inputok száma -, illetve az aktivációs függvények alakja adja.

Látástávolság és felhőzet

A látástávolság és a felhőzet pontos meghatározása és előrejelzése főként a légiközlekedés szempontjából fontos, ezért elmondható, hogy a legtöbb látástávolságra és felhőzetre vonatkozó neurális hálózattal történő kutatás általában repülőtérhez kapcsolódik. A kutatások eredményei megegyeznek abban, hogy a neurális hálózat képes a köd és a felhőalap magasságának előrejelzésére, és általában a meglévő klasszikus statisztikai módszereknél jobban teljesít a rövidtávú előrejelzések során.

Milánóban, a téli időszakban a látástávolság ultrarövid távú előrejelzésére (0–2 óra) használtak neurális hálózatot (*Pasini et al.*, 2001), amelyhez felszíni mérések szolgáltatották a tanulóadatsort. A hálózat 1 rejtett réteget tartalmazott és 10 inputot, amelyek közül az év adott napja és az óra szinusz és koszinusz függvényekkel lett átalakítva. Érzékenységi vizsgálat alapján elmondható volt, hogy a helyes előrejelzés pontosságán javított a perzisztencia prognózishoz szükséges, az előrejelzési idő előtt mért látástávolság ismerete. Verifikációs indexek számítása után elmondható volt, hogy a neurális hálózat pontosabb

értékeket szolgáltatott, mint amiket a perzisztenciából és a klimatológiai indexekből lehetett nyerni.

Az Egyesült Államok parti területein a nyári hónapokban kialakuló stratus felhőzet magasságának és a horizontális látástávolságban történő romlásának mértékére történő előrejelzést is megkísérelték neurális hálózat segítségével (*Marzban et al.*, 2006). A neurális hálózat inputjait a felszíni mért adatok és a numerikus modell outputok adták, így végül a hálózatnak 20 inputja és 3 vagy 4 outputja volt attól függően, hogy felhőalapot vagy látástávolságot jelzett előre. Mind a két előrejelzendő paraméter esetében logisztikus aktivációs függvényt alkalmaztak. A 6 és a 12 órára vonatkozó neurális hálózattal készített előrejelzések a legtöbb állomás esetében mind a felhőalap magasság és mind a látástávolság esetén jobbnak bizonyultak, mint a hagyományos modell alapú statisztikai módszer (MOS) segítségével készített előrejelzések.

Az előző témához hasonló kutatást végeztek a San Francisco-i Nemzetközi Repülőtéren is (*Dean & Fiedler*, 2001). Ezen, a part közelében fekvő repülőtéren a nyári hónapok során gyakori, hogy az éjszaka folyamán alacsonyszintű stratiform felhőzet képződik, amely általában csak másnap reggel oszlik fel, és a felhőzet feloszlásának pontos idejének a meghatározására tesztelték a lineáris regressziós módszert és egy előrecsatolt, logisztikus szigmoid aktivációs függvényrel rendelkező neurális hálózatot egyaránt. Ezen kívül mind a két módszert alávették egy újabb előrejelzési feladatnak. Kora reggeli adatok alapján kellett előrejelzést adni a repülőtéren kora estére várható hőmérsékletre. Mindkét módszer jobbnak bizonyult, mint a klimatológiai értékek, és a kettő közül a neurális hálózattal történő előrejelzés bizonyult kicsit pontosabbnak mind a két előrejelzendő paraméter esetén.

A Canberrai Nemzetközi repülőtéren a köd 3, 6, 12 és 18 órás időlépcsőre történő előrejelzésére használtak előrecsatolt többrétegű neurális hálózatot, amely 2 rejtett réteggel rendelkezett és BATCH algoritmussal tanult (*Fabbian et al.*, 2007). Ebben a tanulmányban is arról számoltak be, hogy a neurális hálózat képes a köd előrejelzésére, és javasolták a használatát erre a repülőtérre vonatkozó köd előrejelzés készítéséhez.

Neurális hálózatok segítségével valószínűségi előrejelzést is készítettek már látástávolságra (*Bremnes & Michaelides*, 2007). Ebben az esetben kétféle megközelítést alkalmaztak. Az első megközelítés, hogy nem egy konkrét, a legjobbnak választott neurális hálózat output értékeit használták fel eredményként, hanem több különböző hálózat eredményeit figyelembe vették, hogy egy valószínűségi információt kapjanak a látástávolságra vonatkozóan. A második megközelítésben egy determinisztikus neurális

hálózatot használtak, hogy előállítsanak inputokat egy valószínűségi neurális hálózat számára.

Fricke Cathy (2017) diplomamunkájában szintén neurális hálózatokkal foglalkozott. Munkájában perfect prognosztika módszer segítségével nowcasting előrejelzést készített a látástávolságra.

Csapadék és hőmérséklet

A csapadék előfordulásának valószínűségét, csapadékmennyiséget és hőmérsékletet is jeleztek már előre neurális hálózatok segítségével, és igencsak biztató eredményeket kaptak. Ebben az esetben nem csak rövidtávú (1 napra előre vonatkozó) előrejelzések készültek, hanem egyes tanulmányokban havi csapadékösszegek meghatározásával is foglalkoztak.

Az egyik vizsgálatot Dallas és Texas területén végezték el napi csapadékkal kapcsolatos információk előrejelzésére (*Hall et al.*, 1999). Két hálózatot hoztak létre, az egyik a csapadék előfordulásának valószínűségét jelezte előre az adott napra, míg a másik hálózat a kiválasztott területre átlagos csapadékmennyiséget becsült (nem maximális csapadékmennyiséget). A meleg hónapokra (áprilistól októberig) és a hideg hónapokra (novembertől márciusig) különböző hálózatokat fejlesztettek ki. A 19 bemeneti adatot egy numerikus modell outputjai és szondázási adatok szolgáltatták, és ezekhez adták még a megfigyelt csapadékösszeget. A verifikáció során a neurális hálózat előrejelzését egy 36 billenőedényt tartalmazó hálózat adataihoz viszonyították két éves teszt időszak során. Az így kapott eredmények igencsak figyelemreméltóan pontosak voltak, hiszen a csapadék előfordulására vonatkozó előrejelzések több mint 70%-a esetén 5%-nál alacsonyabb, vagy 95%-nál nagyobb valószínűség jött ki. A 436 5%-nál alacsonyabb valószínűségű napból 435 esetén valóban nem hullott csapadék, és a 111 95%-nál nagyobb valószínűségű nap mindegyikén előfordult csapadék.

Az indiai gazdaság számára nagyon fontos a nyári monszunesőzés, ezért komoly kihívást jelent a csapadék minél pontosabb előrejelzése a monszun időszakra. Az indiai Kárnata egyik kerületében azt tanulmányozták, hogy lehetséges-e átlagos havi csapadékösszeget előrejelezni neurális hálózat segítségével (*Abhishek et al.*, 2012). Ebben az esetben három különböző hálózatot próbáltak ki a kísérlet során: 1., előrecsatolt hiba visszaáramoltatásos, 2., réteg visszacsatolásos 3., előrecsatolt, kaszkádos hiba visszaáramoltatásos. Hasonlóan a havi csapadékösszeg előrejelzését később is megkísérelték (*Mislan et al.*, 2015). A kutatás során három különböző struktúrájú neurális

hálózatot vizsgáltak. Az első egy 2-50-10-1 felépítésű 500 epoch-al, a második egy 2-50-20-1 1000 epoch-al, míg a harmadik szintén 2-50-10-1 struktúrájú volt 1500 epoch-al. A négyzetes hibákból kapott eredmények alapján a második hálózat bizonyult a legpontosabbnak. A kísérlet során mérték az egyes hálózatok esetén az iterációs időt, amely eltérő értékeket mutatott a különböző hálózatok esetén. Az eredmények alapján is jól látható, hogy ezen a területen az egyenlítői két esős hónap a jellemző (április és november). Az említett három hálózat közül a hiba visszaáramoltatásos hálózat teljesített a legjobban. Továbbá elmondható, hogy a neuronok számának, és az input adatok mennyiségének növelésével a négyzetes hiba értéke csökkent.

Nyugat-Irán egyik városában a hőmérséklet rövid távú előrejelzését végezték többrétegű neurális hálózat segítségével (*Hayati & Mohebi, 2007*). A tanuló- és a teszt adatsor létrehozásához 10 éves mérési eredmények álltak rendelkezésre. A tanítás során elsőnek a Levenberg-Marquardt algoritmust próbálták ki, de mivel így nem kaptak megfelelő előrejelzést, végül a Skálázott Konjugált Gradiens (SCG) algoritmust használták a többrétegű neurális hálózat tanítása során. Az eredmények tükrében elmondható, hogy a neurális hálózat egy napra előre vonatkozó hőmérsékleti előrejelzése során csupán minimális hiba volt, így összességében Kermanshahban használható ez a modell hőmérséklet előrejelzéséhez.

A Floridában található Nemzeti Hurrikán Center és még sok egyetem világszerte dolgozik azon, hogy javítsák a hurrikánok előrejelezhetőségét és ennek érdekében a hurrikánok előrejelzését végző modelleket fejlesztését is gyors ütemben végzik. Az Észak-Atlanti-óceán feletti hurrikánok útvonalának 6 órás előrejelzését is megkísérelték egy rejtett réteget tartalmazó neurális hálózat segítségével (*Johnson & Lin, 1995*). A neurális hálózat 8 inputot használt fel az előrejelzéshez, amelyeket egy logaritmikus összefüggés segítségével 0 és 1 közötti értékekké alakítottak át. Az outputok száma szintén 8 volt, még a rejtett rétegen egy neuron volt. Hozzávetőlegesen az adatsor 65%-a szolgált a hálózat tanítására. Az előrejelzések térbeli bizonytalansága $1,63^\circ$ és $5,75^\circ$ voltak a szélességi és hosszúsági fokokat illetően.

Légszennyezettség

Számos nagyváros esetében egyre fontosabbá válik a légszennyezés napi szintű előrejelzése, ezért a meteorológia ezen területén is kipróbálták a neurális hálózat teljesítőképességét. Az előrejelzések legtöbb esetben valamelyik nagyváros központi területére, 1 napra előre vonatkoztak. A különböző légszennyezőanyagok esetén eltérő volt

a neurális hálózattal történt előrejelzés pontossága.

Egy tanulmány során a regressziós modell és a neurális hálózat teljesítményét hasonlították össze az ózon nagyvárosokban történő előrejelzésére (Comrie, 1997). A kutatás keretein belül 8 nagyváros levegőjét vizsgálták. Kétféle felépítésű neurális hálózatot is teszteltek, az egyik 4-6-1, a másik pedig 5-7-1 struktúrájú volt. A két hálózat abban tért el egymástól, hogy a második esetében a múltból is felhasználtak információkat. A vizsgálat során az az eredmény született, hogy a neurális hálózat előrejelzése valamivel jobbnak bizonyult az ózon időjárási alapon (tehát inputként meteorológiai adatokat felhasználva) történő napi előrejelzéséhez képest, de nem drasztikus a két módszer közötti különbség. Ezen kívül megállapítható volt, hogy mindegyik modell alulbecsülte a magas ózon koncentrációjú eseményeket, még az alacsony koncentrációjúak esetén pedig felülbecslés volt megfigyelhető.

Egy másik vizsgálat során a lisszaboni régió PM_{10} koncentrációját vizsgálták 2002 és 2006 között, 12 állomás meteorológiai és légszennyezettségi méréseit felhasználva (Russo *et al.*, 2015). Azt találták, hogy a többszörös lineáris módszer és a logisztikus szigmoid aktivációs függvényvel rendelkező többretegű neurális hálózat előrejelzése között nincs szignifikáns különbség. Ezen kívül kimutatható volt, hogy a modellek más-más eredményeket adtak a 12 állomás esetén, amely lehetővé teszi a városi régió jó térbeli felbontású előrejelzését.

Pekingben, Tiencsinben és Hopej tartományokban a $PM_{2.5}$ napi koncentrációját jelezték két napra előre egy új hibrid modell segítségével, amelyben a légtömeg trajektória-analízist és a wavelet transzformációt kombinálták, hogy javítsák a neurális hálózat előrejelzésének pontosságát (Feng *et al.*, 2015). Az egy rejtett réteget tartalmazó neurális hálózat tanítása során figyeltek az „early stopping” jelenségre, ami azt jelenti, hogy idejében leállították a tanulási folyamatot, hogy elkerüljék a hálózat túltanulását. Az adatok 85%-a szolgált tanulásra, 15%-a tesztelésre. Az egyes rétegeken elhelyezkedő neuronok száma 10-8-1 volt, és logisztikus szigmoid aktivációs függvényt alkalmaztak. Az eredmények ebben az esetben is kielégítően pontosnak bizonyultak.

Az Arizona területén fekvő Phoenix városában is PM_{10} előrejelzése során vizsgálták a neurális hálózatok hatékonyságát (Fernando *et al.*, 2012). Olaszországban kifejlesztettek egy sztochasztikus neurális hálózat prototípust, hogy nagyvárosokban (Róma, Milánó, Nápoly) előrejelezzék a levegő minőségét. Ennek a neurális hálózatnak EnviNNet nevet adták. Ez egy háromrétegű neurális hálózat, amely az első és a második réteg között tangens hiperbolikus, a második és a harmadik réteg között exponenciális aktivációs

függvényt használt. A sztochasztikus EnviNNet modellt összevetették egy determinisztikus CMAQ (Community Multiscale Air Quality) modellel Phoenix városának levegőminőség előrejelzésére, és a 2005. novemberi időszakban tesztelték mindkettő modell előrejelző képességét. Azért esett a választás a novemberi teszt időszakra, mert ilyenkor általában magasabb a PM₁₀ koncentráció, mint a nyári hónapokban, illetve ezalatt az egy hónapos időszak során előfordultak alacsonyabb és magasabb PM₁₀ koncentrációjú napok egyaránt. Annak ellenére, hogy a neurális hálózat nem tartalmaz komoly fizikai és dinamikai hátteret, a gyakorlati levegőminőség előrejelzés során méltó versenytárs lehet a fotokémiai modellekkel szemben, mivel a teszt során az EnviNNet jobban teljesített, mint a fotokémiai modell, ezen kívül gyors és gazdaságos az alkalmazása.

Helsinki belvárosában 2 állomásra történő NO₂ és PM₁₀ koncentráció órák előrejelzésére öt neurális hálózat, egy determinisztikus modell és egy lineáris statisztikus modell eredményeit hasonlították össze (Kukkonen et al., 2003). Az NO₂ koncentráció előrejelzése során a neurális hálózat előrejelzése jobbnak bizonyult a determinisztikus modellénél. A lineáris statisztikus modell előrejelzésénél a PM₁₀ és az NO₂ esetén is jobbnak bizonyult a neurális hálózat előrejelzése. A PM₁₀ előrejelzése esetén a neurális hálózat teljesítmény statisztikai nem voltak olyan jók, mint az NO₂ előrejelzése során. Ezen kívül kimutatták, hogy a jelenlegi neurális hálózatok a térbeli koncentráció eloszlásra nem alkalmazhatók, illetve a levegőszennyezés csökkentő forgatókönyvek elemzésére sem.

Hidrológiai alkalmazás

A hidrológiában is sikeresen alkalmazták a neurális hálózatokat, és legtöbb esetben a neurális hálózattal történt előrejelzés pontosabbnak bizonyult a klasszikus statisztikai módszereknél. Ebben az esetben is főként rövidtávú előrejelzések készítéséhez használták sikeresen ezt a módszert.

