

Eötvös Loránd Tudományegyetem
Földrajz- és Földtudományi Intézet
Meteorológiai Tanszék

Látástávolság ultrarövidtávú előrejelzése neurális hálózatok segítségével a Liszt Ferenc Nemzetközi Repülőtéren

DIPLOMAMUNKA



Készítette:

Fricke Cathy

Meteorológus MSc,

Éghajlat kutató szakirány

Témavezető:

Kardos Péter



HungaroControl

Magyar Légiforgalmi Szolgálat Zrt.

HungaroControl Magyar Légiforgalmi Szolgálat Zrt., FMET csoportvezető

Tanszéki konzulens:

Dr. Pongrácz Rita

ELTE TTK, Meteorológiai Tanszék, egyetemi adjunktus

Budapest, 2017

Tartalomjegyzék

1. Bevezetés	3
2. A látástávolság előrejelzése	5
2.1 A látástávolság előrejelzésének szerepe	5
2.2. A látástávolság fogalmak és a velük kapcsolatos kritériumok.....	6
2.3. A köd mint látástávolságot csökkentő tényező	8
3. Módszerek a látástávolság előrejelzésére	10
3.1. Numerikus módszerek	11
3.2. Statisztikai módszerek	14
3.2.1. Klasszikus módszerek.....	16
3.2.2. A tökéletes prognózis módszere (PP)	18
3.2.3. Modell Output Statisztika (MOS).....	19
3.2.4. Neurális hálózatok	21
4. Neurális hálózatok (Artificial Neural Networks)	23
4.1. A neurális hálózatok alkalmazása a prognosztikai gyakorlatban.....	24
4.2. A neurális hálózatok szoftveres támogatása	27
4.3. Alkalmazott tanítási algoritmusok	28
4.3.1. A hiba-visszaterjesztési (backpropagation) algoritmus	28
4.3.2. RPROP algoritmus.....	32
4.3.3. Quickprop algoritmus	34
4.3.4. SARPROP algoritmus.....	36
5. Adatok és módszer	38
6. Eredmények	42
6.1. A decimális hálózatok	42
6.1.1. A decimális hálózatok prediktorainak hatása az előrejelzésre	42
6.1.2. A decimális hálózat előrejelzéseinek hatásvizsgálata	43
6.2. A kategóriás hálózatok	47
6.2.1. A küszöbindex hatása a kategóriás hálózatok előrejelzésére	47
6.2.2. A kategóriás hálózatok prediktorainak hatása az előrejelzésre.....	49
7. Esettanulmányok.....	52
7.1. Időjárási helyzet 2016. január 8-án	52
7.2. A decimális hálózatok esettanulmánya	57
7.3. A kategóriás hálózatok esettanulmánya	61
Összefoglalás.....	66
Köszönetnyilvánítás	69
Irodalomjegyzék.....	70

1. Bevezetés

A látástávolság nappali fényviszonyok esetén definíció szerint az a legnagyobb távolság, amelyről egy megfelelő nagyságú, felszínközeli objektum felismerhető. A látástávolság éjszaka az a legnagyobb távolság, amelyről egy megközelítőleg 1000 kandela erősségű fényforrás még beazonosítható (ICAO, 2016). A civil légi forgalom folyamatos növekedése minél pontosabb, ám költséghatékonyabb látástávolság előrejelzéseket kíván, ezért számtalan kutatás e témával kapcsolatos igények kielégítését célozza meg. A látástávolság előrejelzéseket a repülésmeteorológusok TAF¹ kódban vagy a METAR² táviratok TREND előrejelzésében juttatják el a felhasználókhoz, azaz a légi társaságokhoz és a légiforgalmi irányítókhoz.

A látástávolság nem áll elő az operatív előrejelző modellek kimeneti paramétereként, csak más prognosztikai változók előrejelzett értékeiből származtatható. Az előrejelző szakemberek a nowcasting során leginkább a tapasztalataikra és a klimatikus ismereteikre hagyatkoznak, mivel a numerikus előrejelző modellek sok esetben nem képesek a felszínközeli kisskálájú folyamatok nedvességi viszonyait megfelelően szimulálni. A modellek felbontásának növelésével és a fizikai parametrizációk finomításával javítható az előrejelzés minősége, de a számítási idő ezzel együtt járó megnövekedése miatt az ultrarövidtávú előrejelzés készítéséhez nem tekinthető a legjobb eszköznek. A statisztikai módszerek kevesebb számítást igényelnek és rövidtávon kifejezetten jól teljesítenek, így ezek alkalmazása terjedt el leginkább a látástávolság előrejelzése során. A neurális hálózat is egy statisztikai modell, amely a légkörben lejátszódó folyamatokra is jellemző nemlineáris kapcsolatok leírására alkalmas. Hazai vonatkozásban Nagy Roland (2014) használta először a neurális hálózatokat látástávolság előrejelzésére, és az általa kapott biztató eredmények arra ösztönöztek minket, hogy további vizsgálatokat folytassunk ezen a területen.

Célkitűzésünk az volt, hogy a hálózatok különböző okokból adódó előrejelzésbeli hiányosságait és erősségeit kitapasztalva a hálózatok lehető legjobb működését érjük el annak érdekében, hogy a modell az operatív előrejelzési gyakorlatban is a szakemberek segítségére legyen a látástávolság nowcastingja során. Elsődleges eredményeinket a Repüléstudományi Konferencián mutattuk be (Fricke és Kardos, 2017), a további vizsgálatok eredményeit viszont a diplomamunkám keretében ismertetem.

¹ Terminal Area Forecast

² Meteorological Actual Report

A 2. fejezetben ismertetem, hogy miért kiemelten fontos a repülésmeteorológiában a látástávolság ultrarövidtávú előrejelzése, illetve, hogy milyen folyamatok határozzák meg a látástávolság alakulását. A 3. fejezetben bemutatom a látástávolság előrejelzésére alkalmazott módszereket. A fejezet keretében kitérek a numerikus módszerekre, de mivel a diplomamunka során is statisztikai módszert alkalmazunk, ezért ezen módszerek ismertetésére helyezem a hangsúlyt. Ezt követi az általam használt módszer, a neurális hálózatok és az egyes algoritmusok leírása (4. fejezetben). Az 5. fejezetben a felhasznált adatokat és a módszertant ismertetem konkrétabban, majd a 6. fejezetben a vizsgálati eredményeinket mutatom be, a 7. fejezetben pedig egy általunk kiválasztott, ködös napon teszteljük az egyes hálózatok előrejelzéseit. Végül összefoglalom a fontosabb eredményeket és levonom a fontosabb konklúziókat.

2. A látástávolság előrejelzése

2.1 A látástávolság előrejelzésének szerepe

A légiforgalmat legjobban befolyásoló meteorológiai tényezők egyike a látástávolság, így előrejelzésének biztonsági és anyagi szempontból is kiemelkedő jelentősége van. Rossz látási viszonyok egy egész nap folyamán fennállhatnak, ami azt jelenti, hogy egy teljes napon keresztül korlátozhatja a repülőtér működését.

Alacsony látástávolság esetén előfordulhat, hogy a repülőgépeknek alternatív repülőteret kell használniuk, amely extra üzemanyag fogyasztással jár (*Wantuch és mtsai.*, 2010). Amennyiben a pilóta a leszállás mellett dönt, az veszélyes szituációt is jelent. Különösen veszélyes a művelet, ha a landolás a látva repülés szabályai szerint (VFR³) történik, azaz a pilóták felelősek a gép biztonságos földet éréséért rossz látási viszonyok alatt. A műszeres leszállító berendezés (ILS⁴) segítségével manapság gyakorlatilag 50 m-es látástávolság mellett is landolhat a repülőgép, amely nagymértékben függetlenítette a légi közlekedést az időjárástól. ILS megközelítést viszont csak olyan repülőgép végezhet, amely a megfelelő felszereltséggel rendelkezik és pilótája a megfelelő képzettséggel rendelkezik. A következő két példán látni fogjuk, hogy baleset a (kevésbé korszerűbb) ILS berendezése mellett is bekövetkezhet és a köddel együtt járó rossz látási viszonyok és az erőteljes jegesedés miatt a repülés látástávolságtól való függése bizonyos mértékben megmarad.

1994. november 22-én egy MD-500-as helikopter Siófok-Kilitiről kitűnő látási viszonyok között indult és Ferihegyre érkezve a helikoptertípusokra előírt éjszakai üzemeltetési időjárási minimumoknál jóval alacsonyabb látástávolsággal szembesült. A helikoptert várakozásra utasították a futópálya foglaltsága miatt, majd a helikopter vezetőkkal megszakadt a kapcsolat, és már csak a roncsokat találták meg. A balesetben mindkét helikopter vezető életét veszítette. A baleset arra vezethető vissza, hogy az ereszkedéssel a VFR repülésből hirtelen műszeres repülésbe (IFR⁵) kellett váltani, ami hosszabb-rövidebb idejű tájékozódási problémát okozott, és mivel a jégtelenítő berendezések sem voltak üzembe helyezve, ezért váratlanul igen intenzíven elkezdődött a hajtómű jegesedése. Ilyen nagyfokú jegesedést önmagában a levegőben lévő vízgőz jég formájában történő kiválása nem okozhatott volna. A jegesedésben a köd játszott jelentős szerepet, mivel az alsó rétegben rengeteg apró átmérőjű folyékony halmazállapotban lévő

³ Visual Flight Rules

⁴ Instrumental Landing System

⁵ Instrument Flight Rules

vízcsepp lebegett, amely a beömlőnyíláson bejutva a kifagyó jég tömegét jelentősen megnövelte, melynek következtében a hajtómű elvesztette teljesítményét (*Bottyán és mtsai.*, 2000).

Egy másik repülőgép szerencsétlenséget is – többek között – a látás hirtelen leromlása okozott 1975. január 15-én. A Berlin Schönefeld repülőtérrel induló repülőgép személyzetét már az út megkezdése előtt és az úton is Férihegy időjárási helyzetének romlásáról tájékoztatták, ennek ellenére a személyzet mégis a ferihegyi leszállás megkísérlése mellett döntött. A repülőtér feletti vastag Stratus felhőzetben adva voltak a feltételek a jegesedéshez. A felhőréteg a magasból ferdén átlátható volt, de belesüllyedve a látástávolság rendkívül gyorsan lecsökkent minden irányban. A repülőgép ILS és radarbevezetés mellett 1300 méterrel a küszöb előtt a földnek csapódott. A feltételezések szerint a katasztrófában jelentős szerepet játszhattak az eljegesedett külső érzékelők hibás adatai, a személyzet térbeli tájékozódási képességének elvesztése és a gép egyensúlyi helyzetének ezekből fakadó végzetes megbomlása. Az adott körülmények közötti látási viszonyokat az MS Flight Simulator X szoftverrel modellezték, amelyből egyértelműen látszódott a felhőbe süllyedés után a látástávolság nagymértékű csökkenése, ami a térbeli tájékozódás elvesztéséhez vezethetett (*Bottyán*, 2008).