Marylandben a Little Patuxent folyó vízgyűjtő területén a napi lefolyás modellezésére alkalmaztak előre-csatolt, hiba visszaáramoltatásos algoritmussal tanult neurális hálózatot és az eredményeket a meglévő technikákhoz hasonlították, mint például statisztikus regresszióhoz és egyszerű konceptuális modellekkel készített előrejelzésekhez (Tokar & Johnson, 1999). Többféle neurális hálózatot is kipróbáltak, amelyek a bemeneti adataikban tértek el egymástól, így a csapadék, a hőmérséklet és a hóolvadás adatokat eltérőképpen használták fel. A Little Patuxent folyó esetén a neurális hálózat előrejelzései pontosabbnak bizonyultak a hagyományos módszereken alapuló előrejelzésnél.

Az Olaszországban található Tagliamento folyó egy csapadékos időszakban

előforduló áradásának előrejelzésére is alkalmaztak logisztikus aktivációs függvénnyel rendelkező és BATCH algoritmussal tanult neurális hálózatot (*Campolo et al., 1999*). A modell számára a csapadék információra vonatkozó input a hegyekben elhelyezett billenőedényes csapadékmérők által szolgáltatott adatokból származott. A modell vízszintre vonatkozó előrejelzése egy órás időablakot tekintve nagyon pontos volt (az átlagos négyzetes hiba kevesebb volt, mint 4%), de az időablak növelésével csökkent a pontosság. Az optimális időablak megválasztása erősen függött az adott eseménytől, de általánosságban elmondható, hogy a modell pontossága 5 óráig kielégítő maradt. Az ilyen, csak csapadék és vízszint információt felhasználó modellek ezen az időhatáron túl nem tűnnek alkalmasnak az előrejelzésre.

Dawson & Wilby (1998) szigmoid aktivációs függvényt alkalmazó előrecsatolt neurális hálózatokat fejlesztettek ki és használtak az áradások előrejelzésére két árvíz kialakulására hajlamos brit vízgyűjtő területen. A tanulmány során valós 15 perces időintervallumra vonatkozó hidrometriai adatokat használtak fel.

Megújuló energia alapú áramfejlesztés előrejelzése

Az utóbbi évtizedekben előtérbe került a megújuló energiaforrások használata, amelyek közül az időjárásfüggő típusok további térnyeréséhez elengedhetetlenek a mainál pontosabb célprognózisok. Egyre több tanulmány foglalkozik ezzel a témával, és az előrejelzést már több energiaforrás esetén is megkísérelték neurális hálózatok segítségével támogatni. Figyelemreméltó eredményeket kaptak.

A villamosenergia-rendszer egyensúlya miatt nagyon pontos szélsébség-előrejelzési módszereket kell kidolgozni. A jövő optimális hálózati működéséhez a rövid távú szélsébség-előrejelzés kritikus fontosságú és egyben komoly kihívást jelentő probléma. A szél előrejelzését szintén megkísérelték neurális hálózat segítségével végezni (*Filik & Filik, 2006*). A neurális hálózatok a jövőbeli szél alakulásának becslésére az előrejelzést megelőző időlépcsőkben előforduló szélsébség adatokat, hőmérséklet és nyomás adatokat különbözőképpen használták fel, így a vizsgálat során több hálózat előrejelző-képességét is tesztelték. A hálózatok logisztikus szigmoid transzfer függvényt használtak és Levenberg–Marquard algoritmus segítségével tanultak. A legjobban az a struktúra teljesített, ahol a szél adatok mellett a nyomás és a hőmérséklet adatok is a hálózat inputjait képezték.

Az északi szélesség 36° és 42° között fekvő, a mediterrán térségben található Törökország 12 különböző régiójában elhelyezkedő városában a potenciális napenergia

előrejelzését kísérelték meg neurális hálózat használatával (Sözen *et al.*, 2005). Az évi átlagos egy napra jutó sugárzás $3,6 \text{ kW h/m}^2$, míg egy év során körülbelül 2610 órán keresztül tart a szoláris sugárzási periódus ezen a területen. Egy háromrétegű hálózatot alkalmaztak a kísérlet során, amelynek 6-6-1 volt a struktúrája. A vizsgálat során Skálázott Konjugált Gradiens (SCG), Pola-Ribiere konjugált gradiens (CGP) és Levenberg–Marquardt (LM) algoritmusok változatait alkalmazták. Az inputok és az outputok a neurális hálózatok esetében bevett gyakorlatnak megfelelően -1 és 1 közötti tartományba lettek normálva. Az input rétegen található neuronoknak nem volt transzfer függvényük, míg a rejtett rétegen logisztikus szigmoid függvényt alkalmaztak. Az eredmények azt mutatták, hogy a potenciális napenergia előrejelzése során a neurális hálózat előrejelzése pontosabbnak bizonyult a klasszikus regressziós módszereknél.

2.2. Felhőalap becslése

A felhőzet meghatározása és mérése

A légiközlekedés szempontjából az időjárás sokkal jelentősebb hatású befolyásoló tényező, mint a többi közlekedési ágazat számára. A köd, az alacsony szintű felhőzet és az intenzív csapadék megváltoztatja a repülőgép működésének szabályszerűségeit, így akár a leszállás veszélyessé is válhat (Gaumet et al., 1997). A felhőzet pontos ismerete nagyon fontos a pilóták számára, hiszen a felhőzet korlátozza a földi tereptárgyak láthatóságát, így nehezítve a leszállást, illetve néhány felhőfajtában a repülés veszélyes lehet például a jegesedés vagy a turbulencia miatt (Sándor & Wantuch, 2005). A látástávolságmérők és a ceilométerek létfontosságúak a folyamatosan üzemelő repülőtereken, hiszen ezek szolgáltatnak pontos információt a látástávolságról és a felhőalapról (Gaumet et al., 1997).

Számos tanulmány foglalkozik a szakirodalomban a felhőzet mennyiségének, illetve a felhőzet alapjának és a tetejének a meghatározásával.

Ha egy adott napon a termikus konvekció már kialakult, akkor a Ferrel-formula segítségével meg lehet határozni a gomolyos felhőzet alapjának a magasságát (Sándor & Wantuch, 2005):

$$h=120\cdot(t-t_d) \quad (1)$$

ahol t a hőmérsékletet, t_d a harmatpontot jelöli °C-ban, és így a h felhőalap magasságát méterben kapjuk meg.

Rádiószondás adatokból történő felhőzet meghatározást kíséreltek meg a Szovjetunióban (Chernykh & Eskridge, 1996). A módszert eltérő éghajlatú szondázó állomások adataival tesztelték. Potenciálisan jobb paraméter a vertikális gradiens megváltozása, mint a relatív nedvesség vagy a hőmérséklet pontos értéke, mivel a különböző országok más és más szenzort használnak ezen paraméterek mérésére, illetve a relatív nedvességből is eltérő formulával számítanak harmatpont depressziót, ezen kívül a mérési körülmények gyors változására is eltérően reagálnak a szenzorok. A módszer úgy működik, hogy a hőmérsékletnek és a relatív nedvességnek a vertikális profiljából határozzák meg a felhőzet magasságát, úgy, hogy ahol ennek a két mennyiségnek a második deriváltja negatív, ott található a felhőzet. A felhőben a relatív nedvesség második deriváltja végig egyenlő lesz 0-val, hiszen itt a relatív nedvesség értéke konstans. Ennek a módszernek a használatával a helyes meghatározás valószínűsége nagyobb, mint 90%. Legnagyobb a helyes meghatározás valószínűsége az alacsony szintű felhőzet esetén, míg legkisebb valószínűséggel a magas szintű felhőzet esetén nyílik erre mód.

Műholdas felhőmagasság megítéléssel is számos cikkben találkozhatunk (pl. *Hanel*, 1961; *Smith & Platt*, 1978; *Kassianov et al.*, 2005). A műholdas adatokból származtatott felhőalapmagasság becslés kifejezetten fontos, mivel a felhő radarok és LIDAR-ok mérései elég költségesek, illetve elég hiányosan érhetőek el a föld felszínén (*Kassianov et al.*, 2005).

Az egyik tanulmányban a Nimbus 5 műholdon található infravörös hőmérsékleti profil radiométerével mért felhőmagasságokat hasonlították össze egyidejűleg végzett megfigyelésekkel, illetve a LIDAR-rendszer által mért értékekkel Ausztráliában (*Smith & Platt*, 1978). Az eredmények azt mutatták, hogy a CO₂-csatornából abszorpciós módszerrel történő felhőzet meghatározás egyezett a legjobban a földi alapú megfigyelésekkel. Szintén CO₂ abszorpciójának a vizsgálatával történő felhőmagasság meghatározásával foglalkozott *Hanel* (1961) is.

A felhőzet előrejelzése

A légitözlekedés biztonsága és hatékonysága szempontjából nagyon fontos a repülőtereken az időjárás pontos és időszerű előrejelzése (*Hansen*, 2007). A repülésmeteorológiában a szélre, csapadékra, látástávolságra és felhőzetre vonatkozó előrejelzéseket a TAF (Terminal Aerodrome Forecast) távirat tartalmazza. A pilóták az előrejelzések alapján akár kitérő repülőterre is mehetnek, amennyiben az időjárási körülmények és az előrejelzések ezt indokolják.

A meteorológusok számára a felhőalap és a látástávolság előrejelzése egyaránt komoly nehézségekbe ütközik, mert ezeket a paramétereket gyakran mikro-, illetve mezoskálájú folyamatok befolyásolják, amíg a meglévő megfigyelési és előrejelzési rendszer főként szinoptikus skálájú folyamatok vizsgálatát teszi lehetővé (*Bocchieri & Glahn*, 1972).

A rövidtávú előrejelzések szempontjából kulcsfontosságú az előrejelzés előtti utolsó időlépcsőjéből származó adatok felhasználása, tehát a légkör aktuális állapotának ismerete (*Vislocky & Fritsch*, 1997). Ez különösen igaz a látástávolság és az alacsonyszintű felhőzet előrejelzésénél, mert ezek igencsak gyorsan képesek változni akár rövid idő alatt is. A modell alapú statisztika (MOS) esetén is fontos az utolsó időlépcsőből származó állapothatározó értékek ismerete, mert így látható, hogy a modell outputjai és a tényleges felhőalap, illetve a látástávolság között milyen a kapcsolat.

Az első modell alapú statisztikák egyike *Bocchieri & Glahn* (1972) munkája, amelyben megkísérelték a felhőalap előrejelzését. A módszer lényege, hogy az előrejelző

modell outputjai és az előrejelzendő állapototáró 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. A kapott eredmények alapján elmondható, hogy a regressziós becslés jobbnak bizonyult a perzisztencia és a klimatológiai alapú előrejelzésnél is.

Egy másik módszer az 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 (*Hansen, 2007*). A WIND-3 előrejelző rendszerben az analógiás módszert kombinálták a fuzzy logikával, és a hatékonyságát 190 kanadai repülőtéren tesztelték az előrejelzők. A fuzzy k-NN (k legközelebbi szomszéd algoritmus) módszerrel lehetséges az analógiás előrejelzés alkalmazása, hiszen ennek a módszernek a segítségével lehet kiválasztani a leghasonlóbb eseményeket, amelyek egy úgynevezett „analógiás ensemble”-t alkotnak. A k-NN algoritmus a gépi tanulás egy egyszerű módszere, amely a klasszifikációhoz és a regresszióhoz egyaránt használható. Lényege, hogy a tanuló adatsorban található szomszédok minél távolabb vannak a keresett értéktől, annál kisebb súlyt kapnak.

Az USA-ban a Szövetségi Légügyi Hivatal (FAA) Nemzeti Felhőalap és Látástávolság Kutatócsoportja (NCV) kifejlesztett egy repüléstechnikai módszert (*Black et al., 2008*), amely 10–12 órára vonatkozó előrejelzést ad a felhőalapra, látástávolságra és a kettőt kombinálva egy mezőn, a repülési kategóriára (IFR/VFR). Ez a rendszer segít automatizálni a felhőalap és a látástávolság előrejelzését. A módszer négy inputot használ fel az előrejelzéshez: két numerikus modell adatait (RUC, LAMP), egy belső megfigyelés-alapú rendszer adatait és a METAR észleléseket. Az előrejelzések METAR-okkal való összehasonlítása jó eredményeket adott.

Egy másik kutatás során kimutatták, hogy a földi megfigyeléseket alapul vevő előrejelzés 1–3 órás előrejelzési idő esetén jobbnak bizonyult a perzisztenciánál, a klimatológiánál, sőt még a MOS előrejelzésnél is (*Vislocky & Fritsch, 1997*). Viszont 6 órás előrejelzési idő esetén már a megfigyelés alapú előrejelzés hasonlóan teljesített a MOS technikával készített előrejelzéshez képest. Nagy előnye a megfigyelés alapú előrejelzésnek a többi módszerrel szemben, hogy nem kapcsolódik konkrét helyhez és numerikus modellhez, könnyen automatizálható és gyorsan futtatható akár egy egyszerű személyi számítógépen is.

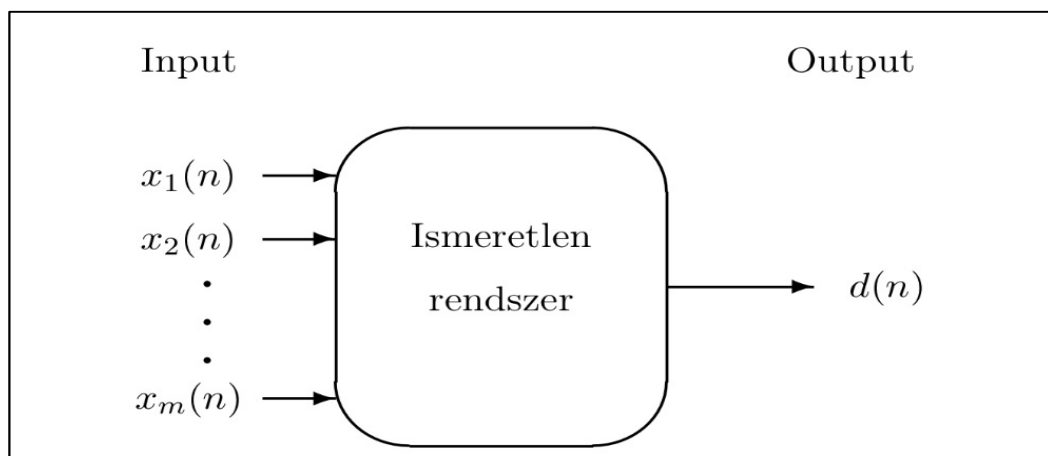
3. Neurális hálózatok

Az utóbbi évtizedekben egyre elterjedtebben használják a neurális hálózatokat a legkülönbözőbb természettudományos kutatásokban. 1943-ban Warren McCulloch és Walter Pitts megalkotta az első mesterséges neuronok segítségével működő modellt. Azóta évről évre egyre több és kifinomultabb neurális hálózatot hoznak létre (Rojas, 1996).

A neurális hálózat egy olyan számítási mechanizmus, amely a biológiai idegrendszer felépítésének és működésének analógiájára lett kialakítva. A biológiai idegrendszer fő tulajdonsága, hogy kicsiny alapegységekből van felépítve, és az egységek között sok a kapcsolat, és a rendszer sajátossága maga a tanulás képessége. A mesterséges neurális hálózatok is rendelkeznek ezekkel a tulajdonságokkal, de természetesen a biológiai idegrendszer mélyebb tulajdonságait már nem tudja átvenni.

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

Az 1. ábra alapján látható, hogy a bemeneti adatok egy m dimenziós vektorban vannak tárolva, ahol n az adott időpillanatot jelenti, és minden időpillanathoz tartozik egy $d(n)$ kimeneti érték ($n=1,2,\dots$) (Fazekas, 2013).



1. ábra: A modellezendő rendszer (Fazekas, 2013)

A perceptron a neurális hálózatok egy kezdeti típusa, amely egyetlen neuronból épül fel (Fazekas, 2013). Lényeges újítás volt ebben az esetben, hogy bevezették a számszerű súlyokat, és a speciális összekapcsolódási mintát. A tanulás folyamata során a hálózathoz különböző súlyok vannak rendelve egy numerikus algoritmus segítségével (Rojas, 1996).

A neurális hálózat alkalmazása a következő lépésekből épül fel:

1. A konkrét hálózat séma megadása:

Megadhatjuk, hogy az adott problémát perceptronnal kívánjuk modellezni, illetve hozzá egy aktivációs függvényt megadva már meg is van a konkrét séma kiválasztása. Aktivációs függvénynek általában szigmoid függvényeket szoktak használni (de lehet pl.: logisztikus, tangens hiperbolikus is).

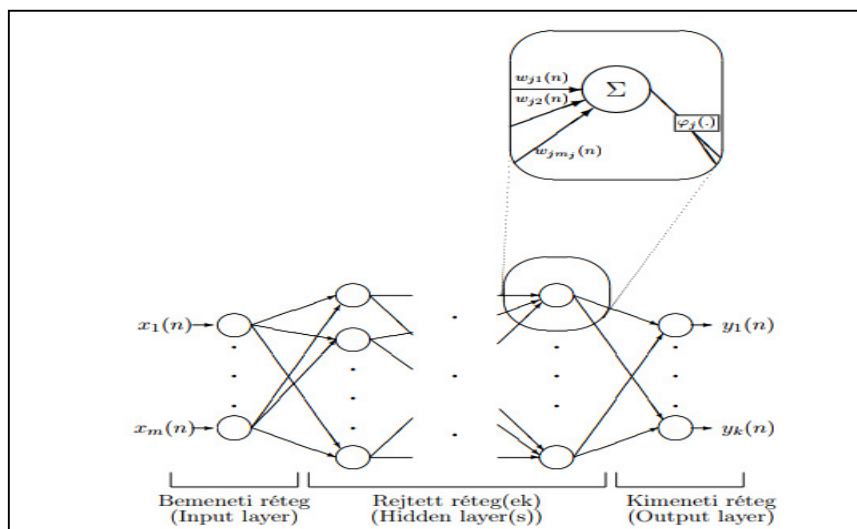
2. A hálózat betanítása:

Ehhez szükségünk van ismert $x(n)$ input adatokra, és a hozzájuk tartozó $d(n)$ kimeneti értékekre. A perceptron által adott $x(n)$ inputhoz számolt $y(n)$ outputok és a $d(n)$ értékek összehasonlításával megkaphatjuk a hálózat hibáját (négyzetes hiba). A tanítás folyamán az a cél, hogy ezt a hibát minimalizálni kell.

3. A hálózat használata:

A betanított hálózatot alkalmazzuk olyan adatokra, ahol az input ismert, és a $d(n)$ érték hiányában a modell által számolt outputot fogadjuk el igaznak. Gyakran a hálózat ellenőrzésére tesztadatokat használnak. (Fazekas, 2013)

Fontos említést tenni a többrétegű perceptron modelljéről is (2. ábra), amikor nem egyszerűen neuronokat kapcsolunk össze, hanem azokat rétegekbe is szervezzük. Ebben a konstrukcióban található egy bemeneti réteg, egy vagy több rejtett réteg, és egy kimeneti réteg. Rejtett rétegből tetszőleges számú lehet egy ilyen típusú neurális hálózatban, viszont bementi- és kimeneti rétegből kizárólag csak egy lehetséges. (Haykin, 1995)



2. ábra: A többrétegű perceptron felépítése (Fazekas, 2013)

A tanulás folyamata


A neurális hálózat elsődleges jelentőséggel bíró tulajdonsága a hálózat azon képessége, hogy környezetéből tudjon tanulni, és a tanulási folyamaton keresztül javuljon a teljesítménye. A neurális hálózat úgy tanul a környezetéből, hogy a neuronokhoz tartozó súlyokat kalibrálja olyanra, hogy a legjobb teljesítményre legyen így a hálózat képes. Ideális esetben a neurális hálózatnak a tanulási folyamat minden egyes ismétlése után jobbnak kell lennie.

A tanulási folyamat során a következő lépések történnek:

1. a neurális hálózatra a környezet hatást gyakorol,
2. a neurális hálózatnak ennek eredményeképpen megváltoznak a szabad paraméterei,
3. a neurális hálózat a megváltozott belső struktúrája miatt másképpen reagál a környezetre.

A tanulási problémát előre jól definiált úgynevezett tanulási algoritmusok segítségével lehet megoldani. Ahogyan az várható, nincs egyedi tanulási algoritmus minden egyes neurális hálózatra, hanem van egy olyan eszköztárunk, amely a tanulási algoritmusok sokféleségéből áll össze, és mindegyik algoritmusnak megvannak a saját maga előnyei. Alapvetően a tanulási algoritmusok abban térnek el egymástól, hogy a neuronokhoz eltérő módon rendelik a súlyokat. (Haykin, 1995)

A többrétegű perceptron 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 (3. ábra). Ezt a lépéssorozatot hiba-visszaáramoltatási módszernek (back-propagation algorithm) nevezik.



3. ábra: A neurális hálózat két súlyához tartozó hibafelület (Gardner & Dorling, 1998)

Az n -edik lépés négyzetes hibája a következő módon kapható meg:

$$\mathcal{E}(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) = \frac{1}{2} \sum_{j \in C} (d_j(n) - y_j(n))^2, \quad (1)$$

ahol $y_j(n)$ a j -edik neuronhoz tartozó a hálózat által kibocsátott output érték, $d_j(n)$ a j -edik kimenet valós értéke, C pedig a kimeneti réteg neuronjainak halmazát jelöli.

Ebből képezhetjük az N tanuló pontok számának ismeretében az átlagos hibát:

$$\bar{\mathcal{E}} = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n). \quad (2)$$

Ezután a gradiens módszer (delta rule) segítségével elvégezzük a súlyok korrekcióját:

$$w_{ji}(n+1) - w_{ji}(n) = \Delta w_{ji}(n) = -\eta \frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)}, \quad (3)$$

w_{ji} jelöli az i -edikből a j -edik neuronban mutató élen lévő súlyt, $\eta > 0$ pedig a tanulási paraméter, amely az iterációs lépések nagyságát határozza meg.

Az \mathcal{E} hibafüggvénynek az összes w_{ji} szerinti parciális deriváltját, azaz gradiensét kellene képezni, ami numerikusan elég nehezen megoldható. A hiba visszaáramoltatási módszer nagy előnye, hogy a deriváltakat rekurzívan számítja ki. A gradienst visszafelé haladva, rétegenként határozzuk meg. Egy adott neuron esetén a lokális gradiens megkapható az utána következő réteg lokális gradiensei segítségével. Mivel rétegenként visszafelé haladunk és a kimeneti réteg lokális gradiense ismert, ezért az összes lokális gradiens kiszámítható. Összegezve az egészet és a parciális differenciálás során alkalmazott szabály segítségével az alábbi képlet kapható:

$$\Delta w_{ji}(n) = -\eta \frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} = \eta \left(-\frac{\partial \mathcal{E}(n)}{\partial v_j(n)} \right) \frac{\partial v_j(n)}{\partial w_{ji}(n)} = \eta \delta_j(n) y_i(n), \quad (4)$$

ahol $v_j(n)$ a j -edik neuron által produkált összegzett érték, $\delta_j(n)$ a lokális gradiens, $y_i(n)$ pedig az i -edik neuron kimeneti értéke (az i réteg pontosan megelőzi a j réteget).


A tanulási algoritmus leállítása több esetben is történhet:

1. Ha a gradiens vektor kicsi, mert ilyenkor már nem változnak jelentősen a súlyok.
2. Ha egy epoch (a tanító halmaz egyszeri végigfutása a hálózaton) alatt a négyzetes hiba már nem csökken jelentősen.
3. Ha túl sok az epoch vagy túl hosszú a futási idő.

A négyzetes hiba általában nem csökkenthető nullára, így ez egy elvetendő célkitűzés. A hiba visszaáramoltatási módszer igen érzékeny a kezdeti értékekre, mivel a

gradiens módszeren alapul. Előfordulhat, hogy a globális minimum helyett csupán lokális minimumot talál. A kezdeti súlyok megválasztása emiatt egy fontos feladat. (Fazekas, 2013)

A tanulási folyamat során figyelni kell a túltanulás elkerülésére (4. 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 pontok mennyiségéhez képest túl nagy. (Altrichter et al., 2006)



4. ábra: A tanulás során a négyzetes hibákat ábrázoló görbék (Altrichter et al., 2006)

A következőkben ismertetem a kutatás során felhasznált két algoritmust.

RPROP tanulási algoritmus:

Az RPROP algoritmus az egyik legjobban teljesítő elsőrendű tanulási algoritmus a neurális hálózatok esetén. Az algoritmust Riedmiller és Braun tervezte. (Igel & Hüsken, 2000)

Ez a tanulási algoritmus a „rugalmas visszaáramoltatásról” (**R**esilient **backPROP**agation) kapta a nevét, tehát közvetlenül változtatja a súlyfrissítés értékét. Az algoritmus alapvető elve, hogy kiküszöbölje a súlyozási lépések során a parciális derivált káros hatásának a mértékét. Ennek érdekében csak a derivált előjelét veszi figyelembe, az értékét nem, és így jelzi a súlyfrissítés irányát. A súlyváltoztatás mértéke kizárólag súlyspecifikus, az úgynevezett „súlyfrissített érték” határozza meg:

$$\Delta w_{ij}^{(t)} = \begin{cases} -\Delta_{ij}^{(t)} & , ha \quad \frac{\partial \mathcal{E}^{(t)}}{\partial w_{ij}} > 0 \\ +\Delta_{ij}^{(t)} & , ha \quad \frac{\partial \mathcal{E}^{(t)}}{\partial w_{ij}} < 0 \\ 0 & , ha \quad \frac{\partial \mathcal{E}^{(t)}}{\partial w_{ij}} = 0 \end{cases} , \quad (5)$$

ahol $\partial E/\partial w_{ij}$ jelöli az összegzett gradiens információt a séma beállításairól. A Δ_{ij} helyettesíthető konstans Δ frissítési értékkel, így létrehozva a Manhattan-frissítési szabályt.

A $w_{ij}^{(t+1)}$ lépésnél a súly az alábbi képlet segítségével kapható meg:

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} + \Delta w_{ij}^{(t)}, \quad (6)$$

A következő lépésként meg kell határozni az új Δ_{ij} súlyfrissítési értéket:

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ \cdot \Delta_{ij}^{(t-1)} & , ha \frac{\partial \mathcal{E}^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial \mathcal{E}^{(t)}}{\partial w_{ij}} > 0 \\ \eta^- \cdot \Delta_{ij}^{(t-1)} & , ha \frac{\partial \mathcal{E}^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial \mathcal{E}^{(t)}}{\partial w_{ij}} < 0 \\ \Delta_{ij}^{(t-1)} & , ha \frac{\partial \mathcal{E}^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial \mathcal{E}^{(t)}}{\partial w_{ij}} = 0 \end{cases}, \quad (7)$$

Ahol $0 < \eta^- < 1 < \eta^+$ a tanulási paraméter.

Minden időpillanat, amikor a megfelelő w_{ij} súly szerinti parciális derivált előjelet vált, akkor az azt mutatja meg, hogy az utolsó frissítés túl nagy volt és az algoritmus átugrott a hibafüggvény lokális minimumán, és a Δ_{ij} súlyfrissítési érték η^- -szal lett csökkentve. Ha a derivált megőrzi az előjelét, akkor a súlyfrissítési érték kis mértékben van növelve annak érdekében, hogy a konvergencia gyorsuljon a kis gradiensű tartományokban.

Annak céljából, hogy csökkentsük a szabadon beállítható paraméterek számát, a növelő és csökkentő faktor értékét fixálni lehet. Az η^- esetén a következő dolgokat kell megfontolni. Ha a minimumon átugrás történik, akkor az előző frissítési érték túl nagy volt. Arról nincs információnk, hogy hány minimum érték lett átugorva, de ettől függetlenül meg kell becsülnünk a korrekt értéket. Általában az jó közelítés, ha a frissítési érték felének választjuk (maximum-likelihood becslés), tehát η^- -t 0,5-nek választjuk. Az η^+ növelési faktornak egyrészt elegendően nagynak kell lennie ahhoz, hogy elérhetővé tegye a frissítési érték gyors növekedését a hibafüggvény kis gradiensű tartományaiban, másfelől, ha túl nagy értéket választunk η^+ -nak, akkor perzisztens változást okozhat a súlyozási lépések irányában. Általában ezt az értéket 1,2-nek választják a különböző tanulmányokban, de ez függ a vizsgált problémától is.

Az RPROP a tanulási folyamatot próbálja a hibafüggvény topológiájához igazítani, ami azt jelenti, hogy a súlyfrissítés és a hozzáillesztés azután történik, hogy az egész sémára ki lett számítva a gradiens információ. (Riedmiller, 1994)

QUICKPROP algoritmus:

A back-propagation módszer első parciális deriváltat számol a hibafüggvényen végig minden egyes súly figyelembe vételével, annak érdekében, hogy megtalálja annak minimumát (Fahlman, 1988). Ha a gradiensben infinitezimális lépéseket teszünk, akkor garantált, hogy megtaláljuk a lokális minimumot, és azt empirikusan kell eldönteni, hogy ez a lokális minimum a globális minimum hely-e, illetve, hogy ezt a minimumhelyet globálisnak véve megfelelően jó eredményeket tudunk-e elérni a kitűzött feladatunkban.

Nyilvánvaló, hogy a lehető legrövidebb idő alatt szeretnénk megtalálni a megoldást, ezért nem lépkedhetünk infinitezimális lépésközökkel. A QUICKPROP algoritmus működése során az a cél, hogy a lehető legrövidebb idő alatt megtaláljuk a hibafüggvény globális minimumát. Ehhez a lehető legnagyobb lépésközt kell választani úgy, hogy a megoldást lehetőleg ne ugorjuk át. Az első derivált sajnos nagyon kevés információt nyújt arról, hogy mi az a legnagyobb lépésköz, amit még biztonságosan alkalmazhatunk. Ha tudnánk valamit a magasabb rendű deriváltakról, tehát a hibafüggvény görbületéről, akkor sokkal könnyebb lenne meghatározni az ideális lépésközt.

A QUICKPROP algoritmusban a probléma megoldására kétféle közelítési módszer van ötvözve. Az első közelítés dinamikus, próbálja igazítani a tanulási sebességet, mind globálisan, mind pedig külön-külön minden egyes súlyra. A másik módszer explicit használja fel a hiba második deriváltját minden egyes súly figyelembe vételével, és így ezzel az információval már új beállítást tudunk választani a Newton-módszerhez.