A látástávolság előrejelzéseinek javításával a késésekből adódó anyagi veszteség is csökkenthető. Repülőtér túlterheltségét okozza, ha az aktuális kapacitás alacsonyabb, mint a tervezett kapacitás és veszteséget okoz, ha az aktuális kapacitás nagyobb, mint a tervezett. A látástávolság előrejelzésének légi forgalomra gyakorolt hatását jól illusztrálja, hogy 2003-ban a zürichi repülőtéren a látástávolság 1 h-t tévedő reggeli előrejelzése következtében a Swiss International Airlines a nap folyamán összesen 1400 perc késést halmozott fel (*Müller és mtsai.*, 2007).

2.2. A látástávolság fogalmak és a velük kapcsolatos kritériumok

A repülésben különféle látástávolság fogalmat használnak (*Sándor és Wantuch*, 2005):

- meteorológiai (vízszintes) látástávolság (Horizontal visibility, HV).
- Futópálya menti látástávolság (Runway Visual Range, RVR)
- Függőleges látástávolság (Vertical visibility)
- Ferde látástávolság (Slant visibility)

A meteorológiai látástávolságot szinoptikus állomásokon és a repülőtereken részben becsléssel, részben mérésekkel határozzák meg. A látástávolság észlelése nappal a

tereptárgyak, sötétedés után pedig a különböző fényforrások segítségével történik. A horizontális látástávolság kerül megadásra a METAR táviratokban és a TAF-ban. A repülőtéri észlelőknek a horizontális látástávolságot 5 km és 10 km között 1 km-es lépcsőben, 800 m és 5000 m között 100 m-es lépcsőben, 800 m alatt pedig 50 m-es lépcsőben kell megadnia a METAR és a SPECI táviratban. A horizontális látástávolság TAF-táviratba foglalt előrejelzése is ugyanezen lépcsők szerint történik (ICAO, 2016).

Az RVR az a távolság, amelyről a futópálya középvonalán lévő légi jármű vezetője a futópálya felületi jelzéseit, vagy a futópálya szegélyfényeit, illetve a középvonalat jelző fényeket felismeri. A több futópályából álló repülőtereken a nagy kiterjedésből adódóan a látástávolság értéke futópályánként és azok különböző pontjain is eltérő lehet. A személyzetet az a távolság érdekli, amelyről láthatja a futópálya felületén levő jelzéseket és a leszállást segítő fénytechnikai berendezéseket fel- és leszálláskor. Az ICAO ezért bevezette a futópálya menti látástávolság fogalmát. A pilóták számára fontos RVR-t akkor kell táviratban jelenteni, amikor a horizontális látástávolság vagy az RVR, vagy mindkettő értéke 1500 m alá csökken, tehát az RVR táviratban megadott értéke 50 m és 1500 m közötti tartományon belül mozoghat. Az RVR értékét 800 m felett 100 m-es lépcsőben, 400 m és 800 m között 50 m-es, 400 m alatt pedig 25 m-es lépcsőben kell megadnia az észlelőnek. (Sándor és Wantuch, 2005).

A METAR táviratok jelentései között különleges időjárási eseményeket jelentő távirat (SPECI) kiadásának feltétele többek között a látástávolság különböző kritikus értékek átlépése is. SPECI-t akkor is kötelező kiadni, ha a horizontális látástávolság eléri a 800 m, 1500 m, 3000 m, 5000 m-es határt vagy az alá csökken, illetve, ha az RVR értéke eléri a 150 m, 350 m, 600 m vagy 800 m-es határt vagy az alá csökken. A TAF előrejelzést módosító táviratot (Amended TAF) is ugyanezen kritériumok mellett indokolt kiadni (Sándor és Wantuch, 2005).

A Liszt Ferenc Nemzetközi Repülőtéren az ICAO által és a helyi üzemeltetési viszonyok (Reptéri Rend) alapján meghatározott üzemelési fázisok (LVP) lépnek életbe a különböző mértékben romlott látási viszonytól függően:

- Műszeres meteorológiai körülmények (IMC): HV < 5000 m és/vagy a felhőalap < 1500 láb
- Felkészülési fázis (preparation phase) PREP: a HV < 800 m és/vagy a felhőalap < 400 láb
- Üzemelési fázis (Operations phase) LVP-1: futópálya földetérési zónájában az RVR < 600 m és/vagy a felhőalap < 200 láb
- Üzemelési fázis (Operations phase) LVP-2: RVR < 400 m

A PREP fázis életbe lépésével vagy annál rosszabb látási viszonyok alatt a Hungarocontol Zrt. kötelessége a bevezető fénysorhoz tartozó villanó fények bekapcsolása. A PREP fázisban különösebb korlátozások nincsenek érvényben, azonban a munkavégzőket tájékoztatni kell a várható meteorológiai helyzetről. 400 m vagy annál nagyobb RVR esetén a légiforgalmi irányító felelős az útvonal biztosításáért, illetve az elsőbbségi sorrend meghatározásáért, a pilóta felelős a megadott útvonal pontos követéséért. LVP-2 érvényessége esetén pedig kizárólag a légiforgalmi irányító felelős a légi járművek közötti elkülönítés biztosításáért repülőtér munkaterületén.

2.3. A köd mint látástávolságot csökkentő tényező

A látási viszonyok romlását olyan fizikai hatások idézhetik elő, mint például köd, zápor, hózápor, por- és homokvihar stb. Ködről akkor beszélünk, ha a vízgőz kondenzációja a talaj közelében meggy végbe és a látástávolság nem éri el az 1 km-t. A kicsapódáshoz kondenzációs magvak jelenléte és a levegő telítettsége szükséges. A kondenzációs magvak gyakorlatilag mindig elegendő mennyiségben vannak jelen (*Sándor és Wantuch, 2005*), viszont a telítettségre különböző tényezők vannak hatással, amelyek közül a legfontosabbak (*Duynkerke, 1991*):

- hosszúhullámú kisugárzás mértéke,
- különböző hőmérsékletű, telítéshez közel álló légtömeg keveredése,
- növényzettel borítottság,
- horizontális és vertikális szél,
- talaj hő- és nedvességtranszportja,
- advekción,
- orográfia,

Ha a köd már kialakult, akkor az alábbi további hatások befolyásolják a köd tartósságát:

- hosszúhullámú kisugárzás a köd tetején,
- mikrofizika,
- rövidhullámú sugárzás,
- a cseppek gravitációs ülepedése,

A felhőzet hosszúhullámú kisugárzást csökkentő hatása következtében a felhőborítottság szintén meghatározó a ködképződés szempontjából. A felsorolt tényezők nagyrésze általában együttesen járul hozzá a köd képződéséhez, de egyes folyamatok döntő szerepet játszhatnak.

A köd osztályozása is a meghatározó folyamatok szerint történik. A köd képződhet légtömegben belül, illetve frontok területén (*Sándor és Wantuch, 2005*). Légtömegben belül alakul ki a kisugárzási köd, amely során a telítettséget a talajközeli légréteg lehülése idézi elő. Kialakulásának feltételei a talajközeli magas páratartalom, gyenge talajszint közeli szél és derült ég. A megfigyelések alapján sokszor kitűnő látás viszonyokat váltva hirtelen képződik, holott a kisugárzási típusnál a telítődési folyamattól fokozatosságot várnánk el (*Bottyán és mtsai., 2000*). A valóságban előfordul az is, hogy szélcsendben, telítéshez mindvégig közel álló légréteg csak kissé párasodik, a máskor pedig már kisebb nedvességtartalom mellett is köd képződik.

Az inverziós köd anticiklonális időjárási helyzetben jellemző a téli évszakban. Ekkor kezdetben a magasban elhelyezkedő inverziós réteg alatt zárt Stratus képződik, majd a napok múlásával a felszín közelébe ereszkedve tartósan megmaradó hideg légpárnát képezhet. Áramlási köd keletkezik, ha meleg, nagy nedvességtartalmú levegő áramlik hideg felszín fölé. Gyorsan és váratlanul képződik, ezért a légi forgalom szempontjából különösen veszélyes. Frontális köd a talajfront előtt és mögött is képződhet. A frontok előtt a hideg levegőbe hulló viszonylag meleg esőcseppek párolgása okozza a telítettséget, de az is előfordulhat, hogy a melegszeaktor levegője hideg felszín felé kerülve válik telítetté. Máshol kialakult köd áthelyeződése is igen gyakori jelenség és mivel a látástávolság hirtelen csökkenését eredményezi, különösen veszélyes a repülés során (*Sándor és Wantuch, 2005*).

3. Módszerek a látástávolság előrejelzésére

Az elmúlt évtizedekben több ezer köddel kapcsolatos publikáció született, amely azt mutatja, hogy fontos kutatási terület, és sok munkát fektettek a jelenség megismerésére. Ennek ellenére a látástávolság ultrarövid távú előrejelzésének (nowcasting) pontosítása máig további kutatásokra szorul, mivel a mai napig nem létezik olyan, a hazai gyakorlatban alkalmazható eljárás, amely igazán hathatósan segítené az előrejelzők munkáját (Wantuch, 2014). Ennek oka, hogy a repülésmeteorológia szempontjából releváns időjárási paramétert olyan térben és időben változó folyamatok kölcsönhatásai határozzák meg, amelyekre hatással van a mikrofizika, a sugárzás, a turbulencia és a felszíni sajátosságok. Mindezek explicit ismerete viszont máig hiányos (Gultepe és mtsai., 2007). A látástávolság megfelelő pontosságú előrejelzése komoly feladat elé állítja az előrejelző szakembert, hiszen a repülésmeteorológiában az ICAO nemzetközi előírásai szabályozzák ezt a területet (Wantuch, 2014).