A minimumhelyet úgy próbáljuk megtalálni, hogy a súlyokhoz egy felfelé nyíló parabola alakú hibafüggvényt illesztünk, és feltesszük, hogy ennek a parabolának a meredeksége nem függ a többi súlytól. Majd ennek a parabolának a minimum pontját próbáljuk megkeresni.

A számítás nagyon egyszerű, és csak lokális információt használ a súlyfrissítéshez:

$$\Delta w_{ij}^{(t)} = \frac{\frac{\partial E^{(t)}}{\partial w_{ij}}}{\frac{\partial E^{(t-1)}}{\partial w_{ij}} - \frac{\partial E^{(t)}}{\partial w_{ij}}} \Delta w^{(t-1)}. \quad (8)$$

4. Verifikációs indexek

A kutatás során a vizsgált 3 kategóriára verifikációs indexeket határoztunk meg. Ezek a kategóriák az alábbiak voltak:

- 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)

A verifikációs indexeket az ún. kontingencia-táblázatban található értékek alapján lehet kiszámítani (1. táblázat). Ebben a táblázatban négyféle variáció létezik:

- a referencia kategória (METAR, felhőalap mérő adatsor) egybeesik neurális hálózat által számított kategóriával (a: helyes találat),
- a referencia kategória más kategóriába esik, (b: hibás riasztás),
- a neurális hálózattal számított érték megegyezik a vizsgált kategóriával (c: téves elvetés),
- 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	
				$n=a+b+c+d$

1. táblázat: A vizsgálatban alkalmazott kontingencia-táblázat.

A dolgozatban az alábbi verifikációs indexeket használtuk fel (Ebert & McBride, 1997; Nurmi, 2003):

- 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.

$$POD=a/(a+c) \quad (9)$$

- II. A FAR (False Alarm Ratio) index arról az arányról tájékoztat, hogy az előrejelzett események milyen aránya volt téves (túlbiztosított). Értéke 0-tól 1-ig vehet fel értékeket, az ideális értéke a 0. A POD és a FAR indexet együtt kell vizsgálni.

$$FAR= b/(a+b) \quad (10)$$

- III. 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.

$$ETS=(a-ar)/(a+b+c-ar) \quad (11)$$

$$ar=(a+b)(a+c)/n \quad (12)$$

- IV. A HSS (Heidke Skill Score) index az egyik leggyakrabban használt mutató, amely nagyon jól összefoglalja a 2x2-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.

$$HSS=2(ad-bc)/\{(a+c)(c+d)+(a+b)(b+d)\} \quad (13)$$

5. Adatok

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. 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 felhasználtuk a neurális hálózat tanuloadatsorának 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 kategóriákba. Mindkét szinten a keverési arányt, szélesség u és v komponensét és hőmérsékletet használtuk fel.

A felhözetről az információ két adatforrásból származott. Az egyik adatforrás a Liszt Ferenc Nemzetközi Repülőtérén a 13R pályaküszöbnél üzemelő felhőalapmérő nyers adatai. Ebben az esetben a felhőborítottságról nem, csupán a felhőzet alapjának a magasságáról kapunk információt.

A másik adatforrás a Liszt Ferenc Nemzetközi Repülőtérén dolgozó észlelők közreműködésével szolgáltatott METAR táviratban található felhőzetinformáció. Ez esetben a kategorizálás során a felhőzet borítottságát is figyelembe tudtuk venni, hiszen a táviratban a felhőalap magasság mellett a felhőzet mennyiségét is megadják. A METAR táviratban több szintre is találunk a felhözetről információt, ilyen esetben a repülés szempontjából fontosabb információt vettük figyelembe, tehát az 5 okta feletti és az 1500 láb alatti felhőzetet, ha előfordult ilyen. A METAR táviratban a felhőalap magassága 100 láb léptékkal van megadva, ezért a többi adatforrás adatait, illetve a felhőzet kategorizálását is ezzel a mértékkal végeztük.

Tehát a neurális hálózat tanulóadatsorának inputjai a modellből kinyert adatok voltak, még az output az a METAR-ban található, illetve a felhőalap mérő által mért adatok voltak kategorizálva.

A felhőzet adatokat három kategóriába soroltuk. A felhőalap mérős értékeket úgy kategorizáltuk, hogy az 1-es kategóriába tartozott az 1500 láb és afeletti felhőzet, 2-es az 1400 és 900 láb közötti felhőzet, még a 3-as kategóriába a 800 láb alatti felhőzet.

A METAR táviratban található felhőzetinformációk esetén a felhőborítottságot és a felhőalap magasságot is figyelembe vettük a kategorizálás során. Az 1-es kategóriába tartozott a repülés szempontjából kevésbé jelentős 1500 láb feletti felhőzet, illetve a 4 okta alatti bármilyen szinten található felhőzet (FEW/SCT). A 2-es kategóriába az 1400 és 900 láb közötti felhőzet tartozott, ami legalább 5 okta mennyiségű volt (BKN/OVC). A 3-as kategória a szintén 5 okta feletti, de 800 láb alatti felhőzet volt (5. ábra). Mivel az 1-es kategóriához 1–1,5 nagyságrenddel több érték tartozott, mint a másik két kategóriához, ezért véletlenszerű válogatással lecsökkentettük ezen kategória esetszámát a másik két kategória nagyságrendjére.

NSC			
FEW049	SCT049	BKN049	OVC049
...
FEW019	SCT019	BKN019	OVC019
FEW018	SCT018		OVC018
FEW017	SCT017	BKN018	OVC017
FEW016	SCT016	BKN017	OVC016
FEW015	SCT015	BKN015	OVC015
FEW014	SCT014	BKN014	OVC014
FEW013	SCT013	BKN013	OVC013
FEW012	SCT012	BKN012	OVC012
FEW011	SCT011	BKN011	OVC011
FEW010	SCT010	BKN010	OVC010
FEW009	SCT009	BKN009	OVC009
FEW008	SCT008	BKN008	OVC008
FEW007	SCT007	BKN007	OVC007
FEW006	SCT006	BKN006	OVC006
FEW005	SCT005	BKN005	OVC005
FEW004	SCT004	BKN004	OVC004
FEW003	SCT003	BKN003	OVC003
FEW002	SCT002	BKN002	OVC002
FEW001	SCT001	BKN001	OVC001

5. ábra: A három felhőzet kategória elkülönítése a lehetséges METAR kódok alapján. Zöld: 1-es kategória, narancssárga: 2-es kategória, lila: 3-as kategória.

6. Neurális hálózat alkalmazása

A felhőzet előrejelzésére a kutatás során neurális hálózatot használtunk. A következőben a hálózat alkalmazásának lépései kerülnek ismertetésre.

6.1. A tanuloadatsor elkészítése

Első lépésként egy olyan adatsort kellett elkészíteni, amiből a neurális hálózat képes volt tanulni. Ahogy az már az előbbiekben említésre került, a bemenő adatok a WRF modell adataiból kerültek ki, a kimenő adatok pedig a METAR, illetve a felhőalap mérő által mért értékek három kategóriába besorolva. A METAR és a felhőalap mérős adatsorra is külön-külön tanuloadatsor készült, hiszen a hiányzó adatok is eltérőek voltak mindkét esetben. Az outputokat binomiális klasszifikációval is átalakítottuk a METAR-os esetben, illetve a 2-es és a 3-as kategóriát is összevonásra került, így a végén négyféle tanuloadatsor jött létre:

I. A felhőalap mérős adatsor:

➤ inputok: nap, óra, a 2 vertikális szint keverési aránya, hőmérséklete, és a felszíni adatok

➤ outputok: a mért értékek kategorizálva

II. A METAR-os adatsor

➤ inputok: nap, óra, a 2 vertikális szint keverési aránya, hőmérséklete, a szélesség u és v komponense és a felszíni adatok

➤ outputok:

a. az észlelt felhőzetinformáció kategorizálva

b. az észlelt felhőzetinformáció kategorizálása után a binomiális klasszifikáció segítségével átalakított értékek

c. 2 csoportba kategorizálva az outputok

Fontos említést tenni a napok és az órák értékeinek az átalakításáról. Mivel a neurális hálózat nem tudja, hogy december 31. után január 1. következik (365. nap után az 1. jön), illetve, hogy a 23 óra után 00 óra következik, ezért mind a két esetben átalakítást hajtottunk végre szinuszfüggvénnyel, így ezek -1 és 1 között váltakozó értéket vettek fel. A tanuloadatsor inputjába már az átalakított formájuk került be.

6.2. A hálózat megkonstruálása és betanítása

A hálózat megkonstruálásához a FANN (Fast Artificial Neural Network) programkönyvtár volt segítségünkre, amelyet php programnyelvvvel használtunk. A hálózat topológiájának beállításakor számos tényező adott, de vannak paraméterek, amin változtathatunk. A bemenő és a kimenő rétegen található neuronok számát az input és az output adatok száma határozza meg. A kutatás során két rejtett réteggel rendelkező neurális hálózatokkal dolgoztunk, a rejtett rétegeken található neuronok számát az input rétegen található neuronok számának a felére választottuk meg. A FANN programkönyvtárban 18 aktivációs függvény és 5 tanulási algoritmus közül lehet választani. A két legjobban bevált tanulási algoritmus az RPROP és a QUICKPROP voltak, így a dolgozatban ezzel a két algoritmussal készült eredményeket mutatom be. Aktivációs függvények közül a szimmetrikus Gauss és a szimmetrikus szigmoid függvények bizonyultak a legjobbnak. Az így konstruált hálózatok a következők voltak:

- **1_Gauss_szimm_QUICKPROP:** Ez egy szimmetrikus Gauss aktivációs függvény segítségével és QUICKPROP algoritmussal tanult hálózat, amelynek bemeneti rétegén 9, kimeneti rétegén 1, és a 2 darab rejtett rétegén 4–4 neuron található. A tanuladatsorához az outputokat a felhőalap mérős adatsor szolgáltatta.

- **1_szigmoid_szimm_RPROP:** Ez a hálózat RPROP algoritmus segítségével tanult, és szimmetrikus szigmoid függvényt használt. A hálózat topológiája és tanuladatsora megegyezik az 1_Gauss_szimm_QUICKPROP hálózatéval.

- **2_Gauss_szimm_QUICKPROP:** Az aktivációs függvény és a tanulási algoritmus megegyezik az 1_Gauss_szimm_QUICKPROP hálózatéval, csupán a hálózat topológiájában van eltérés. Mivel itt 15 input volt, így a bemeneti réteg neuronjainak száma 15, a kimenetié 1, és a két rejtett rétegé 7–7 darab volt. A tanuladatsorához az outputokat a METAR táviratban található felhőzetinformáció szolgáltatta.

- **2_szigmoid_szimm_RPROP:** Ez a hálózat RPROP algoritmus segítségével tanult, és szimmetrikus szigmoid függvényt használt. A topológiája és tanuladatsora megegyezett a 2_Gauss_szimm_QUICKPROP hálózatéval.

- **3_Gauss_szimm_RPROP:** Ennek a hálózatnak az outputjait binomiális klasszifikációval alakítottuk át, így itt már 3 outputja volt a hálózatnak. Ennek megfelelően a topológiája megváltozott. A bemeneti rétegen 15, a két rejtett rétegen 7–7, még a kimeneti rétegen 3 neuron volt.

- 3_szigmoid_szimm_QUICPROP: A 3_Gauss_szimm_RPROP hálózatával megegyező topológiával és tanuladatsorral rendelkezett. Annyi különbséggel, hogy másik aktivációs függvényt és tanulási algoritmust használt.

- 4_szigmoid_szimm_RPROP: Annyiban tért el az előző 6 hálózattól, hogy a tanuladatsorban összevonásra került a 2-es és a 3-as kategória, így már a tanulás során is csak két kategória szerepelt.

A tanuladatsort szétválasztottuk: 70%-ból tanult a hálózat és 30% pedig a teszt adatsorként szolgált a tanuláshoz. A tanulási folyamat során azt a hálózati konfigurációt mentettük el, amelyik esetén a legkisebb volt a teszt adatsor négyzetes hibája. Fontos, hogy a teszt adatsor esetén nézzük a legkisebb négyzetes hibát, mert így kiküszöbölhető a hálózat túltanulása.

6.3. A hálózat tesztelése és az eredmények értékelése

A hálózat betanítása után, elkezdődhetett a tesztelésük. Jelen kutatás során 2 eltérő időszakra teszteltük mind a 7 különböző neurális hálózatot. Az első időszak egy január elsejétől február végéig, a második időszak egy augusztus elsejétől november elejéig tartó tesztidőszak volt. Természetesen a tanuladatsorban ezek az adatok nem szerepeltek, így a neurális hálózatnak ekkor a számára ismeretlen adatokkal kellett számolnia. Ez a tesztadatsor esettől függően egy 504 vagy egy 599 adattal rendelkező állományt jelentett.

A kapott értékeket a 3. fejezetben említett verifikációs indexek segítségével értékeltük ki. Az így kapott eredményeket a szakirodalomban fellelhető felhőalap magasság számító módszerekhez, 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. (*Costa-Surós et al., 2014*)

$$\begin{aligned} \Delta T_d &< 1,7 \text{ } ^\circ\text{C}, \text{ ahol } T > 0 \text{ } ^\circ\text{C} \\ \Delta T_d &< 3,4 \text{ } ^\circ\text{C}, \text{ ahol } T < 0 \text{ } ^\circ\text{C} \text{ és } T > -20 \text{ } ^\circ\text{C} \\ \Delta T_d &< 5,2 \text{ } ^\circ\text{C}, \text{ ahol } T < -20 \text{ } ^\circ\text{C} \end{aligned} \quad (14)$$

A képletben ΔT_d a harmatpont deficitet jelöli, amelyet a hőmérséklet és a harmatpont különbségeként kaphatunk meg:

$$\Delta T_d = T - T_d \quad (15)$$

ahol T a levegő hőmérsékletét, T_d pedig a harmatpontot jelöli $^\circ\text{C}$ -ban.

A (14)-es képlet közelíthető egy másik összefüggés segítségével, amelyben a harmatpont deficit helyett a relatív nedvesség alapján történik a felhőzet meghatározása.

$$\begin{aligned} RH &> 91,5 \% , \text{ ahol } T > 0 \text{ } ^\circ\text{C} \\ RH &> 83 \% , \text{ ahol } T > -20 \text{ } ^\circ\text{C} \\ RH &> 74 \% , \text{ ahol } T < -20 \text{ } ^\circ\text{C} \end{aligned} \quad (16)$$

ahol RH a relatív nedvesség jelöli, T pedig az hőmérsékletet.

A dolgozat további részeiben a (14)-es képlet 1/a , a (16)-os képlet pedig 1/b módszer néven fog szerepelni.

Egy másik összefüggést is alkalmaznak a felhőalap magasságának meghatározására, amely nem a hőmérséklet alapján ír le kritériumot a felhőzet megjelenésére, hanem a levegő nyomása alapján.

$$\begin{aligned} RH &> 92,5 \% , \text{ ahol } P < 1000 \text{ hPa és } P > 800 \text{ hPa} \\ RH &> 87,5 \% , \text{ ahol } P < 800 \text{ hPa és } P > 550 \text{ hPa} \\ RH &> 75 \% , \text{ ahol } P < 550 \text{ hPa és } P > 300 \text{ hPa} \end{aligned} \quad (17)$$

ahol RH a relatív nedvességet és P pedig a nyomást jelöli. A továbbiakban ez az összefüggés 2-es módszer néven lesz említve.

Azon a szinten számíthatunk felhőzetre, ahol a (14)-ben, (16)-ban és (17)-ben található három összefüggésből valamelyik teljesül.


Ezen kívül a neurális hálózat eredményeit még a részecske módszer segítségével számított felhőalapokhoz is hasonlítottuk. A módszer lényege, hogy azt feltételezzük, hogy a felszínről induló részecske száraz adiabatikus hőmérsékleti gradiens mentén mozog mindaddig, amíg a rendszerben a víz csak gőz alakban van jelen, tehát telítetlen a levegő (Götz & Rákóczi, 1981). Ezen a telítetlen szakaszon való emelkedés során a légréteg keverési aránya állandó marad. Mivel a levegő a felfelé emelkedés közben hűl, ezért a relatív nedvessége növekszik, majd ha eléri a telítettség állapotát, akkor megindul a gőz cseppfolyós állapotba való átmenete. Ezt a szintet, ahol ez az átmenet bekövetkezik, emelési kondenzációs szintnek nevezzük. Másképpen megfogalmazva, ez az a szint, ahol a felfelé haladva csökkenő harmatpont depresszió értéke egyenlő lesz nullával. Innentől kezdve a keverési arány már változik, mert megkezdődik vízgőz kondenzációja.

7. Eredmények


7.1. A neurális hálózattal becsült felhőalap magasságok kategorikus verifikációja

Az eredmények verifikációs indexek segítségével történő értékelése előtt még röviden áttekintjük a hálózatok időbeli felbontóképességét. Az első időszak (téli) vizsgálatához a felhőalap mérő adatait, az 1_Gauss_szimm_QUICKPROP (6. ábra) és az 1_szigmoid_szimm_RPROP hálózatok (7. ábra) kalkulált értékeit használtuk fel.

A következő diagramokon az látható, hogy a neurális hálózat által szolgáltatott nyers eredmények jól követik a felhőzet alakulásának tendenciáját. Amikor a 3-as kategóriába esett a felhőalap mérő által mért érték, akkor a neurális hálózat által kalkulált értékek is magasabbak voltak. Ez főként hosszabb ideig fennálló, 3-as kategóriájú felhőalapok esetén figyelhető meg a legjobban. A kétféle neurális hálózat teljesítménye szemmel láthatóan nem sokban tér el, ami a későbbiekben a verifikációs indexek értékeivel is alá lesz támasztva.



6. ábra: Az 1_Gauss_szimm_QUICKPROP hálózat által számított felhőalap kategóriák összehasonlítása a felhőalap mérőből kategorizált értékekkel az 1. (téli) időszakra



7. ábra: Az 1_szigmoid_szimm_RPROP hálózat által számított felhőalap kategóriák összehasonlítása a felhőalap mérőből kategorizált értékekkel az 1. (téli) időszakra

Ahhoz, hogy verifikációs indexeket lehessen a neurális hálózat által szolgáltatott valós számhalmazbeli értékekből számolni, az értékeket kategorizálni kell. Olyan küszöbértékek megtalálása a cél, amelyek mellett az index értékei a legjobban közelítenek az adott index ideális értékéhez. Ebben az esetben a verifikációs indexek értékeit tartalmazó táblázat (2. táblázat) az 1-es és a 2-es kategória között 1,4-es és 1,5-ös, illetve a 2-es és a 3-as kategória között 1,8-as és 1,9-es küszöbértéket alkalmazó kategorizálás során kapott értékekre számított indexeket tartalmazza a fenti diagramon szereplő két hálózatra. A kategorizálás során 1 tizedes változtatás a küszöbértékben néhány verifikációs index (pl. HSS, POD) értékében 2–4 százalékos eltérést okozott. A 2. táblázat, illetve az összes soron következő táblázat színezése az adott verifikációs index előforduló terjedelmétől függ, pirostól zöldig terjedő skálán a rossz egyezéstől a jó egyezésig. Az 1-es és a 3-as kategória esetén viszonylag jól, és nagyon hasonlóan teljesített mindkét hálózat, a HSS értékek 0,35 körül vagy afölött alakultak, az 1_sigmoid_szimm_RPROP hálózat esetén még 0,46-os HSS indexet is találhatunk az 1-es kategóriára. A 2-es kategória esetén minden indexnél az látható, hogy sokkal rosszabban teljesített mindkét hálózat, mint a másik két kategória esetén. A HSS, POD, ETS 0 körüli értéket vett fel.

Az így kapott eredményeket az 6. fejezetben ismertetett módszerek segítségével számolt felhőalapokra vizsgált indexekkel (3. táblázat) összevetve megállapítható, hogy a neurális hálózat általában pontosabban határozta meg ugyanazon adatokból a felhőalap magasságot, mint a másik 4 módszer. A 2-es kategóriára történő előrejelzés esetén a részecske módszer segítségével számított értékek valamivel meghaladják a neurális hálózat értékeire számított verifikációs indexeket, de a 3-as (tehát a legalacsonyabb felhőzetre vonatkozó kategória esetén) a neurális hálózat értékei jobbnak bizonyultak. Az (1/a), (1/b) és (2) módszerekkel számított felhőalap magasságok esetén az 504 adat egyikén sem jött ki a 2-es kategóriába eső érték.


1. időszakra számított indexek értékei						
1_Gauss_szimm_QUICKPROP 1,4-es és 1,8-as küszöbértékekkel			1_Gauss_szimm_QUICKPROP 1,5-ös és 1,9-es küszöbértékekkel			
	1-es kategória	2-es kategória	3-as kategória	1-es kategória	2-es kategória	3-as kategória
HSS	0,40	-0,04	0,36	0,42	-0,05	0,36
POD	0,31	0,02	0,97	0,34	0,02	0,97
FAR	0,08	0,95	0,25	0,10	0,96	0,25
ETS	0,25	-0,02	0,22	0,27	-0,02	0,22
1_sigmoid_szimm_RPROP 1,4-es és 1,8-as küszöbértékekkel			1_sigmoid_szimm_RPROP 1,5-ös és 1,9-es küszöbértékekkel			
	1-es kategória	2-es kategória	3-as kategória	1-es kategória	2-es kategória	3-as kategória
HSS	0,44	0,03	0,35	0,46	0,03	0,36
POD	0,35	0,06	0,98	0,37	0,06	0,98
FAR	0,09	0,84	0,25	0,09	0,82	0,25
ETS	0,28	0,01	0,21	0,30	0,02	0,22

2. táblázat: Az 1_Gauss_szimm_QUICKPROP és az 1_sigmoid_szimm_RPROP hálózatok eredményeire számított verifikációs indexek értékei az 1. (téli) időszakra különböző küszöbindexekkel (a táblázat színezése az adott verifikációs index előforduló terjedelmétől függ, pirostól zöldig terjedő skálán a rossz egyezéstől a jó egyezésig)


1. időszakra számított indexek értékei						
(1/a) módszer			(1/b) módszer			
	1-es kategória	2-es kategória	3-as kategória	1-es kategória	2-es kategória	3-as kategória
HSS	0,125	---	0,197	0,022	---	0,045
POD	0,836	---	0,415	0,900	---	0,156
FAR	0,726	---	0,161	0,773	---	0,221
ETS	0,067	---	0,109	0,011	---	0,023
(2) módszer			Részecske módszer			
	1-es kategória	2-es kategória	3-as kategória	1-es kategória	2-es kategória	3-as kategória
HSS	-0,002	---	-0,003	0,416	0,038	0,164
POD	0,964	---	0,032	0,345	0,481	0,565
FAR	0,782	---	0,353	0,156	0,873	0,244
ETS	-0,001	---	-0,001	0,263	0,019	0,090

3. táblázat: Különböző módszerekkel meghatározott felhőalapokra számított verifikációs indexek értékei az 1. (téli) időszakra (a táblázat színezése az adott verifikációs index előforduló terjedelmétől függ, pirostól zöldig terjedő skálán a rossz egyezéstől a jó egyezésig)

A következő diagramokon a második időszakra (nyári végi-őszi) figyelhetjük meg a 2_Gauss_szimm_QUICKPROP (8. ábra) és a 2_sigmoid_szimm_RPROP hálózatok (9. 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 megfigyelhető, hogy a 2_sigmoid_szimm_RPROP hálózat jobban leköveti a METAR adatsor értékeit, mint a 2_Gauss_szimm_QUICKPROP, amit a verifikációs indexek értékei is megerősítenek.



8. ábra: A 2_Gauss_szimm_QUICKPROP hálózat által számított felhőalap kategóriák összehasonlítása a METAR-ban található felhőalap kategóriákkal a 2. (nyár végi-őszi) időszakra



9. ábra: A 2_sigmoid_szimm_RPROP hálózat által számított felhőalap kategóriák összehasonlítása a METAR-ban található felhőalap kategóriákkal a 2. (nyár végi-őszi) időszakra

Az eredmények értékelésének folyamata megegyezett az előző esetben leírtakéval. Itt már nagyobb volt az eltérés a két hálózatra számított verifikációs indexek értékei között (4. táblázat). A négy index értékeit figyelembe véve kijelenthető, hogy a 2_sigmoid_szimm_RPROP általában mind a három kategória esetén jobb értékeket szolgáltatott, mint a 2_Gauss_szimm_QUICKPROP hálózat, de a 2-es kategória esetén itt is nagyon rosszak a verifikációs indexek értékei (0 körüli HSS, POD, ETS érték, 1 körüli FAR érték). A 2_sigmoid_szimm_RPROP hálózat esetén az 1-es kategóriához tartozó HSS indexek 0,5 feletti, míg a 2_Gauss_szimm_QUICKPROP hálózat esetén 0,4-es HSS értékek vannak. A másik 4 módszerrel kapott felhőalapokra számított verifikációs index értékeivel összevetve (5. táblázat) a neurális hálózatok eredményeit hasonló

mondható el, mint az előző esetben. A 2-es kategória esetén a részecske módszer verifikációs index értékei optimálisabbak a neurális hálózatokra számolt indexek értékeinél, de az összes többi kategória esetén a neurális hálózat jobban teljesített a többi módszernél.

2. időszakra számított indexek értékei						
2_Gauss_szimm_QUICKPROP 1,4-es és 1,8-as küszöbértékekkel			2_Gauss_szimm_QUICKPROP 1,5-ös és 1,9-es küszöbértékekkel			
	1-es kategória	2-es kategória	3-as kategória	1-es kategória	2-es kategória	3-as kategória
HSS	0,43	-0,03	0,26	0,41	-0,04	0,24
POD	0,78	0,17	0,45	0,83	0,11	0,40
FAR	0,39	0,80	0,42	0,42	0,82	0,42
ETS	0,27	-0,01	0,15	0,25	-0,02	0,13
2_szigmoid_szimm_RPROP 1,4-es és 1,8-as küszöbértékekkel			2_szigmoid_szimm_RPROP 1,5-ös és 1,9-es küszöbértékekkel			
	1-es kategória	2-es kategória	3-as kategória	1-es kategória	2-es kategória	3-as kategória
HSS	0,52	0,04	0,35	0,51	0,05	0,35
POD	0,67	0,15	0,74	0,69	0,18	0,69
FAR	0,26	0,73	0,45	0,29	0,72	0,44
ETS	0,35	0,02	0,21	0,34	0,03	0,21

4. táblázat: A 2_Gauss_szimm_QUICKPROP és a 2_szigmoid_szimm_RPROP hálózatok eredményeire számított verifikációs indexek értékei a 2. (nyár végi-őszi) időszakra (a táblázat színezése az adott verifikációs index előforduló terjedelmétől függ, pirostól zöldig terjedő skálán a rossz egyezéstől a jó egyezésig)

2. időszakra számított indexek értékei						
(1/a) módszer			(1/b) módszer			
	1-es kategória	2-es kategória	3-as kategória	1-es kategória	2-es kategória	3-as kategória
HSS	0,042	---	0,035	0,033	---	0,022
POD	0,996	---	0,053	0,996	---	0,040
FAR	0,587	---	0,429	0,589	---	0,471
ETS	0,021	---	0,018	0,017	---	0,011
(2) módszer			Részecske módszer			
	1-es kategória	2-es kategória	3-as kategória	1-es kategória	2-es kategória	3-as kategória
HSS	0,012	---	-0,026	0,380	0,116	0,004
POD	0,996	---	0,000	0,892	0,432	0,035
FAR	0,596	---	1,000	0,443	0,708	0,600
ETS	0,006	---	-0,013	0,235	0,062	0,002


5. táblázat: Különböző módszerekkel meghatározott felhőalapokra számított verifikációs indexek értékei a 2. (nyár végi-őszi) időszakra (a táblázat színezése az adott verifikációs index előforduló terjedelmétől függ, pirostól zöldig terjedő skálán a rossz egyezéstől a jó egyezésig)

Mivel az eddig bemutatott hálózatok egyike sem mutatott túl jó eredményeket a 2-es kategóriát illetően, ezért most olyan hálózatok eredményeinek ismertetése következik, amelyek mind a három kategória esetén elfogadható értékekkel rendelkeztek. Ilyen hálózatok a 3_Gauss_szimm_RPROP és a 3_szigmoid_szimm_QUICKPROP (6. táblázat). Ezek olyan neurális hálózatok, amelyek outputjai binomiális klasszifikáció segítségével át lettek alakítva, így a modellnek három output értéke volt. A kategorizálás ebben az esetben úgy történt, hogy a maximális érték kiválasztása a három output közül döntött a felhőzet

kategóriáról. A 3_Gauss_sigmoid_QUICKPROP hálózat eredményei jobbnak bizonyultak a második 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. Ezen hálózatok esetén már teljesen szembevetendő, hogy mind a három kategória esetén a neurális hálózat sokkal pontosabb előrejelzést szolgáltatott a másik 4 módszer bármelyikénél. A legjobban ezek közül a részecske módszer teljesített (10. ábra), az 1-es kategória esetén a HSS index értéke megegyezik a 3_Gauss_szimm_RPROP hálózat eredményeire számított HSS indexével, azonban a másik 2 kategória esetén alacsonyabbak a HSS index értékei.

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. táblázat: A 3_Gauss_szimm_RPROP és a 3_sigmoid_szimm_QUICKPROP hálózatok eredményeire számított verifikációs indexek értékei a 2. (nyár végi-őszi) időszakra (a táblázat színezése az adott verifikációs index előforduló terjedelmétől függ, pirostól zöldig terjedő skálán a rossz egyezéstől a jó egyezésig)



10. ábra: A 3_Gauss_szimm_RPROP, 3_sigmoid_szimm_QUICKPROP és a részecske módszer eredményeire számított HSS index értékei a 2. (nyár végi-őszi) időszakra

Az eddigi esetekben jól látszódott, hogy a neurális hálózatok esetén a 2-es és a 3-as kategória elkülönítése jelenti a legnagyobb problémát. A továbbiakban ezt a két kategóriát összevontan kezeljük. Így arról kaphatunk információt, hogy várható-e 1500 láb alatti felhőzet.

A 3_Gauss_szimm_RPROP esetén kifejezetten magas HSS index értékek láthatóak (7. táblázat), mind a két kategória esetén a téli időszakra 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 vizsgált téli időszakra nézve.