A látástávolság becslésének pontatlansága – többek között – abból adódik, hogy nem áll rendelkezésünkre a pontos előrejelzéshez elengedhetetlen térben megfelelően sűrű megfigyelés, amely a köd detektálásának nehézségeiből ered. A műholdképekkel kapcsolatban spektrális csatornától függően különböző korlátozó tényezők lépnek fel. A látható tartományú műholdfelvételek esetében a téli időszakban – amikor rövidek a nappalok – a köd detektálása nem mindig lehetséges, hiszen a köd kialakulásának ideje jó egybeesést mutat a napkelte és a napnyugta körüli időszakokkal (Tuba, 2008). Az infravörös tartományban készült műholdképek esetében ha összefüggő felhőzet található a magasabb szinteken, akkor nem tudjuk detektálni a felszín közelében lejátszódó folyamatokat. A köd emellett láthatatlan maradhat az infravörös tartományban, ha a köd vastagsága nem elegendően nagy ($< 50\text{--}100\text{ m}$) (Gultepe és Ellrod, 2013) vagy ha a hőmérsékleti tartományban a köd felhőtető hőmérséklete megegyezik a felszín hőmérsékletével. Az utóbbi az inverziós felhőzet és a kisugárzási köd esetében elsősorban napkelte vagy napnyugta körül fordulhat elő (Tuba, 2008). Különböző infravörös tartományok kombinációin alapuló algoritmusokkal is kísérleteztek, de ezek éjszakai produktumai esetenként nehezen különítik el a felszín közelében kialakult Stratus-t a magasabb felhőalappal rendelkező Stratus-októl, Stratocumulus-októl és Altostratus-októl, amelyek nincsenek jelentős veszéllyel a repülésre. Ezekre a nehézségekre tekintettel olyan algoritmus kifejlesztésére lenne szükség a köd pontosabb detektálása érdekében, amely több spektrális csatornát használ fel (Ellrod és Gultepe, 2007).

A távérzékelés korlátozó tényezői ellenére különböző térbeli sűrűségű in situ mérések felhasználásával különféle módszereket – numerikus modelleket, illetve statisztikai módszereket – alkalmaznak több-kevesebb sikerrel a látástávolság előrejelzésére.

3.1. Numerikus módszerek

A látástávolság azon időjárási változók közé tartozik, amely alapvetően nem áll elő numerikus előrejelzési modellek output-jaként. A köd numerikus szimulációjához a határréteg hőmérsékletének, nedvességének és szélsébségének majdnem tökéletes előrejelzése, valamint a telített réteg mikrofizikájának pontos leírása lenne szükséges. A szimulációt tovább nehezíti, hogy a hőmérséklet és a páratartalom minimális hibái is drámai hatásokkal vannak az előrejelzésre, ha a levegő telítettséghez közeli állapotban van. Habár vannak olyan helyzetek amikor az előrejelezhetőség könnyebb (magas relatív nedvesség az éjszaka kezdetén, derült ég, gyenge szél) a köd képződésének és feloszlásának pontos idejét még ekkor is nehéz megbecsülni a numerikus szimulációk alapján (*Müller és mtsai.*, 2007).

A numerikus modellek előrejelzésének minőségét a horizontális és vertikális felbontás, illetve a fizikai parametrizáció határozza meg. A durvább felbontású, nagyskálájú modellek más nedvességhez kapcsolódó paraméterhez hasonlóan a felszínközeli magas páratartalom kialakulásának komplexebb folyamatait nem képesek elegendően nagy pontossággal rekonstruálni. A nagyskálájú modellek emellett elhanyagolják vagy egyszerűen konstansnak veszik a csepp koncentrációt (N_d), pedig a köd numerikus modellekkel történő előrejelzése során ennek változása nem elhanyagolható, mivel a látástávolság és az N_d között lineáris kapcsolat áll fenn (*Gultepe és mtsai.*, 2007). A finomabb felbontású numerikus időjárás előrejelző modellek a látástávolság kiszámításához általában a látástávolság és a folyékony víztartalom (LWC^6) közötti kapcsolatot használják. A modell által előrejelzett LWC hibájának minimalizálása rendkívül bonyolult a köd fizikájának pontatlan leírása, a modellek szisztematikus hibája és az operatív modellek alacsony felbontása miatt (*Zhou és mtsai.*, 2012). A felhőcsepp koncentráció egy köbcentiméteren néhány csepptől néhány száz darab között változhat egy adott folyékony víztartalomra vonatkozóan, így olyan parametrizációs sémát is kifejlesztettek, amely során a látástávolságot a cseppkoncentráció (N_d) és a folyékony víztartalom (LWC) függvényében származtatták, és a NOAA nemhidrosztatikus mezoskálájú modelljében alkalmazták (*Gultepe és mtsai.*, 2006). Az eredmények azt mutatták, hogy a látástávolság fizikai parametrizációjának javításához részletes mikrofizikai méréseket végző expedíciók és olyan

⁶ Liquid Water Content

2D-s vagy 3D-s modellek szükségesek, amelyekben a kisskálájú turbulencia és a nukleáció is megfelelő pontossággal van parametrizálva. A 3D-s modellek esetében viszont a nagy számítási igény miatt az egyszerűsítések elkerülhetetlenek az egyes folyamatok parametrizálása során. Mindent összevetve a határréteg pontos kezdeti nedvességi profil ismeretének hiánya, valamint sugárzás, a mikrofizika, a turbulencia és a felszíni folyamatok parametrizációinak pontatlansága miatt a köd determinisztikus előrejelzése nagy kihívást jelentő feladat (*Pagowski és mtsai.*, 2004).

Mivel a köd numerikus előrejelzése különösen érzékeny a kezdeti feltételekre és az alkalmazott fizikai sémákra, így a bizonytalanság számszerűsítésére alkalmas ensemble technikával is kísérleteztek. A különböző kezdeti feltételekkel és különböző modellkonfigurációkkal készült látástávolságra vonatkozó valószínűségi előrejelzést a WMO B08RDP⁷ alatt, majd Észak-Amerikában az NCEP⁸ regionális modelljeivel és ensemble rendszerében alkalmazták és tesztelték. A vizsgálatok azt bizonyították, hogy ha az ensemble mérete elegendően nagy, akkor a felbontás növelésével tovább javítható az előrejelzés (*Zhou és mtsai.*, 2012).

A COST 722 program (*Jacobs és mtsai.*, 2008) során különböző látástávolság előrejelzési módszereket hasonlítottak össze, így különböző 3D-s numerikus modellek által készített előrejelzéseket is összevetettek a megfigyelésekkel három különböző ködös időszakra. A modellezés során a következő problémák merültek fel (*Gultepe és mtsai.*, 2007):

- A durva horizontális és vertikális felbontás miatt az operatív modellek nem képesek a felszín közelében lejátszódó folyamatokat a megfelelő részletességgel szimulálni.
- Finom (néhány méternél kisebb) rácsfelbontás szükséges ahhoz, hogy a köd képződése előtt lejátszódó folyamatok (10 m magasságú inverziós réteg fejlődése) szimulációja is megfelelő legyen.
- Mivel a köd képződését a növényzet horizontális eloszlása is nagyban befolyásolja, ezért a talajnedvességet és a növény-borítottságot is megfelelő részletességgel kell reprezentálni.
- A modellek előrejelzésében a köd képződésének idejét jelentősen befolyásolta a modell inicializációjának időpontja a modellek felpörgési ideje (spin up) miatt.

⁷ 2008 Beijing Olympic Game Research and Demonstration Project

⁸ National Centers for Environmental Prediction

- A modell outputok egy adott területet reprezentálnak, a megfigyelések pedig egy adott pontra vonatkoznak, amely nehezíti a modell verifikálását.

Az 1D-s modellek költséghatékonyabbak és kevesebb számítást igényelnek, segítségükkel a horizontális inhomogenitások elhanyagolása ellenére a köd fizikai folyamatait vizsgálhatjuk. *Bergot és Guedalia* (1994) például 1D-s modellel tanulmányozták a kezdeti nedvességi profil precíz ismeretének fontosságát, mely különösen az este második felében képződő ködök esetében lényeges. Emellett azt is megmutatták, hogy a ködképződés érzékenyen reagál a horizontális advekcióra. Az 1D-s modellekkel történő látástávolság előrejelzés lehetőségei viszont korlátozottak az összetett felszínborítottságú területeken, ahol a térbeli heterogenitás hatásai (például a hegyoldalon lefolyó és a völgyekben felhalmozódó hideg levegő) jelentősen befolyásolják a köd képződés folyamatát.

A COST 722 program során 1D-s modellek előrejelzéseit is összehasonlították (*Jacobs és mtsai.*, 2008) és verifikálták. Az áttekintő tanulmány során megmutatták, hogy az esetek túlnyomó részében az előrejelzések nem voltak megbízhatóak. A modellek pontatlanságának hátterében számos ok áll, amelyekből a legfontosabbak az alábbiak (*Gultepe és mtsai.*, 2007):

- A modell által feltételezett horizontális homogenitás mellett a termodinamikai változók horizontális gradienseinek elhanyagolása nagy hibákat eredményez.
- A felhőzet nincs megfelelően parametrizálva az 1D-s modellekben, a ködképződésben meghatározó szerepet játszó kisugárzás azonban erősen függ a felhőborítottságtól
- A modellek homogénnek tekintik az olyan felszíni tulajdonságokat, mint például a növényzetet, a talajtípust, a talajnedvességet és a talajhőmérsékletet, ezáltal a nedvesség és hőáramok heterogenitása sincs megfelelően reprezentálva.
- A turbulencia sincs megfelelő pontossággal parametrizálva, főleg a ködképződés szempontjából fontos erősen stabil rétegződés esetén.

Az 1D-s modellek homogenitás-feltételezéséből adódó hibáinak kiküszöbölése érdekében 1D-s és 3D-s modellek összekapcsolásával is készítettek látástávolság előrejelzést (*Müller és mtsai.*, 2007), melynek előnye, hogy egy 3D-s modellhez képest kevesebb számítási kapacitást igényel. Mivel a 3D-s modell az 1D-s modell peremfeltételeként szolgált, a modellben nem csak a helyi hatások jelentek meg a szimulációban. Müller és társai (2007) vizsgálataik során megmutatták, hogy a számításbeli nagy különbségek ellenére a csatolt modell valószínűségi előrejelzései a 3D-snél jobbnak

bizonyultak viszonylag egyszerű felszínen. Összetett felszín felett viszont a 3D-s determinisztikus előrejelzés pontosabb volt a csatolt modell előrejelzésénél.

A fentieket összegezve, a látástávolság előrejelzésére tehát fel lehet állítani differenciál-, illetve parciális differenciálegyenleteket, és több országban fejlesztenek jelenleg is ilyen modelleket. Ezek a modellek azonban többnyire nem tudják megfelelően szimulálni a köd fejlődése szempontjából fontos lokális folyamatokat, melyek egy része vagy még nem teljesen megértett folyamat, így nincs megfelelően parametrizálva vagy modellezésük nagyobb számítógépes kapacitásokat igényel (*Wantuch, 2014*). A repülésmeteorológiai gyakorlatban a látástávolság ultrarövidtávú előrejelzése a következő két órára terjedő időszakra történik, amelyre numerikus előrejelzést a nagy számítási igény és a fent említett okok miatt sem szoktak a gyakorlatban használni.