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

	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

7. táblázat: A 3_Gauss_szimm_RPROP és a 3_sigmoid_szimm_QUICKPROP hálózatok eredményeire számított verifikációs indexek értékei az 1. (téli) időszakra (a táblázat színezése az adott verifikációs index előforduló terjedelmétől függ, pirostól zöldig terjedő skálán a rossz egyezéstől a jó egyezésig)

Ugyanezen hálózatok a nyár végi-őszi időszakra is vizsgálat alá kerültek. Ebben az időszakban a 3_sigmoid_szimm_QUICKPROP hálózat (8. táblázat) verifikációs indexeinek értékei jobbak voltak, mint a téli időszakban kiemelkedően teljesítő 3_Gauss_szimm_RPROP hálózat index értékei. A 3_sigmoid_szimm_QUICKPROP hálózat esetén a téli és a nyár végi-őszi időszakban is hasonló HSS index értéket kaptunk (a téli időszakra 0,49, nyár végi-őszi időszakra 0,46), csupán 3 százados volt mind a 2 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 esetén (téli időszakra 0,59, nyár végi-őszi időszakra 0,38).


A másik négy módszerrel kalkulált felhőalapra számolt indexekkel összevetve (9. táblázat) megállapítható, a neurális hálózatok jobban teljesítettek ebben az esetben is. A négy módszer közül egyedül a részecske módszerrel számított verifikációs indexek értékei közelítik meg a neurális hálózat eredményeit.

	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

8. táblázat: A 3_Gauss_szimm_RPROP és a 3_sigmoid_szimm_QUICKPROP hálózatok eredményeire számított verifikációs indexek értékei a 2. (nyári végi-őszi) időszakra (a táblázat színezése az adott verifikációs index előforduló terjedelmétől függ, pirostól zöldig terjedő skálán a rossz egyezéstől a jó egyezésig)

	1. időszakra számított indexek értékei				2. időszakra számított indexek értékei			
	(1/a) módszer		(1/b) módszer		(1/a) módszer		(1/b) módszer	
	1-es kategória	2-es kategória	1-es kategória	2-es kategória	1-es kategória	2-es kategória	1-es kategória	2-es kategória
HSS	0,103	0,103	0,011	0,011	0,042	0,042	0,033	0,033
POD	0,825	0,362	0,865	0,159	0,996	0,056	0,996	0,045
FAR	0,744	0,114	0,785	0,185	0,587	0,048	0,589	0,059
ETS	0,054	0,054	0,006	0,006	0,021	0,021	0,017	0,017
	(2) módszer		Részecske módszer		(2) módszer		Részecske módszer	
	1-es kategória	2-es kategória	1-es kategória	2-es kategória	1-es kategória	2-es kategória	1-es kategória	2-es kategória
	HSS	0,001	0,001	0,480	0,480	0,012	0,012	0,380
POD	0,937	0,066	0,429	0,970	0,996	0,019	0,892	0,526
FAR	0,789	0,205	0,206	0,136	0,596	0,125	0,443	0,121
ETS	0,004	0,004	0,316	0,316	0,006	0,006	0,235	0,235

9. táblázat: Különböző módszerekkel meghatározott felhőalapokra számított verifikációs indexek értékei az 1. és a 2. időszakra (a táblázat színezése az adott verifikációs index előforduló terjedelmétől függ, pirostól zöldig terjedő skálán a rossz egyezéstől a jó egyezésig)



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

A 2-es és a 3-as kategória összevonása esetén is a 4 összehasonlító módszer közül a részecske módszer teljesített a legjobban. A HSS és ETS indexekre kapott értékei az első időszak során körülbelül 0,1-el maradtak el a 3_Gauss_szimm_RPROP hálózatétól (11. ábra), a 3_sigmoid_szimm_QUICKPROP hálózatéval pedig közel megegyeztek az értékei. 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 hálózatéval 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.

7.2. Előreccsatolt hálózatok

A kutatás során az előbbi alfejezetben ismertetett hálózatok közül a legjobb teljesítményt nyújtók előreccsatolt változatainak is megvizsgáltuk a teljesítményét. Az előreccsatolás ebben az esetben azt jelenti, hogy a bemeneti és a kimeneti rétegek között közvetlenül is van adatáramlás, és az ezekhez tartozó súlyok is változnak a tanulási folyamat során.

Ilyen hálózatok voltak a 3_szigmoid_szimm_QUICKPROP és a 3_Gauss_szimm_RPROP hálózatok. Ez a két hálózat teljesített jól a két-, illetve a három kategóriára történő előrejelzés során, ezen kívül a két különböző időszakban is viszonylag egyenletesen teljesítettek.

A 2. időszakra megvizsgálva a verifikációs indexek értékeit (10. táblázat) azt tapasztaltuk, hogy a 3_Gauss_szimm_RPROP hálózatnál mind a három kategória esetén romlottak az indexek értékei, tehát még távolabb került az értékük az egyes indexekre jellemző ideális értéktől. Ez a romlás igencsak jelentősnek mondható, hiszen a HSS index értékeiben az 1-es és a 3-as kategória esetén körülbelül 1 tizedet esett vissza az index értéke, a 2-es kategória esetén ez a visszaesés két tizedes nagyságrendű volt. A 3_szigmoid_szimm_QUICKPROP hálózat esetén az 1-es és a 3-as kategóriára számított indexek értékeiben némi javulás látható a legtöbb esetben, a HSS index értéke 5 százados javulást mutatott, még a 2-es kategória esetén itt is romlottak az indexek értékei az előreccsatolást követően.

2. időszakra számított indexek értékei						
Eredeti hálózat eredményei			Előreccsatolt hálózat eredményei			
3_Gauss_szimm_RPROP a maximum értékeket véve			3_Gauss_szimm_RPROP a maximum értékeket véve			
	1-es kategória	2-es kategória	3-as kategória	1-es kategória	2-es kategória	3-as kategória
HSS	0,38	0,20	0,22	0,28	0,00	0,13
POD	0,94	0,27	0,31	0,92	0,10	0,25
FAR	0,45	0,56	0,37	0,49	0,78	0,46
ETS	0,24	0,11	0,12	0,16	0,00	0,07
3_szigmoid_szimm_QUICKPROP a maximum értékeket véve			3_szigmoid_szimm_QUICKPROP a maximum értékeket véve			
	1-es kategória	2-es kategória	3-as kategória	1-es kategória	2-es kategória	3-as kategória
HSS	0,46	0,24	0,25	0,51	0,06	0,31
POD	0,89	0,38	0,36	0,92	0,07	0,57
FAR	0,39	0,58	0,37	0,37	0,57	0,43
ETS	0,30	0,14	0,14	0,34	0,03	0,18

10. táblázat: A 3_Gauss_szimm_RPROP és a 3_szigmoid_szimm_QUICKPROP hálózatok eredményeire számított verifikációs indexek értékei a 2. (nyár végi-ősz) időszakra (a táblázat színezése kifejezi, hogy az eredeti vagy az előreccsatolt hálózat eredményei az optimálisabbak, a zöld szín jelöli az optimálisabb, a piros pedig a rosszabb eredményt)


Ezután tekintsük a 2-es és a 3-es kategória összevonásával kapott eredményeket szintén a feljebb említett két hálózat esetén (11. táblázat). Mind a két hálózat értékeit megvizsgálva elmondható, hogy a két időszak során hasonlóan javultak, illetve romlottak a verifikációs indexek értékei az előreccsatolást követően. A téli és a nyár végi-őszi időszak esetén is ugyanaz figyelhető meg mind a két hálózat esetében, mint amikor három kategóriára történt az előrejelzés. Tehát a 3_Gauss_szimm_RPROP hálózat esetén az előreccsatolás mind a két kategória esetén romló tendenciát mutatott. Ez a romlás az 1. időszak során igencsak jelentős volt, a HSS és az ETS index értékei vizsgálata során 2-3 tizedes visszaesés figyelhető meg. Ezzel szemben a 3_sigmoid_szimm_QUICKPROP hálózatnál az előreccsatolás javuló tendenciát mutatott mind a két időszak során mind a négy verifikációs index értékében. Mind a két időszak esetén a HSS és az ETS index értékében is körülbelül 5 százalós javulás látható.

1. időszakra számított indexek értékei				
Eredeti hálózat eredményei			Előreccsatolt hálózat eredményei	
3_Gauss_szimm_RPROP a maximum értékeket			3_Gauss_szimm_RPROP a maximum értékeket	
	1-es kategória	2-es kategória	1-es kategória	2-es kategória
HSS	0,59	0,59	0,31	0,31
POD	0,61	0,94	0,51	0,82
FAR	0,26	0,10	0,56	0,14
ETS	0,42	0,42	0,19	0,19
3_sigmoid_szimm_QUICKPROP a maximum			3_sigmoid_szimm_QUICKPROP a maximum	
	1-es kategória	2-es kategória	1-es kategória	2-es kategória
HSS	0,49	0,49	0,54	0,54
POD	0,56	0,91	0,61	0,92
FAR	0,37	0,11	0,34	0,10
ETS	0,32	0,32	0,37	0,37
2. időszakra számított indexek értékei				
Eredeti hálózat eredményei			Előreccsatolt hálózat eredményei	
3_Gauss_szimm_RPROP a maximum értékeket			3_Gauss_szimm_RPROP a maximum értékeket	
	1-es kategória	2-es kategória	1-es kategória	2-es kategória
HSS	0,38	0,38	0,28	0,28
POD	0,94	0,49	0,92	0,40
FAR	0,45	0,08	0,49	0,12
ETS	0,24	0,24	0,16	0,16
3_sigmoid_szimm_QUICKPROP a maximum			3_sigmoid_szimm_QUICKPROP a maximum	
	1-es kategória	2-es kategória	1-es kategória	2-es kategória
HSS	0,46	0,46	0,51	0,51
POD	0,89	0,61	0,92	0,64
FAR	0,39	0,11	0,37	0,08
ETS	0,30	0,30	0,34	0,34

11. táblázat: A 3_Gauss_szimm_RPROP és a 3_sigmoid_szimm_QUICKPROP hálózatok eredményeire számított verifikációs indexek értékei mind a két vizsgált időszakra (a táblázat színezése kifejezi, hogy az eredeti vagy az előreccsatolt hálózat eredményei az optimálisabbak, a zöld szín jelöli az optimálisabb, a piros pedig a rosszabb eredményt)


7.3. Érzékenységvizsgálat a küszöbértékek variálásával

A 4_szigmoid_szimm_RPROP hálózat tanuladatsorában két kategória szerepelt. Az 1-es az 1500 láb feletti felhőzet, a 2-es pedig az ez alatti felhőzetre vonatkozott. A verifikációs indexek kalkulálása során nem konkrét küszöbértékekre történt a számítás, hanem a verifikációs indexek értékeinek a küszöbérték megválasztásától való függését szeretnénk volna megvizsgálni. Jól látható, hogy a téli időszakban (12. ábra) a neurális hálózat által szolgáltatott értékek viszonylag jól közelítették a METAR-ban található felhőzetinformációból származó kategória értékét.




12. ábra: A 4_szigmoid_szimm_RPROP hálózat által számított felhőalap kategóriák összehasonlítása a METAR-ban található felhőalap kategóriákkal az 1. (téli) időszakra

A küszöbértékek variálása során az ETS és a HSS indexek kerültek vizsgálat alá (13. ábra). Látható, hogy a két index értékei hasonló tendenciát mutatnak a küszöbértékek függvényében. A maximum értéküket is ugyanannál a küszöbértéknél veszik fel. Ez mindkét index esetén körülbelül 1,2-nél (teljesen pontosan 1,199-nél) található. Itt a HSS index értéke 0,33 körüli, és az ETS index értéke 0,2 körüli.




13. ábra: A 4_sigmoid_szimm_RPROP hálózat eredményeire számított HSS és ETS index értékei az 1. (téli) időszakra a küszöbérték megválasztásától függően

A második időszakra számított értékek is vizsgálat alá kerültek. A 4_sigmoid_szimm_RPROP hálózat ebben az időszakban jobban lekövette a felhőzet alakulását (14. ábra), mint a téli időszakban, amelyet a verifikációs indexek is alátámasztottak.



14. ábra: A 4_sigmoid_szimm_RPROP hálózat által számított felhőalap kategóriák összehasonlítása a METAR-ban található felhőalap kategóriákkal a 2. (nyár végi-ősz) időszakra

A verifikációs indexek értékeit szemléltető grafikonon szembevetve (15. ábra), hogy az indexek értékeinek a küszöbértékektől való függésének tendenciája teljesen eltérően alakult a téli 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 pedig már 0,4 feletti értéke volt. Ebből is látszik, hogy az eredmények értékelésekor mennyire sok múlik a küszöbértékek megválasztásán is.



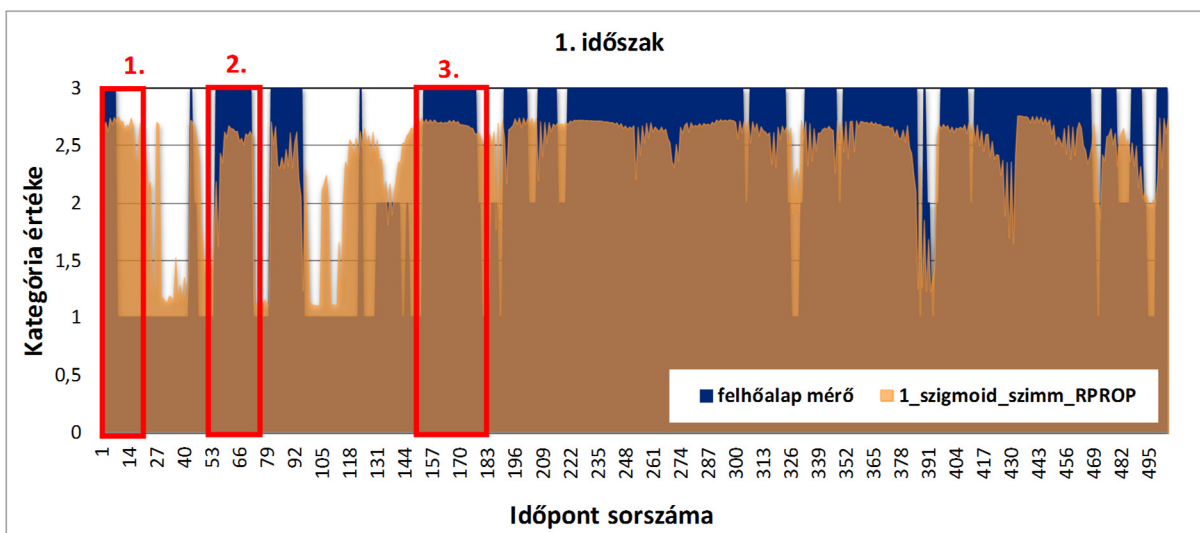
15. ábra: A 4_sigmoid_szimm_RPROP hálózat eredményeire számított HSS és ETS index értékei a 2.(nyár végi-ősz) időszakra a küszöbérték megválasztásától függően

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-del volt magasabb, ezért általánosságban elmondható, hogy ez a hálózat a nyári időszak során jobban teljesített.

8. Esettanulmány

8.1. Téli időszak

Az esettanulmány során az első (téli) időszakból három rövidebb időszakot emelnék ki, amikor a neurális hálózat előrejelzése kiemelkedően jól, illetve rosszabbul teljesített (16. ábra).



16. ábra: Az 1_sigmoid_szimm_RPROP hálózat által számított felhőalap kategóriák összehasonlítása a felhőalap mérőből kategorizált értékekkel az 1. (téli) időszakra, és a részletesebben vizsgált három időszak feltüntetése

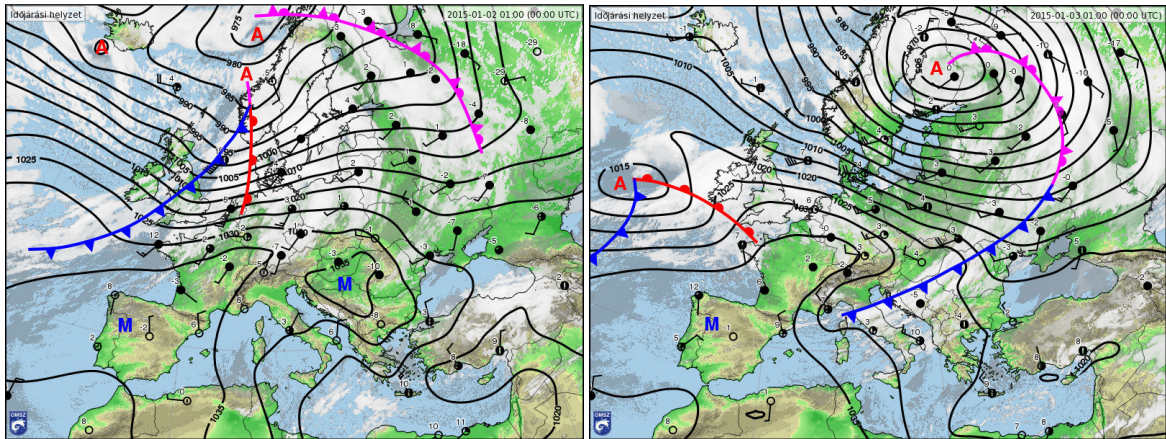
1. időszak (2015. január 2. 4:00 – 2015. január 2. 21:00):

Ennek a vizsgált időszaknak az első pár időpontjában jellemzően 3-as kategóriájú felhőalapot detektált mérő, amely hirtelen 8–9 óra között 1-es kategóriára váltott (16. ábra). A neurális hálózat a 3-as kategóriájú felhőalapot jól előrejelezte, viszont az 1-es kategóriára történő leugrás nem látszódik a kalkulált eredményekben, hanem még körülbelül 12 órán keresztül viszonylag magas, 2,5 feletti értékeket adott (12. táblázat).

Európa északi és északi-nyugati területein ciklonok alakították az időjárást. A Kárpát-medence felett magasnyomású anticiklon uralkodott a közelgő, a nap második felében átvonuló hidegfront érkezéséig (17. ábra).

Hazánk területén aznap jellemzően borult volt az idő, a Dunántúlon átmenetileg felszakadozott a felhőzet, még a középső és keleti területeken maradtak párásabb, ködösebb foltok is.

Ebben az időjárási helyzetben tehát jól teljesített a neurális hálózat a 3-as kategória előrejelzését tekintve, viszont az 1-es kategóriájú felhőzet megjelenésének időpontját csak késve jelezte előre.



17. ábra: Európai időjárás helyzetkép 00 UTC-kor, 2015.01.02. (bal) és 2015.01.03.(jobb) napokon (forrás: OMSZ)

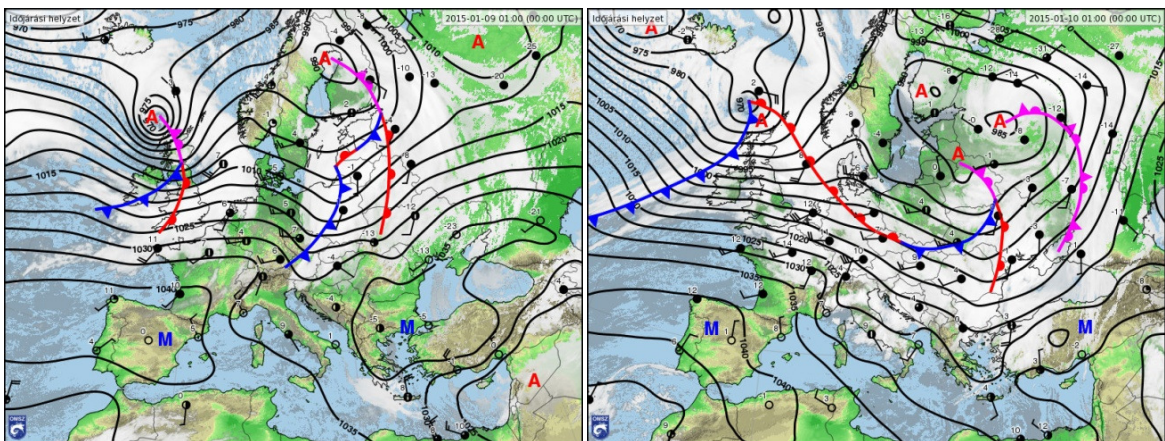
január 2. 4:00-19:00	4:00	5:00	7:00	8:00	9:00	10:00	13:00	14:00	19:00
felhőalap mérő	3	3	3	3	1	1	1	1	1
neurális hálózat	2,70	2,71	2,75	2,75	2,76	2,72	2,72	2,68	2,75

12. táblázat: A felhőalap mérő által mért értékek és a neurális hálózat kalkulált értékei január 2-án 4:00 és 19:00 között (a táblázat színezése kifejezi az egyezés milyenségét, zöld szín jelöli a jó egyezést, piros szín pedig a rossz egyezést)

2. időszak (2015. január 9. 19:00 – 2015. január 10. 10:00):

Ebben az időszakban a mérő hirtelen az 1-es kategóriáról 3-asra ugrott január 9-én este, majd 10-én délelőtt vissza 1-esre. A neurális hálózatnak ezeket a változásokat nagyon pontosan sikerült lekövetnie (16. ábra).

Európa északi és középső területeinek időjárását ciklonok alakították. A Kárpát-medence időjárását ezeknek a ciklonoknak az átvonuló frontjai határozták meg (18. ábra).



18. ábra: Európai időjárás helyzetkép 00 UTC-kor, 2015.01.09. (bal) és 2015.01.10.(jobb) napokon (forrás: OMSZ)

Magyarországon január 9-én estétől egyre több helyen eleredt az eső egy átvonuló melegfrontnak köszönhetően. Másnap reggel még az ország nagyobb részén esett az eső, majd nyugat felől elkezdett szakadozni a felhőzet. Ebben az időjárás helyzetben a neurális

hálózat kellően pontosan előrejelezte a 3-as kategóriájú felhőzetet (13. táblázat)

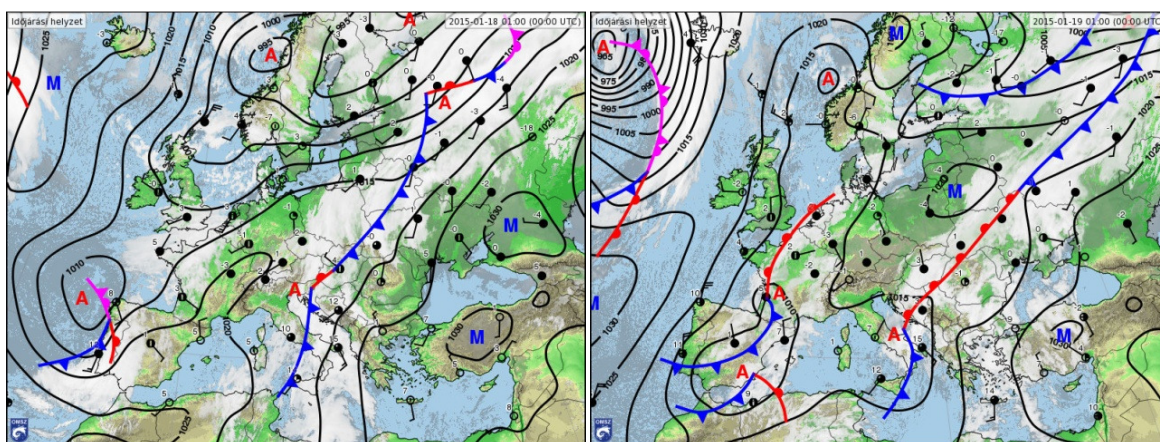
január 9. 19:00- január 10. 10:00	19:00	22:00	23:00	1:00	6:00	7:00	8:00	9:00	10:00
felhőalap mérő	3	3	3	3	3	3	3	3	3
neurális hálózat	2,19	2,44	2,63	2,68	2,65	2,63	2,57	2,61	2,63

13. táblázat: A felhőalap mérő által mért értékek és a neurális hálózat kalkulált értékei január 9-én 19:00 és január 10-én 10:00 között (a táblázat színezése kifejezi az egyezés milyenségét, zöld szín jelöli a jó egyezést, piros szín pedig a rossz egyezést)

3. időszak (2015. január 19. 01:00 – 2015. január 19. 16:00):

Ez egy olyan időszak volt, amikor a mérő 3-as kategóriát mért a nap folyamán szinte végig délután 4 óráig (16. ábra). A neurális hálózat viszont nem jól jelezte előre ennek a 3-as kategóriájú felhőzetnek a megjelenésének és az eltűnésének az időpontját, így a neurális hálózat hosszabb időre jelzett előre 3-as kategóriájú felhőzetet, mint amennyi ideig valójában volt (14. táblázat).

Izland, az Ibériai-félsziget és a Kelet-európai-síkság területén is ciklonok határozták meg az időjárást. A kontinens északkeleti részén található középponttal rendelkező ciklon, hullámzó frontálzónája egészen Olaszország déli részéig húzódott, a Kárpát-medence időjárását is ez a hullámzó front határozta meg (19. ábra).



19. ábra: Európai időjárás helyzetkép 00 UTC-kor, 2015.01.18. (bal) és 2015.01.19. (jobb) napokon (forrás: OMSZ)

Hazánkban egész nap borult idő volt a jellemző, csupán északnyugaton szakadozott fel kis időre a felhőzet. A csapadéközóna a nap folyamán egyre inkább kelet felé tolódott. A felhőzet 3-as kategóriába való kerülését a már fentebb is említett hullámzó front átvonulása okozta.


A neurális hálózatnak sikerült a 3-as kategóriájú felhőzetet előrejelezni ebben az esetben, a megjelenésének és eltűnésének időpontját viszont pontatlanul jelezte előre (14. táblázat).

január 19. 0:00-20:00	0:00	1:00	3:00	5:00	7:00	9:00	11:00	13:00	14:00	16:00	20:00
felhőalap mérő	1	3	3	3	3	3	3	3	2	1	1
neurális hálózat	2,70	2,70	2,71	2,71	2,73	2,72	2,68	2,61	2,61	2,44	2,52

14. táblázat: A felhőalap mérő által mért értékek és a neurális hálózat kalkulált értékei január 19-én 00:00 és 20:00 között (a táblázat színezése kifejezi az egyezés milyenségét, zöld szín jelöli a jó egyezést, piros szín pedig a rossz egyezést)

8.2. Nyár végi-őszi időszak

Ebből az időszakból két rövidebb időszak időjárását ismertetem a következőkben részletesen (20. ábra).



20. ábra: Az 2_sigmoid_szimm_RPROP hálózat által számított felhőalap kategóriák összehasonlítása a METAR-ban található felhőalap kategóriákkal a 2. (téli) időszakra, és a részletesebben vizsgált három időszak feltüntetése

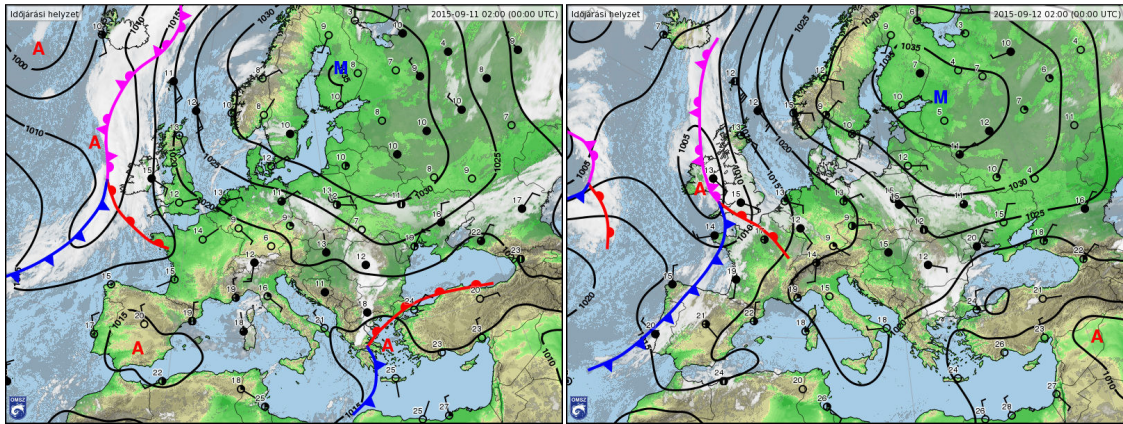
4. időszak (2015. szeptember 11. 04:00 – 2015. szeptember 12. 06:00)

A mérő ebben a körülbelül 1 napos időszakban nagyrészt 3-as kategóriájú felhőzetet detektált (20. ábra). A neurális hálózatnak sikerült jól lekövetnie nagyjából ennek a felhőzetnek a kialakulását és eltűnését.

Nyugat-Európa időjárását egy ciklon alakította. Ezzel szemben a kontinens nagy része felett egy anticiklon helyezkedett el (21. ábra). A Kárpát-medence ennek az anticiklonnak a déli peremén helyezkedett el, nedves légtömegek voltak a jellemzőek, amelyek a 3-as kategóriájú felhőzet megjelenését segítették elő.

Ezen a napon hazánkban borult idő volt a jellemző, több helyen az eső is eleredt. Majd 12-én éjfélétől egyre szárazabb levegő érkezett a Kárpát-medence fölé, így ez a borultság egyre kevésbé volt meghatározó, emiatt is válhatott a felhőzet 1-es kategóriára.

Ezt a helyzetet a neurális hálózat viszonylag jól előrejelezte, csupán a 2-es és a 3-as kategóriát nem tudta megfelelően elkülöníteni (15. táblázat).