3.2. Statisztikai módszerek

A kutatási eredmények azt mutatják, hogy az egy vagy több dimenziós numerikus modellek szolgáltatta látástávolság előrejelzések még alatta maradnak a statisztikai alapú előrejelzéseknek (*Wantuch, 2014*). A látástávolság nowcastingja során ebből kifolyólag leginkább a statisztikai módszerek alkalmazása terjedt el és több ország, köztük hazánk eredményei is azt bizonyítják, hogy alkalmasak a gyakorlatba történő adaptálásra (*Wantuch, 2014*). Mivel hazánkban a látástávolság előrejelzésére különféle statisztikai módszerek kifejlesztése történt meg és zajlik jelenleg is, ezért e fejezetben leginkább a hazai kutatási eredményekre fókuszálva fogom bemutatni az egyes statisztikai módszereket.


Statisztikai technikák alapvető célja egy bizonyos időjárási elem (prediktandusz) és más időjárási változók (prediktorok) közötti kapcsolat számszerűsítése egy múltbeli időszakra vonatkozó adatbázis alapján. Egy operatív statisztikai előrejelzés fejlesztésének lépései a következők (*WMO CAeM Working Group, 1999*):

- meghatározni az előrejelezni kívánt meteorológiai elemet,
- a módszer kiválasztása és az adatbázis előkészítése,
- a statisztikai kapcsolat feltárása,
- a formula tesztelése a tanuló adatsoron, független adatsoron és esettanulmányokon,
- a formula vagy egyenlet operatív gyakorlatba történő alkalmazása, ha a teszt eredményei pozitívak,
- az előrejelzés utófeldolgozása szükség esetén.

A statisztikai alkalmazások során a minta mérete nagyon fontos mivel a kevés minta instabillá teheti az előrejelző technikát. A statisztikai módszerek meteorológiában történő

alkalmazása során egy reprezentatív mintához legalább 250 eseményre van szükség. A múltbeli adatok felhasználásának előnye és hátránya is van. Előnye, hogy a jelenlegi klimatikus viszonyoknak megfelelő előrejelzéseket készít, mivel a statisztikai kapcsolat közelmúlt mérései alapján van származtatva. A modellek outputjai viszont a felbontástól és a fizikai parametrizációk pontosságától függenek. A múltbeli adatsor felhasználásnak hátránya, hogy csak arra a helyre alkalmazható az előrejelzés, amelynek az adatbázisát felhasználtuk (*WMO CAeM Working Group, 1999*).

A módszerek tesztelése során gyakran az eljárás előrejelzését perzisztencia prognózissal vetik össze. Az esetek nagy részében a perzisztencia prognózis ultrarövidtávon kifejezetten jó becslést ad, mivel két órán belül jellemzően a legutóbbi méréshez közeli értékek várhatók és szignifikáns változás ritkábban történik. A perzisztencia rövidtávon többnyire megbízható előrejelzését reprezentálja, hogy a perzisztencia prognózis beválása képes volt meghaladni egy mezoskálájú operatív modell látástávolság 1-5 órás előrejelzéseit (1. Ábra) (*Porter, 1995*).



1. Ábra: Threat Score MM5 mezoskálájú modell (3 mérföldnél alacsonyabb) látástávolság előrejelzésére és a perzisztencia prognózisra vonatkozó Threat Score verifikációs index 1992. 02. 15-én 0 és 6 UTC között (*Porter, 1995*)
(A Threat Score értéke ideális előrejelzés esetén 1.)

Háromféle statisztikai előrejelzési módszert különböztetünk meg az eljárás által használt adatok forrása szerint (*Jacobs és mtsai., 2008*):

- Klasszikus módszerek: a statisztikai kapcsolat feltárása és a módszer alkalmazása során a numerikus modellek előrejelzéseit nem használják fel, csak a megfigyeléseket. Tehát a prediktorok megfigyelt időjárási elemek, ebből szolgáltatja az előrejelzést is a módszer (*Sándor és Wantuch, 2005*).

- A tökéletes előrejelzés módszere (Perfect Prog – PP): a több időjárási változó modell által előrejelzett értékével becsülünk egy numerikus modell által nem előrejelzett paramétert azt feltételezve, hogy az előrejelzés tökéletes – módszer elnevezése is innen ered.
- Modell Output Statisztika (MOS): az eljárás során a modell output, in situ mérések és klímaadatok is szolgálhatnak prediktorként.

3.2.1. Klasszikus módszerek

A klasszikus módszeren belül általában három további eljárási módot különböztetünk meg (*Wantuch*, 2014):

- analógiás módszer,
- fuzzy algebrás módszer,
- konceptuális modellek.

Az **analógiás módszer** alapelve, hogy egy hasonlósági metrika segítségével megkeresik a jelen időjárási helyzetet jellemző paraméterekhez leginkább hasonlót a rendelkezésre álló adatbázisban, azt feltételezve, hogy hasonló időjárási helyzethez hasonló látástávolság tartozik (*Wantuch és mtsai.*, 2010). Az időjárási helyzet fogalma jelen esetben az időjárási állapothatározók néhány óra folyamatos megfigyelésére terjed ki. Az analógiás módszer előrejelzése többnyire igen rövid időtávon használható fel, mivel az előrejelzés többnyire csak akkor működik, ha a feltételek homogének, vagyis nem várható dinamikai változás a következő időszakban (*Tuba és Bottyán*, 2017). A meteorológiai helyzet szempontjából kiemelkedően fontos paraméterek nagyobb súlyokat kapnak, aminek következtében növelhető a látástávolság előrejelzésének pontossága. Mivel a prognózis múltbeli adatok alapján készül, ezért minél nagyobb a különbség a paraméterek között, annál nagyobb az előrejelzés bizonytalansága.

Wantuch és szerzőtársai (2010) klímaadatokon alapuló analógiás eljárást dolgoztak ki és megmutatták, hogy a klíma adatok is képesek jelentős prognosztikai jellegű információval szolgálni. Az analógiás módszerű klíma előrejelzéseket az Országos Meteorológiai Szolgálatnál operatíván futó látástávolság előrejelző modelljével hasonlították össze az ICAO látástávolság kategóriáira bontva. A módszer által készített előrejelzés hasonló átlagos eltéréseket mutatott a valós látástávolságokhoz képest. Az eredmények azt mutatták, hogy 1 km alatti látástávolság esetén az Országos Meteorológiai Szolgálatnál futó modell jobb eredményt adott, viszont az 1 km feletti látástávolságok esetén, a klíma adatokon alapuló módszer tűnt sikeresebbnek.

A **fuzzy algebrás módszer** előrejelzésben történő felhasználása annak köszönhetően terjedt el, hogy pontatlansággal jellemezhető elemek könnyen kezelhetőségét teszi lehetővé. Innen kapta a módszer a fuzzy elnevezést, mivel jelentése, homályos, elmosódott körvonalú (*Habobács és mtsai.*, 2013). A módszer lényege a fuzzy halmaz, ahol egy ún. tagsági függvény minden elemhez 0 és 1 közötti valós számot rendel. Ha egy halmaz azon elemeihez, amelyek nem részei a halmaznak 0, míg a halmazban szereplő elemekhez 1 egész számot rendelünk a tagsági függvénnyel, akkor egy adott halmazt fuzzy halmazzá képeztünk le.

A nemzetközi szinten is biztató eredményeket mutató fuzzy logikát (*Hansen*, 2007) az analógiás módszer során hasonlóság mértékének meghatározására alkalmazzák. Fuzzy logikán alapuló hasonlóság kereső statisztikai eljárást hazánkban is kifejlesztettek. A prognosztikai modul fő lépései a következők voltak (*Habobács és mtsai.*, 2013):

1. A fuzzy halmazok előállítása a hasonlóság méréséhez.
2. Az esetek (METAR adatbázis) átvizsgálásával analógiák keresése és a hasonló esetek kigyűjtése.
3. Előrejelzés a megadott statisztikák, például a hasonló esetek súlyozott átlagának felhasználásával.

A hasonlóság keresése során 6 órás időszak információi képezik az összehasonlítás tárgyát, melyek az aktuális időpont felé haladva egyre nagyobb súlyt kapnak a művelet során. Az időbeli súlyozás mellett az egyes meteorológiai és az időbeli paraméterek AHP⁹ módszer alkalmazásával a fontosságuknak megfelelő súlyt kapnak (*Tuba és mtsai.*, 2013). Az eredmények azt mutatták, hogy a fuzzy technikával kialakított analógiás módszerek többnyire alkalmasak a látástávolság rövid távú előrejelzésére.

A fuzzy logikán alapuló analógiás módszer hazai tovább fejlesztéséről idén jelent meg egy friss tanulmány (*Tuba és Bottyán*, 2017). Az eljárás az analógiás módszer és a numerikus modellel történő előrejelzést ötvözi (hibrid előrejelzés) annak érdekében, hogy a két eljárás egyenként megjelenő hátrányait ellensúlyozzák (1. táblázat). Az analógiás módszer legnagyobb előnye az, hogy alkalmazása során az időjárási helyzetben bekövetkező váratlan változások esetén lehetőség van az előrejelzés gyors módosítására a fél óra múlva bekövetkező megfigyelés után. A hibrid előrejelzés ígéretesnek bizonyult és a módszer előrejelzésének minőségének látástávolság kategóriáktól való függetlenségét is bebizonyították. Az analógiás és a hibrid módszer előrejelzéseit a katonai repülőtereken

⁹ Analytic Hierarchy Process

részben az operatív előrejelző gyakorlatba adaptálták és az előrejelző szakemberek visszajelzései pozitívak voltak.

1. Táblázat: az analógiás módszer és a numerikus modellek jellemzői
(Tuba és Bottyán, 2017)

	<i>Analógiás módszer</i>	<i>Numerikus modell</i>
<i>Előrejelzés gyakorisága</i>	0.5-1 h	6-24 h
<i>Terület</i>	Minta adatsor pontján	Modell tartománytól függ
<i>Hatékonyság időtartama</i>	Pár óra	Pár nap
<i>Verifikáció</i>	Teljes (helyi megfigyelés szükséges az előrejelzéshez)	Részleges (ahol rendelkezésre áll megfigyelés)

A klasszikus módszercsaládhoz tartoznak még a **konceptuális modellek** (Wantuch, 2014). Egy időjárási helyzet leírásához általában szinoptikai és távérzékelési eszközök nyújtotta információkat használnak fel. Az analógiás módszerhez hasonlóan itt is felmerül a gyakorlatban az, hogy az éppen aktuális időjárási helyzet milyen mértékben hasonlít a konceptuális modellben megfogalmazott tipikus időjárási helyzethez. A fejlesztők ennek meghatározására vagy egy az analógiás módszerben ismertetett távolságot definiálnak vagy pedig egy döntési sorozatot dolgoznak ki. A döntési sorozat lépésein végig haladva megerősítésre vagy elvetésre kerül az, hogy használhatjuk-e a konceptuális modellt esetünkben vagy sem.

3.2.2. A tökéletes prognózis módszere (PP)

A tökéletes prognózis módszere az előrejelzési modellek nyújtotta információin alapuló statisztikai eljárás. A módszer célja a mérések és modell outputok között lineáris kapcsolat feltárása, alkalmazása során a következő függvénykapcsolatot konstruáljuk:

$$y=f(x_1,x_2, ..., x_N)+h \quad (1)$$

ahol $x_1, x_2, ..., x_N$ -t a prediktorok, a légkör azon paramétereinek együttese, amelyeket az operatív időjárási modell előre tud jelezni, y a becslendő, a légköri modell által nem előrejelezhető paraméter (prediktandusz), h pedig a statisztikai módszer hibáját jelenti. A gyakorlatban a modellek előrejelzései hibával terheltek, így a statisztikai módszer hibához hozzájárul a modell hibája is, amely a PP modellek hátránya. A PP modellek előnye, hogy bármelyik numerikus előrejelzési modellről feltételezhetjük az előrejelzett paraméterek

tökéletes mivoltját, így a PP modell könnyen alkalmazható bármelyik numerikus modell esetén. Az f függvénykapcsolat feltárása a PP módszer leglényegesebb momentuma. A függvény megadása olyan statisztikai módszerek vagy kombinációjuk segítségével történik, mint például a döntési fa (Wantuch, 2014).

A **döntési fa** egy olyan statisztikai eljárás, amely során egy döntési sorozat minden lehetséges kimenetele reprezentálva van. A módszert előszeretettel használják, mivel hasznos eszközként szolgál az előrejelzés során, viszont a látástávolság előrejelzésének komplexitásából adódóan döntések alapjául szolgáló szabályok meghatározása nem könnyű feladat (Gultepe és mtsai., 2007).

A Wantuch (2001) PP módszere nemzetközi szinten is ismertté vált, mely során a függvény megkonstruálásához egy döntési fával kombinált korrelációs módszert alkalmazott. Az eljárást a látástávolság operatív előrejelzési gyakorlatába is adaptálták. A módszer során használt FOGSI¹⁰ egy széleskörű statisztikai elemzések eredményeként kapott index, amely a látástávolság és a különböző időjárási változók (modell kimenetek) közötti kapcsolat leírására szolgál.


A FOGSI és a látástávolság között lineáris regressziós kapcsolat létesíthető, amelyet kétéves adatbázis alapján határoztak meg. A FOGSI-n alapuló döntési fa (2. ábra) a fizikai elkülönítést teszi lehetővé, mivel minden kategória egy fizikai állapotot reprezentál.

A döntési fa küszöbszámai a pestszentlőrinci szinoptikus állomás két évre vonatkozó felszíni és rádiószondás adatai alapján kerültek meghatározásra. Nagy Roland (2014) az indexet diplomamunkája során tovább finomította (módosított FOGSI), ennek eredményeként a látástávolsággal szorosabb lineáris kapcsolat volt kimutatható, amely javította az előrejelzés minőségét.

3.2.3. Modell Output Statisztika (MOS)

A Modell Output Statisztika módszere (Glahn és Lowry, 1972) olyan statisztikai eljárásnak tekinthető, amelynek előrejelzését az utófeldolgozott modell outputok és megfigyelt mérések optimalizálják (Gultepe és mtsai., 2007). Tehát a módszer során az állomásokon történő megfigyelések kapcsolatban állnak a modellek outputtal. Általában a MOS ultrarövidtávú előrejelzése során a legnagyobb súlyt a mérések, azon belül a legutóbbi mérések kapják (WMO, 1991).

¹⁰ FOG stability index



2. Ábra: A döntési fa módszer menete (Wantuch, 2001; Deák, 2010)

A MOS a tökéletes előrejelzés módszeréhez hasonlóan a modell kimenetek és megfigyelés közötti lineáris kapcsolat feltárását célozza meg (Wantuch, 2014):

$$y=f(z_1,z_2,..., z_N) \quad (2)$$

ahol $z_1, z_2, ..., z_N$ -t prediktoroknak vagy megfigyeléseknek nevezzük, y pedig a becslendő a légköri modell által nem előrejelezhető paraméter (prediktandusz).

2. Táblázat: A tökéletes előrejelzés (Perfect Prog – PP) és a Modell Output Statisztika (MOS) módszere közötti különbségek (WMO CAeM Working Group, 1999)

		PP	MOS
Statisztikai kapcsolat feltárása	Prediktorok	Időjárási változók t időpontban mért értéke	Időjárási változók t időpontra előrejelzett értéke
	Prediktandusz	t időpontban mért időjárási elem	
Módszer alkalmazása		A prediktandusz $t+dt$ időpontra vonatkozó előrejelzése a t időpontbeli prediktorokkal	
Statisztikai kapcsolat erőssége		Erős (azonos időpontban megfigyelt mérések)	Gyengül (az idővel növekvő modell hiba miatt)
Modelltől való függés		Modell független	Modell függő
Adatok forrása		Megfigyelések szükségességek	Megfigyelések és a modell kimenetek is lehetnek

A módszer hátránya, hogy az így konstruált f függvényt a numerikus modell sajátosságai határozzák meg, ami gyakran nem felel meg a valóságnak. Emellett más konfigurációval rendelkező numerikus modellre más f függvényt kell konstruálni, ami azt is jelenti, hogy modell fejlesztéseivel ugyanaz az függvény már nem alkalmazható. *Wilson és Vallée* (2002) ennek kiküszöbölésére a MOS egy frissíthető verzióját fejlesztette ki, amely az eljárás során korábbi és új adatok kevert felhasználásán alapul.

A PP és a MOS esetében a f függvény megkonstruálása történhet olyan tanuló algoritmus segítségével is, mint amilyen a neurális hálózat is. *Nagy Roland* (2010) PP megközelítésű neurális hálózatok négyzetes hibáit vizsgálta. Diplomamunkájában a hazai területen még nem alkalmazott látástávolság nowcasting célú neurális hálózatok mérési adatokból alapuló előrejelzéseit is tesztelte és megmutatta, hogy a hálózat előrejelzései képesek meghaladni az ultrarövidtávon jól teljesítő perzisztencia prognózis előrejelzéseit.

3.2.4. Neurális hálózatok

A neurális hálózat egy nemlináris modell, amelynek alkalmazása azért terjedt el a látástávolság rövid és ultrarövid távú előrejelzése során, mert segítségével kiküszöbölhető a látástávolságra ható szinoptikus, a mezoskálájú, és a lokális hatások számszerűsítése (*Pasini és mtsai.*, 2001). *Pasini és mtsai.* (2011) olyan neurális hálózatot fejlesztettek ki, amely felszíni megfigyelések alapján készít 0-2 órás időlépcsőre vonatkozó determinisztikus látástávolság előrejelzést. A fejlesztés során érzékenységvizsgálatot is elvégeztek, amely

során legutóbb megfigyelt látástávolság érték ultrarövidtávú előrejelzések szempontjából meghatározó szerepét mutatták ki. A hálózatok előrejelzéseinek verifikációja során született eredmények biztatóak voltak, mivel azok meghaladták a perzisztencia prognózist és a klíma adatokat is.

Marzban és mtsai. (2007) olyan neurális hálózatot fejlesztettek ki a látástávolság előrejelzésére kifejlesztett, amelyben a felszíni mérések mellett modell kimeneti adatok is prediktorokként szolgáltak. Eredményeik azt mutatták, hogy ha megfelelő mennyiségű és minőségű adat szolgál prediktorként, akkor a neurális hálózat előrejelzései pontosabbak a hagyományos MOS módszer előrejelzéseinél.

Leyton és Fritsch (2003) kutatásaikkal kimutatták, hogy sűrűbb állomáshálózat adataival tanult hálózatok 1, 3 és 6 órás időlépcsőre vonatkozó látástávolság előrejelzései meghaladták a szinoptikus állomások adataival tanult hálózatok előrejelzéseit. *Wang és mtsai.* (2009) olyan a neurális hálózatokat fejlesztett ki, amelyek előrejelzéseit az alacsony látástávolsággal jellemezhető helyzetekre optimalizálták.

Olyan hálózatok kifejlesztésére is sor került, amelyek az köd egzisztenciát vagy a ködképződés valószínűségének becslését hivatottak előrejelezni. A Canberrai Nemzetközi Replőtéren a köd egzisztenciáját 3, 6, 12 és 18 órás időlépcsőkre vonatkozóan becsülték neurális hálózatok segítségével és az előrejelzést az operatív gyakorlatban döntések során használták fel (*Fabbian és mtsai.*, 2007). *Bremnes és Michaelides* (2007) több neurális hálózat becslését átlagolva a köd kialakulásának valószínűségét jelezte előre. Emellett olyan kétlépcsős eljárást is alkalmaztak, amely során egy neurális hálózat determinisztikus előrejelzései szolgálták a valószínűségi előrejelzés bemeneti paramétereit. A módszerrel lehetővé tette a hálózat becsléseiből adódó bizonytalanságok számszerűsítését, amellyel növelte az előrejelzés értékét.

Hazánkban is folyik jelenleg neurális hálózatokkal kapcsolatos kutatás (*Hadobács és Bottyán*, 2015), amely a repülésmeteorológiában hatékony eljárások kidolgozását célozza meg.

4. Neurális hálózatok (Artificial Neural Networks)

A neurális hálózatok (Artificial Neural Network - ANN) egy olyan nemlineáris statisztikai modell, amelyet az emberi idegrendszer mintájára alkottak meg azért, hogy egyszerű részműveletek összekapcsolásával komplexebb összefüggéseket tárjon fel egy rendelkezésre álló adatbázis alapján. Az neurális hálózatokat kezdetben beszéd, kép vagy minta felismerésére használták, majd idővel osztályozásra, függvényközelítésre és előrejelzésre is egyre többen alkalmazták (Lippman, 1987). Előrejelző képességének köszönhetően az üzleti életben (Kaastra és Boyd, 1996), a műszaki tudományokban és a természettudományokban is széles körben elterjedt a használata (Zhang és mtsai., 1998); ám a meteorológiában és azon belül az időjárás előrejelzéséhez csak néhány évtizede kezdték el kihasználni a lehetőségeit (Gardner és Dorling, 1998).