21. ábra: Európai időjárási helyzetkép 00 UTC-kor, 2015.09.11. (bal) és 2015.09.12.(jobb) napokon (forrás: OMSZ)

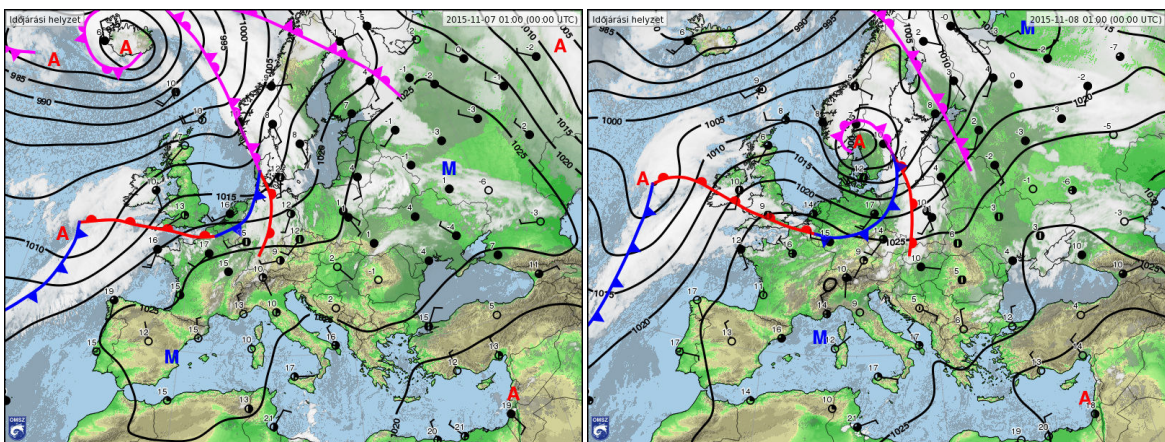
szept. 11. 4:00- szept. 12. 6:00	4:00	6:00	8:00	10:00	14:00	16:00	21:00	23:00	0:00	2:00	4:00	6:00	7:00
felhőalap mérő	2	3	3	3	3	2	3	2	2	2	2	2	1
neurális hálózat	2,12	2,00	1,99	1,81	1,09	1,91	2,13	1,81	2,06	2,16	2,14	2,11	2,22

15. táblázat: A felhőalap mérő által mért értékek és a neurális hálózat kalkulált értékei szeptember 11-én 4:00 és szeptember 12-én 6:00 között (a táblázat színezése kifejezi az egyezés milyenségét, zöld szín jelöli a jó egyezést, piros szín pedig a rossz egyezést)

5. időszak (2015. november 7. 17:00 – 2015. november 8. 7:00)

Ez egy olyan helyzet volt, amikor a mérő által mért 3-as kategóriájú felhőalapot a neurális hálózat lekövette, csupán időbeli pár órás elcsúszás volt, azaz a neurális hálózat pár órával későbbre jelezte előre az 1500 lábnál alacsonyabb felhőalap megjelenését (20. ábra).

Európa nagy részének időjárását egy nagy kiterjedésű anticiklon határozta meg (22. ábra). Ettől nyugatra ciklonok alakították az időjárást. A Kárpát-medence eleinte ennek a nagy kiterjedésű anticiklonnak a területén helyezkedett el, majd a kelet felé haladó ciklonok frontjai súrolták.



22. ábra: Európai időjárási helyzetkép 00 UTC-kor, 2015.11.07. (bal) és 2015.11.08.(jobb) napokon (forrás: OMSZ)

A késő ősszel kialakult anticiklonnak köszönhetően ezen a napon főként borult, párás, ködös időjárás volt a jellemző Magyarország területén, majd a gyenge, súroló frontok szintén felhős időt okoztak.

A neurális hálózat kalkulált értékeiből jól látható, hogy a hálózat a 3-as kategóriájú felhőzetet előrejelezte az időszak végére, viszont 7–8 órás késéssel (16. táblázat)

nov. 7. 17:00- nov. 8. 6:00	17:00	18:00	19:00	20:00	21:00	22:00	23:00	0:00	1:00	2:00	3:00	4:00	5:00	6:00
felhőalap mérő	2	2	2	3	3	3	3	3	3	3	3	3	3	3
neurális hálózat	0,95	0,99	1,04	1,08	1,03	1,00	1,09	1,54	2,07	2,29	2,36	2,41	2,43	2,41

16. táblázat: A felhőalap mérő által mért értékek és a neurális hálózat kalkulált értékei november 7-én 17:00 és november 8-án 6:00 között (a táblázat színezése kifejezi az egyezés milyenségét, zöld szín jelöli a jó egyezést, piros szín pedig a rossz egyezést)

8. Összefoglalás

Összességében kijelenthető, hogy a neurális hálózat által szolgáltatott értékek mindig jobban közelítették a valóságot, mint a szakirodalomban fellelhető módszerek által 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 akár a nyers előrejelzésen is javítani. Elmondható, hogy a legtöbb általunk vizsgált hálózat egészen pontos információt adott a felhözetre vonatkozóan. A diagramokon látható volt, hogy a neurális hálózat képes lekövetni a felhőzet időbeli változását, és tendenciájában képes volt megfogni alacsonyabb szintű felhőzet jelenlétét.

A különböző topológiával rendelkező, eltérő tanulási algoritmust és aktivációs függvényt alkalmazó neurális hálózatok vizsgálatokor kiderült, hogy a két különböző vizsgált időszakban más-más hálózat teljesített jobban, illetve rosszabbul. A három különböző kategóriára történt számítás esetén a 3_szigmoid_szimm_QUICKPROP hálózat bizonyult a legjobbnak, de ez is főként csak a nyár végi-őszi 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 hálózat 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 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_szigmoid_szimm_QUICKPROP hálózat is, amely mind a két időszak esetén viszonylag jól és egyenletesen teljesített. Az eredmények azt mutatják, hogy általánosságban azok a hálózatok teljesítettek a legjobban, amelyek outputjait binomiális klasszifikációval átalakítottuk. Ez azt a szakirodalomban fellelhető ténytet támasztja alá, hogy a neurális hálózat számára a csoportosítás pontosabban elvégezhető feladat, mint konkrét számértékek kalkulálása. Megemlítendő, hogy ebben az esetben az értékek 0 és 1 közé történő átszámításához sem kell egyéb módszert bevetni, hiszen a

binomiális klasszifikációval az outputok értékei 0 és 1 közé esnek.

A 4_sigmoid_szimm_RPROP hálózat működését részletesebben is megvizsgáltuk, így kiderült, hogy a verifikációs indexek értékei erősen függenek a kategóriák szétválasztásához használt küszöbértékektől. E küszöbértékek vizsgálatokor 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 kaptunk, addig a nyári időszakban ugyanez a görbe egy hirtelen felfutást, majd egyenletes leívelést mutatott. Ebből látszik, hogy nem érdemes egy állandó küszöbértéket megválasztani, hanem egy évszaktól függő küszöbérték használata jobb előrejelzéseket eredményez.

9. Köszönetnyilvánítás

Köszönet illeti Kardos Pétert munkám folyamatos irányításáért és figyelemmel kíséréseért. Köszönöm, hogy bevezetett a neurális hálózatok és a PHP programozási nyelv világába, és hogy szaktudásával és építő tanácsaival támogatta a dolgozat létrejöttét. Ezen kívül szeretném még megköszönni neki a jó hangulatban telt konzultációs alkalmakat és a folyamatos biztatást és támogatást, ami nagyban hozzájárult a dolgozat elkészüléséhez.

Nagyon köszönöm dr. Breuer Hajnalkának az építő javaslatait, a rengeteg segítséget és a felmerülő problémáim szinte azonnal történő megoldását. Köszönöm még neki, hogy az egyetemi éveim alatt végig támogatott, minden vizsgám előtt biztatott és türelmesen meghallgatta az aggodalmaimat, minden határidőre figyelmeztetett, és hogy mindig lehetett rá számítani. Nem tudok elég hálás lenni azért a rengeteg időért és türelemért, amit ezekben az években kaptam tőle.

Az adatokért köszönet Gyöngyösi András Zénónak és a GINOP-2.3.2-15-2016-00007 azonosító számú „A légitözlekedés-biztonsághoz kapcsolódó interdiszciplináris tudományos potenciál növelése és integrálása a nemzetközi kutatás-fejlesztési hálózatba a Nemzeti Közzolgálati Egyetemen (VOLARE)” című projektnek.

A diplomamunka írást megelőző nyári gyakorlat biztosításáért köszönet illeti a HungaroControl Zrt.-t és dolgozóit, akik szakmailag hasznossá tették az ott töltött hat hetet.

Ezen kívül szeretnék köszönetet mondani Boginak, aki a mindennapjaim szórakoztatásáért felelt és rengeteg kérdésével mindig sikerült néhány perces kikapcsolódást biztosítania a diplomamunka írás közben.

Köszönöm Janinak a szakirodalmi cikkeket, amiket megosztott velem, illetve a nyári gyakorlaton eltöltött felejthetetlen perceket.

Jaffa lovam folyamatosan gondozásáért és ápolgatásáért köszönettel tartozom Elbert Józsefnek, aki helyettem is foglalkozott a velem, amikor nekem már nem jutott rá idő az egyéb kötelességeim miatt.

Köszönettel tartozom még barátaimnak, akik az egyetemi évek alatt gondoskodtak a megfelelő kikapcsolódásért, meghallgatták minden örömet és bánatomat egyaránt, és végig lelkesen biztattak a nehezebb időszakokban is.

Végül, de nem utolsó sorban szeretném megköszönni családomnak a tanulmányaim során nyújtott folyamatos támogatást és türelmüket.

10. Irodalomjegyzék

- Abhishek, K., Kumar, A., Ranjan, R., Kumar, S., 2012: A Rainfall Prediction Model using Artificial Neural Network, IEEE Control and System Graduate Research Colloquium (ICSGRC 2012), 82-87.
- Altrichter, M., Horváth, G., Pataki, B., Strausz, Gy., Takács, G., Valyon, J., 2006: Neurális hálózatok, Hungarian Edition Panem Könyvkiadó Kft., Budapest, 433 p.
- Black, J.L., Bateman, R.E., Herzegh, P.H., Wiener, G., Cowie, J., Kessinger, C.J., 2008: An Automated National-Scale Ceiling and Visibility Forecast System: Development Progress, 13th Conference on Aviation, Range and Aerospace Meteorology, American Meteorological Society, New Orleans, LA, US
- 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.
- Bremnes, J.B., Michaelides, S.C., 2007: Probabilistic visibility forecasting using neural networks, Pure and Applied Geophysics, 164, 1365–1381.
- Campolo, M., Andreussi, P., Soldati, A., 1999: River flood forecasting with a neural network model, Water Resources Research, Vol. 35, No. 4, 1991-1997.
- 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.
- Comrie, A.C., 1997: Comparing Neural Networks and Regression Models for Ozone Forecasting, Journal of the Air & Waste Management Association, 47:6, 653-663.
- 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.
- Dawson, C.W., Wilby, R., 1998: An artificial neural network approach to rainfall-runoff modelling, Hydrological Sciences Journal, 43:1, 47-66.
- 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.
- 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.
- Fabbian, D., de Dear, R., Lellyett, S., 2007: Application of Artificial Neural Network Forecasts to Predict Fog at Canberra International Airport. Weather and Forecasting, 22, 372–381.
- Fahlman, S.E., 1988: An empirical study of learning speed in back-propagation networks, Carnegie Mellon University, 19 p.
- Fazekas, I., 2013: Neurális hálózatok, Debreceni Egyetem, Informatikai Kar, Debrecen, 204 p.
- Feng, X., Li, Q., Zhu, Y., Hou, J., Jin, L., Wang, J., 2015: Artificial neural networks forecasting of PM_{2.5} pollution using air mass trajectory based geographic model and wavelet transformation, Atmospheric Environment, 107, 118-128.
- 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, 62-67.

- 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, 264-269.
- Fricke, C., 2017: Látástávolság ultrarövidtávú előrejelzése neurális hálózatok segítségével a Liszt Ferenc Nemzetközi Repülőtéren, Eötvös Loránd Tudományegyetem, 72 p.
- 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.
- 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.
- Götz, G., Rákóczi, F., 1988: A dinamikus meteorológiai alapjai. Tankönyvkiadó, Budapest, 484 p.
- Hall, T., Brooks, H.E., Doswell III, C.A., 1999: Precipitation Forecasting Using a Neural Network, Weather and Forecasting, Vol. 14., 338-345.
- Hanel, R.A., 1961: Determination of Cloud Altitude from a Satellite, Journal of Geophysical Research, Vol. 66, No. 4, 1300.
- Hansen, B., 2007: A Fuzzy Logic-Based Analog Forecasting System for Ceiling and Visibility, Weather and Forecasting, Vol. 22, 1319-1330.
- 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.
- Haykin, S., 1995: Neural networks, A comprehensive foundation, 2nd Edition, Pearson Education, Delhi, 823 p.
- Igel, C., Hüsken, M., 2000: Improving the Rprop Learning Algorithm, Proceedings of the Second International Symposium on Neural Computation, NC'2000, 115–121, ICSC Academic Press
- Johnson, G.P., Lin, F.C., 1995: Hurricane Tracking via Backpropagation Neural Network, IEEE International Conference on Perth, WA, Australia, 4 p.
- 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.
- Kukkonen, J., Partanen, L., Karppinen, A., Ruuskanen, J., Junninen, H., Kolehmainen, M., Niska, H., Dorling, S., Chatterton, T., Foxall, R., Cawley, G., 2003: Extensive evaluation of neural network models for the prediction of NO₂ and PM₁₀ concentrations, compared with a deterministic modelling system and measurements in central Helsinki, Atmospheric Environment, 37, 4539-4550.
- Marzban, C., Leyton, S., Colman, B., 2006: Ceiling and Visibility Forecasts via Neural Networks, Weather and Forecasting, Vol. 22, 466-479.
- Mislan, Haviluddin, Hardwinarto, S., Sumaryono, Aipassa, M., 2015: Rainfall Monthly Prediction Based on Artificial Neural Network: A Case Study in Tenggara Station, East Kalimantan-Indonesia, Procedia Computer Science, 59, 142-151
- Nagy, R., 2014: Új módszerek vizsgálata a légiforgalmi irányításban használatos, látástávolságra vonatkozó döntéstámogató célprognózisok készítésében Budapest Liszt Ferenc Nemzetközi Repülőtéren, Eötvös Loránd Tudományegyetem, 69 p.
- Nurmi, P., 2003: Recommendations on the verification of local weather forecasts. ECMWF Technical Memorandum, 430, 18 p.

- Pasini, A., Pelino, V., Potestá, S., 2001: A neural network model for visibility nowcasting from surface observations: Results and sensitivity to physical input variables, *Journal of Geophysical Research*, Vol. 106, No. D14, 14,951-14,959
- Riedmiller, M., 1994: Rprop -Description and Implementation Details, Technical Report, Institut für Logik, Komplexitat und Deduktionssysteme University of Karlsruhe, 2.
- Rojas, R., 1996: *Neural Networks*, Springer-Verlag, Berlin, 509 p.
- Russo, A., Lind, P.G., Raischel, F., Trigo, R., Mendes, M., 2015: Neural network forecast of daily pollution concentration using optimal meteorological data at synoptic and local scales, *Atmospheric Pollution Research*, 6, 540-549.
- Sándor, V., és Wantuch, F., 2005: *Repülésmeteorológia*, Országos Meteorológiai Szolgálat, Budapest, 272 p.
- Smith, W.L., Platt, C.M.R., 1978: Comparison of Satellite-Deduced Cloud Heights with Indications from Radiosonde and Ground-Based Laser Measurements, *Journal of Applied Meteorology*, Vol. 17, 1796-1802.
- Sözen, A., Arcaklioglu, E., Özalp, M., Caglar, N., 2005: Forecasting based on neural network approach of solar potential in Turkey, *Renewable Energy*, 3 , 1075-1090.
- Tokar, A.S., Johnson, A.P., 1999: Rainfall-runoff modelling using artificial neural networks, *Journal of Hidrologic Engineering*, 4, 232-239.
- 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.
- Wang, K., Zhao, H., Liu, A., Bai, Z., 2009: The Risk Neural Network Based Visibility Forecast, *Fifth International Conference on Natural Computation*, 338–341.
doi:10.1109/ICNC.2009.152 .

Internetes hivatkozások:

http://www.met.hu/idojaras/aktualis_idojaras/napijelentes/