A szakirodalomban számos példa van a neurális hálózatok különféle időjárási paraméterekre, különböző időtávra vonatkozó előrejelzésének operatív gyakorlatban történő alkalmazására. Hung és mtsai. (2008) zápor ultrarövidtávú, illetve rövidtávú (1-6 órás) előrejelzésére használtak neurális hálózatot és megmutatták, hogy ultrarövidtávon az előrejelzés megbízható, de az időlépcsők növekedésével már nagyobb volt a bizonytalanság. Az ANN-t csapadék valószínűségének és mennyiségének 24 órára történő előrejelzésére is alkalmazzák, amihez modell kimeneti és szonda adatok szolgálnak bemeneti adatként (Hall és mtsai., 1999). A hálózat által 24 órára előrejelzett és a megfigyelt átlagos csapadékmennyiség között 0,95-ös korrelációs együttható volt kimutatható és abban az esetben, amikor a hálózat 95% vagy annál nagyobb csapadékvalószínűséget jelzett előre, mindig megfigyelhető volt csapadékhullás.

A csapadék előrejelzése mellett több konvektív csapadék, illetve zivatar előrejelzésével foglalkozó tanulmány is beszámolt a neurális hálózatok előrejelzésének használhatóságáról. Ilyen például az Olasz Légierő Meteorológiai Szolgálatá által alkalmazott neurális hálózat, amit konvektív rendszerek állapotának osztályozására tanítottak meg és 15 percre 89%-os, 30 percre 87%-os hatékonysággal képes az egyes cellák továbbfejlődését előrejelezni műholdas adatok alapján (Puca et al., 2005). A hálózatok kifejlesztésével leginkább a MCS¹¹-k előrejelzésének pontosítására törekednek, amely lehetővé tenné a lakosság minél korábbi riasztását.

¹¹ Mesoscale convective systems - mezoskálájú konvektív komplexumok

Shank és mtsai. (2008) a harmatpont 1-12 órás előrejelzését tűzték ki célul neurális hálózatot felhasználva. A köd előrejelzésénél is kiemelkedő jelentőséggel bíró időjárási paraméter a mezőgazdaság területén is fontos információval szolgál, mivel a léghőmérséklettel együtt erősen befolyásolja a fagyok és hóhullámok intenzitását, amelyek károsíthatják a kultúrnövényeket.

Marzban és mtsai. (2007) a látástávolság mellett több időjárási paraméter neurális hálózattal történő előrejelzésével is kísérletezett. *Marzban és Stumpf* (1996, 1998) munkája során olyan neurális hálózatokat fejlesztett ki, amely képes felismerni a tornádókhoz kapcsolódó kis skálájú örvényeket Doppler-radar méréseiből származtatott adatok alapján. Továbbá a hálózat tornádó vagy 25 m/s szélsőséget meghaladó pusztító szelek ultrarövidtávú előrejelzésére is alkalmas.


4.1. A neurális hálózatok alkalmazása a prognosztikai gyakorlatban

A hálózat működésének megértéséhez tekintsünk egy jelenséget, amelyről mérési adatok állnak rendelkezésünkre. A jelenségnek megfeleltethetünk egy rendszert, amely különböző bemeneti értékekhez, kimeneti értékeket rendel hozzá. Célkitűzésünk az, hogy az inputok és az outputok ezen kapcsolati rendszerét modellezhessük és a modellt outputok becslésére alkalmazni tudjuk olyan input adatokra is, amelyekhez tartozó outputot nem ismerjük (*Fazekas*, 2013). A neurális hálózat reprezentatív szituációk sorozatán keresztül képes kapcsolatot létesíteni a független változók és a függő változók – esetünkben az időjárási paraméterek és a látástávolság – között. Információ a prediktorok (független változók) és a prediktanduszok (független változók) közötti kapcsolatáról az egymással kölcsönható csomópontok (neuronok) hálójában lelhető fel. A hálózatot felépítő neuronok információ feldolgozó egységként funkcionálnak és számítási részfeladatokat látnak el. A neuronok súlyokon és transzferfüggvényeken (ún. aktivációs függvény) keresztül kapcsolódnak egymáshoz. A transzferfüggvények szerepe a hálózatban a nemlineáris kapcsolat megjelenítése, így olyan függvényeket szokás választani, amelyek jobbról folytonosak, határértékük a $-\infty$ -ben 0, a $+\infty$ -ben pedig 1 (*Fazekas*, 2013).

A súlyok szerepe a neurális hálózaton belül az, hogy egy időszakra vonatkozó adatbázis tanulása során a lehető legpontosabb hálózati becslések születhessenek, azaz a hálózat becslése minél közelebb essen a valóságban mért értékhez. A tanulási folyamatban a hálózati becslés és a valós érték között folyamatosan átlagos négyzetes hibát számítunk (ez a közelségi indikátorunk), és addig változtatjuk a súlyokat, amíg ez az érték minimális nem lesz. Ennek értelmében a hálózat tanulási folyamata egy minimumkereső algoritmuson

alapul, amely arra törekszik, hogy az iterációs lépések során megtalálja a súlyok azon kombinációját, amelyekhez a hibafüggvény minimuma tartozik. A neurális hálózatokat az teszi izgalmassá, hogy ahelyett, hogy szakemberek által előre meghatározott szabályok alapján hajtáná végre a műveletet, múltbeli helyzetekből tanul meg alapvető összefüggéseket; ez az egyik legnagyobb előnye a dinamikus modellekkel szemben (*Jain és Mao, 1996*).

Ahhoz, hogy a tanulás folyamatát megértsük, tekintsünk egy olyan egyszerű hálózatot, amelyben a neuronok között összesen két súly található. A súlyok kezdeti véletlenszerű kombinációjára kiszámítható a négyzetes hiba, a súlyok folyamatos változtatásával pedig a négyzetes hibák értékeiből kirajzolódó 3D-s hibafelületet kapjuk meg (3. ábra).




3. ábra: Egy egyszerű ANN két súlyhoz tartozó hibafelülete
(*Gardner és Dorling, 1998* – szerkesztve)

A valóságban jóval több neuron és súly alkotja a hálózatokat, így a feladat, amelyet már háromnál több dimenziós hibafelületen kell végrehajtani bonyolultabbá válik (*Gardner és Dorling, 1998*). A minimumkereső algoritmusokat a későbbiekben részletezem.

A neuronok elrendezése, és kapcsolódási struktúrája alapján többféle elrendezés, ún. hálózati topológia alakítható ki. A különböző topológiák más-más módon tanulnak, és más-más problémák megoldására ideálisak. A meteorológiai prognosztikai gyakorlatban az ún. előrecsatolt többrétegű perceptron (4. ábra) egyre gyakrabban alkalmazott típus

(Gardner és Dorling, 1998), ezért mi is ezzel dolgoztunk. Az előrecsatolt többrétegű perceptron neuronokból felépített bemeneti és kimeneti rétegekből áll, amelyek között egy vagy több ún. rejtett réteg helyezkedik el. Az információ a bementi rétegből indulva, egy irányba terjed a kimeneti rétegig. A többrétegű perceptront alkotó minden neuronnak saját aktivációs függvénye és saját súlya van, használatának lépései pedig a következők (Fazekas, 2013):

1. Létrehozunk egy hálózatot, vagyis megadjuk a rétegek számát, a rétegekben a neuronok számát, valamint a transzferfüggvényeket. Meghatározzuk a tanítás algoritmusát.
2. A hálózat betanítása a megadott feltételekkel.
3. A hálózat előrejelzésének tesztelése a tanuló adatbázistól független referencia adatbázissal (ahol az outputot ismerjük).
4. Ha a hálózat rendelkezik a megfelelő általánosító képességgel, akkor a hálózatot a gyakorlatban olyan input adatokra is használjuk, amelyekhez tartozó output nem ismert és hálózat által becsült outputot fogadjuk el.



4. ábra: A többrétegű perceptron (Fazekas, 2013)

A hálózat topológiájának tervezése során figyelembe kell venni, hogy a nem megfelelően konstruált hálózat hajlamos a túlilleszkedésre (over-fit), ami alatt azt értjük, hogy a hálózat a tanuló adatbázisra kellően illeszkedik, viszont korábban nem látott adatokkal téves eredményeket generál. Az over-fit többnyire akkor következhet be, ha a


hálózatot a tanuló adatsor méretéhez képest túl sok neuron alkotja, illetve ha a tanuló adatsor túl rövid. A neurális hálózat eredményei akkor tekinthetők megbízhatónak, ha új adatokon végezve a számítást jól tud általánosítani. Kevés neuronból álló hálózat esetén túl kevés a struktúra szabadsági foka ahhoz, hogy felismerje az alapvető összefüggéseket, ennek következtében előfordulhat, hogy nem csökken le a négyzetes hiba értéke.

A hálózat topológiájának szempontjából fontos tényező még a rejtett rétegek száma: minél összetettebb egy folyamat, annál több rejtett réteg beillesztése szükséges (*Jain és Mao, 1996*). A rejtett rétegbeli neuronok számáról több álláspont van jelen a szakirodalomban. *Kaastra és Boyd (1996)* egy háromrétegű neurális hálózat esetén a bemeneti és a kimeneti neuronszámok szorzatának négyzetgyökét ajánlja a rejtett réteg neuronszámának megválasztására. A neurális hálózatokkal kapcsolatos kutatásokban a rejtett rétegek neuronszáma nem haladta meg a bemeneti adatok kétszeresét, így vizsgálataink során mi sem alkalmaztunk ennél többet

4.2. A neurális hálózatok szoftveres támogatása

Habár a működő neurális hálózatok viszonylag egyszerű matematikai apparátust igényelnek, a hálózatok tanítási algoritmusai ugyanakkor nagyságrenddel bonyolultabbak és számításigényesebbek. A megoldandó matematikai probléma a vizsgálataink során mindig a sokváltozós súlyfüggvény minimumhelyének megkeresése volt, amely a neurális hálózatok tipikus és általános tanítási módszere, ezért kutatásunk során számos szoftveres támogatás közül is választhattunk.

Kezdetben a neurális hálózatok tanulási folyamatához Multiple Back-Propagation (with CUDA) version 2.2.4) szoftvert használtuk fel, majd később a Fast Artificial Neural Network (FANN) – PHP programkönyvtár használatára tértünk át, mivel az számos előnnyel bírt a neurális hálózatok tanítása szempontjából. A FANN olyan C programnyelven írt függvénykönyvtár, amely a C, C++, Python, PHP, Delphi nyelvekkel is egyaránt használható. A FANN függvénykönyvtárban belül ötféle tanulási algoritmus és tizennyolcféle aktivációs függvény közül választhatunk, ezek közül az alapvetőbbeket (Gauss, szigmoid) alkalmaztuk a tanítás során (5. ábra).



5. Ábra: A tanítás során alkalmazott aktivációs függvények: szigmoid (bal), Gauss (jobb)

A FANN keretein belül ötféle tanulási algoritmussal tanulhat a hálózat: soros (incremental), köteget (batch), RPROP, Quickprop és a SARPROP. A következő fejezetben e tanulási algoritmusok működési logikáját fogom részletesen bemutatni.

4.3. Alkalmazott tanítási algoritmusok


Elsőként a back-propagation (hiba visszaáramoltatása, hiba visszaterjesztése) – továbbiakban BP – módszer hátterében álló műveleteket ismertetem, mivel a FANN keretein belül használt további algoritmusok is ezen algoritmus továbbfejlesztett változatai, így a BP számításain alapulnak.

4.3.1. A hiba-visszaterjesztési (backpropagation) algoritmus

A BP algoritmus főbb lépései a következők (Fazekas, 2013):

- Kezdeti súlyok megadása.
- Bemeneti jel végigáramoltatása a hálózaton, anélkül, hogy a súlyok módosulnának.
- A kapott kimeneti jel és a tényleges (valóságban megfigyelt) jel közötti különbség (hiba) kiszámítása.
- A hiba hálózaton történő visszaáramoltatása és a súlyok megváltoztatása a hiba csökkentése érdekében.

A BP súlyváltoztatás folyamatának megértéséhez Fazekas (2013) Haykin (1995) könyvén alapuló magyarázatára támaszkodunk. Ehhez először tekintsünk egy neuront, amely egy olyan többrétegű perceptron része, amelyben csak a szomszédos rétegek neuronjai állnak kapcsolatban egymással; a rétegen belül, illetve távolabbi rétegek közt nem lehetséges fel kapcsolat.



6. ábra: Egy neuron felépítése (Fazekas, 2013)

i, j, k : az egyes rétegeket alkotó neuronok sorszámát jelöli a hálózatban az információval egy irányba, balról jobbra haladva,

n : a tanítás lépéseinek száma,

$y_i(n)$: i . neuron kimenete, j . neuron bemenete, ha i . réteg után közvetlenül a j . réteg következik,

$w_{j0}(n) = b_j(n)$: a j . neuron torzítása

$w_{ji}(n)$: az i . neuronból a j . neuronba mutató súly

$v_j(n)$: j . neuronban összegzett érték:

$$v_j(n) = \sum_i w_{ji}(n) y_i(n) \quad (3)$$

$\varphi_j(\cdot)$: a j . neuronhoz tartozó transzferfüggvény

$y_j(n)$: a j . neuron kimenete, azaz

$$y_j(n) = \varphi_j(v_j(n)) \quad (4)$$

$d_j(n)$: a kimenet valódi, csak a kimeneti rétegben ismert értéke, amelyhez a hálózat becslését, azaz a $y_j(n)$ -et viszonyítjuk.

Az n . lépés $\mathcal{E}(n)$ négyzetes hibáját a valódi kimeneti érték és a hálózat becslésének különbségének négyzetével kapjuk a következő képlet szerint:

$$\mathcal{E}(n) = \frac{1}{2} \sum_j e_j^2(n) = \frac{1}{2} \sum_j (d_j(n) - y_j(n))^2 \quad (5)$$

melyből az átlagos négyzetes hiba képezhető:

$$\bar{\mathcal{E}}(n) = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n) \quad (6)$$

ahol N : tanítópontok száma

A soros és a kötegelt algoritmus is egy BP algoritmus, a köztük lévő különbség az, hogy a súlyok frissítése különböző szakaszon történik. Ennek megértéséhez először definiálnunk kell az epoch jelentését: a tanító halmaz egyszeri végigfutása a hálózaton. A soros algoritmussal történő tanítás során a súlyok módosítása minden egyes tanító pont után megtörténik, míg a kötegelt tanulás során ez csak egy-egy teljes epoch után történik meg. A soros algoritmus előnye, hogy kevesebb tárolási helyet igényel és könnyű a gyakorlatban történő alkalmazása. A batch vagy kötegelt BP algoritmus használata során viszont az alábbi átlagos négyzetes hiba minimalizálását kifejező (7) képletet szükséges alkalmazni az előbbi helyett.

$$\bar{\mathcal{E}} = \frac{1}{2N} \sum_{n=1}^N \sum_j e_j^2(n) \quad (7)$$

A súlyok folyamatos illeszkedése, úgy történik, hogy a gradiens módszer (gradient descent, delta rule) segítségével az algoritmus kiszámítja a hibafüggvény adott pontbeli gradiensét és a súlyok azon újabb kombinációja jön létre, amellyel a legnagyobb gradiens irányába történik a következő iterációs lépés. A gradiens módszer az alábbi egyenlet segítségével írható fel:

$$w_{ji}(n+1) - w_{ji}(n) = \Delta w_{ji}(n) = -\eta \frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} \quad (8)$$

ahol $\eta > 0$: a tanulási paraméter.

A módszer szerint $\mathcal{E}$ hibafüggvény összes w_{ji} súly szerinti gradiensét képezni kellene, ami numerikusan nehezen oldható meg. A kimeneti réteg lokális gradienseinek kiszámítása során diszkrét értéket kapunk, mivel ismerjük valós kimeneti és az előrejelzett értéket. A BP algoritmus így rekurzíve számítja ki a deriváltakat, tehát a gradiensek rétegenként visszafelé haladva kerülnek kiszámításra (például a j . neuron lokális gradiense kiszámítható a k ., azaz j . utáni réteg lokális gradiensét felhasználva) és így az összes tanító pont lokális gradiense meghatározható. A matematikai háttér leírásához először tekintsük a matematikában gyakran alkalmazott láncszabályt, azaz az összetett függvények differenciálási szabályát:

$$\frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} = \frac{\partial \mathcal{E}(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)}; \quad (7)$$

A tagok kiszámításával a következő függvényeket kapjuk:

$$\frac{\partial \mathcal{E}(n)}{\partial e_j(n)} = e_j(n) \quad \frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_j(v_j(n)) \quad \frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad \frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n)$$

Az értékeket behelyettesítve a (7) képletbe és a lokális gradienst $\delta_j(n)$ -vel jelölve az alábbi egyenletet kapjuk:

$$\Delta w_{ji}(n) = -\eta e_j(n) \varphi'_j(v_j(n)) y_i(n) = \eta \delta_j(n) y_i(n) \quad (8)$$

$$\text{ahol } \delta_j(n) = -\frac{\partial \mathcal{E}(n)}{\partial v_j(n)} = e_j(n) \varphi'_j(v_j(n)) \quad (9)$$

Ahogy említettük kimeneti rétegben ismert a becült és a valós érték közötti különbség ($e_j(n) = d_j(n) - y_j(n)$), így a gradiens közvetlenül számítható. Ha viszont a $d_j(n)$ nem ismert, mivel j . rejtett rétegbeli neuron, akkor az összetett differenciálási szabály alapján lokális gradienst rekurzív számítással kapjuk meg:

$$\delta_j(n) = -\frac{\partial \mathcal{E}(n)}{\partial v_j(n)} = -\sum_k \frac{\partial \mathcal{E}(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial v_j(n)} = \sum_k \delta_k(n) w_{kj}(n) \varphi'_j(v_j(n)) \quad (10)$$

$$v_k(n) = \sum_l w_{kl}(n) \varphi_l(v_l(n))$$

mivel

$$\frac{\partial v_k(n)}{\partial v_j(n)} = w_{kj}(n) \varphi'_j(v_j(n))$$

Így megkapjuk a lokális gradiens képletét, ami a BP algoritmus egyik alapja:

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (11)$$

Összefoglalva tehát a súlyok korrigálási mechanizmusa:

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

ahol $y_i(n)$ i . rétegbeli neuron kimenete, $\delta_j(n)$ pedig a kimeneti és a rejtett rétegekben (9) és (11) alapján kapható meg.

Az η tanulási paraméter (learning rate) fontos szerepet játszik a BP algoritmusban. E paraméter határozza meg az iterációs lépések nagyságát, azaz az algoritmus tanulási sebességét, ennek következtében az algoritmus stabilitását. A tanulási paraméter nemcsak konstans értéket vehet fel, hanem a tanulás során egy szabály szerint folyamatosan

illeszkedhet is a paraméter (adaptív tanulási paraméter), mint ahogy azt látni fogjuk a BP algoritmus továbbfejlesztett változatai esetében. Ha az η paraméternek túl kicsi értéket választunk, akkor a súlyok kis mértékben változnak, így hosszabb idő szükséges a konvergencia eléréséhez. Nagy η esetén a konvergenciához szükséges idő lecsökken, de az algoritmus stabilitásának felborulásához is vezethet. Ezalatt azt értjük, hogy a hálózat hibája szabálytalanul változik, emiatt pedig a nagy súlyváltozások következtében nő annak az előfordulási esélye, hogy az algoritmus átugorjon egy globális minimumot. Az instabilitás továbbá oszcillációt is előidézhet a rendszerben, megakadályozva azt, hogy a hiba egy bizonyos érték alá essen. A gradiens módszeren alapuló BP algoritmus érzékeny a kezdeti értékekre és könnyen előfordulhat, hogy nem a globális, hanem egy lokális minimumot talál meg. Ennek és a stabilitás fenntartásának érdekében a gradiens szabályt momentum hozzáadásával az alábbiak szerint módosították:

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta \delta_j(n) y_i(n), \quad n = 1, 2, \dots \quad (12)$$

ahol $\alpha > 0$: momentum konstans, ami a korábbi lépés aktuális lépésre gyakorolt hatásának mértékét szabályozza. A differenciálegyenlet megoldása pedig

$$\Delta w_{ji}(n) = \eta \sum_{t=1}^n \alpha^{n-t} \delta_j(t) y_i(t) = -\eta \sum_{t=1}^n \alpha^{n-t} \frac{\partial \mathcal{E}(t)}{\partial w_{ji}(t)} \quad (13)$$

amiből látszik, hogy a momentum paraméterként 1-nél kisebb pozitív szám megválasztása ajánlott. A momentum paraméter gyorsítja konvergenciát olyan területeken, ahol kisebb a gradiens nagysága és ha jól választjuk meg, akkor egy elegendően nagy lendületként képzelhető el, amely segítségével elkerülhető az oszcillálás és a lokális minimumba történő csapdázódás. A lokális minimumból történő kiszabadulást a momentum segítségével úgy érhetjük el, hogy egy adag korábbi súlyváltozást hozzáadunk az aktuális súlyváltozáshoz, ami kicsi a lokális minimumban (*Gardner és Dorling, 1998*).

A gyakorlati alkalmazásban a BP algoritmus működését segítő momentum paraméterrel sem lehet mindig sikeres a globális minimum keresése. A momentum paraméter optimális megválasztása ugyanúgy problémafüggő, mint a tanulási paraméter és nincs olyan általánosan elfogadott érték, amely minden esetben javítaná a tanulás minőségét.

4.3.2. RPROP algoritmus

A BP algoritmus mellett léteznek adaptív tanulási algoritmusok is, amelyek a súlyfrissítés problémáját újabb paraméterek hozzáadásával hivatottak megoldani. Ezen tanulási algoritmusok illeszkedő (adaptív) tanulási paramétert használnak, amelynek

változását a megfigyelt hibafüggvény viselkedése határozza meg. Gyakran figyelmen kívül hagyják a tényt, hogy az aktuális súlyváltozás Δw_{ji} mérete nemcsak a folyamatosan illeszkedő tanulási paramétertől, hanem a $\frac{\partial \mathcal{E}^{(n)}}{\partial w_{ij}}$ nagyságától is függ, tehát egy kellő körültekintéssel megválasztott adaptív tanulási paraméter mellett is zavart idézhet elő a súlykorrekciójában a derivált előreláthatatlan viselkedése.

Annak érdekében, hogy ezt az ún. zavaros illeszkedést (blurred adaptivity) kiküszöböljék, kifejlesztették az RPROP¹² algoritmust (Riedmiller és Braun, 1993), amely közvetlenül változtatja a súlyfrissítés mértékét, anélkül hogy a parciális derivált nagyságát figyelembe venné. Az RPROP egy hatékony tanulási algoritmus, amely a lokális gradiens információin alapulva, a nagyságától függetlenül határozza meg a súlyfrissítés mértékét. Az RPROP és az BP között a két legnagyobb különbség az, hogy az RPROP adaptívan illeszkedve módosítja a súlylépés mértékét és az illeszkedésre nincs hatással a gradiens $\frac{\partial \mathcal{E}^{(n)}}{\partial w_{ij}}$ nagysága, csak az előjelétől függ.

Ahhoz, hogy ennek matematikai hátterét megértsük, először tekintsük az egyes súlyokat (w_{ij}), amelyekhez egy súlyfrissülési (korrekciós) értéket ($\Delta_{ij}^{(t)}$) rendelhetünk hozzá. Ez az i . és j . réteg neuronja közötti súlyhoz tartozó n . lépésben vett adaptív súlyfrissítési érték ($\Delta_{ij}^{(t)}$) folyamatosan fejlődik a tanulási algoritmus alatt a hibafüggvény lokális viselkedésének függvényében az alábbiak szerint:

$$\Delta_{ij}^{(n)} = \begin{cases} \eta^+ \cdot \Delta_{ij}^{(n-1)} & , ha \frac{\partial \mathcal{E}^{(n-1)}}{\partial w_{ij}} \cdot \frac{\partial \mathcal{E}^{(n)}}{\partial w_{ij}} > 0 \\ \eta^- \cdot \Delta_{ij}^{(n-1)} & , ha \frac{\partial \mathcal{E}^{(n-1)}}{\partial w_{ij}} \cdot \frac{\partial \mathcal{E}^{(n)}}{\partial w_{ij}} < 0 \\ \Delta_{ij}^{(n-1)} & , ha \frac{\partial \mathcal{E}^{(n-1)}}{\partial w_{ij}} \cdot \frac{\partial \mathcal{E}^{(n)}}{\partial w_{ij}} = 0 \end{cases} \quad (14)$$

ahol $0 < \eta^- < 1 < \eta^+$

Tehát ha az $\mathcal{E}$ hibafüggvény w_{ij} egyes súlyok szerinti parciális deriváltja tanulás során az egymást követő lépésben előjelet váltott, az azt jelzi, hogy az utolsó $\Delta_{ij}^{(n)}$ frissítési érték túl nagy volt és az algoritmus átugrott egy lokális minimumon, ebben az esetben az előző lépésbeli $\Delta_{ij}^{(n-1)}$ frissítési érték az η^- együtthatóval szorzódik. Ha a derivált előjelét nem

¹² Resilient back-PROPagation

változtatja, akkor a $\Delta_{ij}^{(n-1)}$ frissítési érték enyhén növekszik annak érdekében, hogy gyorsítsa a konvergenciát a kis meredekségű minimumban. A $\Delta_{ij}^{(n)}$ frissítési érték, pedig a $\Delta w_{ij}^{(n)}$ súlylépést határozza meg, olyan módon, hogy ha a derivált pozitív (növekvő hiba), akkor a $\Delta w_{ij}^{(n)}$ súlylépés a $\Delta_{ij}^{(n)}$ frissítési értékkel csökken, ellenkező esetben a $\Delta_{ij}^{(n)}$ frissítési érték hozzáadódik:

$$\Delta w_{ij}^{(n)} = \begin{cases} -\Delta_{ij}^{(n)} & , ha \quad \frac{\partial \mathcal{E}^{(n)}}{\partial w_{ij}} > 0 \\ +\Delta_{ij}^{(n)} & , ha \quad \frac{\partial \mathcal{E}^{(n)}}{\partial w_{ij}} < 0 \\ 0 & , ha \quad \frac{\partial \mathcal{E}^{(n)}}{\partial w_{ij}} = 0 \end{cases} \quad (15)$$

$$w_{ij}^{(n+1)} = w_{ij}^{(n)} + \Delta w_{ij}^{(n)} \quad (16)$$

Ha a parciális derivált előjelet vált (az előző túl nagy lépés miatt egy minimum kimaradhatott), akkor visszatér a korábbi súlylépésre:

$$\Delta w_{ij}^{(n)} = -\Delta w_{ij}^{(n-1)}, ha \quad \frac{\partial E^{(n-1)}}{\partial w_{ij}} \cdot \frac{\partial E^{(n)}}{\partial w_{ij}} < 0 \quad (17)$$

A visszalépésnek következtében feltételezhetően a derivált újra előjelet vált a következő lépésben. Az RPROP algoritmus során a frissítési értékek és a súlylépések epoch-onként változnak. Az algoritmus működéséhez csak néhány paraméter megadása szükséges. Előnye, hogy ezen paraméterek optimális megválasztása nélkül is viszonylag gyors konvergálási időtartammal működik a hálózatunk.

A tanulás kezdetén a Δ_0 kezdeti súlyfrissítési értéket szokás megadni, amelynek jellemzően 0,1 értéket választják, de ez az érték nem kritikus. Az η^- értékeként alacsony értéket (0,5-öt) ajánlott beállítani, mivel akkor fontos a szerepe, ha túl nagy volt a lépés és kimaradt egy minimum. Az η^+ értékének ennél nagyobbak kell lennie (1,2), abból kifolyólag, hogy e paraméter felelős a konvergencia gyorsításáért a kis gradiensű, azaz kevésbé meredek pontokon. Viszont tekintetbe kell vennünk, hogy ha η^+ túlságosan nagy számot választunk, az a súlylépés irányának váltakozásához vezethet, amely instabillá tenné a tanulási folyamatot (Riedmiller és Braun, 1993).

4.3.3. Quickprop algoritmus

Az algoritmusok tervezése során a cél az, hogy a lehető legrövidebb idő alatt megtaláljuk a hibafüggvény globális minimumát, tehát a lehető legnagyobb iterációs lépésekben

szeretnénk haladni anélkül, hogy kihagynánk a keresett globális minimumot. Sajnos csak az elsőrendű parciális deriváltak egy neuronba gyűjtött összessége szolgál némi információval számunkra arról, hogy mekkora is lehet ez az optimális lépés. A magasabb rendű deriváltak kiszámítása viszont további információval szolgálhat, amely javíthat az algoritmus működésén. A másodrendű deriváltakat két féleképpen használhatjuk fel: az adaptív tanulási paraméteren keresztül és a hibafüggvény másodrendű deriváltjának explicit kiszámításával minden egyes súly figyelembe vételével. *Fahlman (1988)* ötvözte e két megközelítést és így született meg az ún. Quickprop algoritmus, amely az RPROP-hoz hasonlóan egy lokális adaptív formája a tanulási folyamatnak. Lényege, hogy az egyes súlyokhoz tartozó lokális hibafüggvényt egy parabolával közelíthetjük, amelynek meredekségét a többi súly alakulása nem befolyásolja. A minimum helyzetének becslését az alábbi egyenlet megoldása adja:

$$\Delta w_{ij}^{(t)} = \frac{\frac{\partial E^{(t)}}{\partial w_{ij}}}{\frac{\partial E^{(t-1)}}{\partial w_{ij}} - \frac{\partial E^{(t)}}{\partial w_{ij}}} \Delta w^{(t-1)} \quad (18)$$

A módszer célja az $f(w)$ minimumának felderítése, azaz meg kell keresnünk azt az w -t, amelyhez tartozó $f'(w) = 0$. Mivel az $f'(w)$ egy konvex függvény, így a Newton-módszer iteratív lépésekben számítja az w korrekcióját a következő egyenlet szerint (*Fahlman, 1988*):

$$w^{(t+1)} = w^{(t)} + \Delta w^{(t)} \quad \text{ahol } \Delta w^{(t)} = \frac{f'(w(t))}{f''(w(t))} \quad (19)$$

Ha a $f''(w(t))$ másodrendű derivált kiszámítása nehézkes, akkor elsőrendű deriváltakat felhasználva is számolhatjuk a $\Delta w(t)$ súlylépés értékét:

$$f''(w(t)) = \frac{f'(w(t)) - f'(w(t-1))}{w(t) - w(t-1)} = \frac{f'(w(t)) - f'(w(t-1))}{\Delta w(t)} \quad (20)$$

$$\Delta w(t) = - \frac{f'(w(t))}{f'(w(t)) - f'(w(t-1))} \Delta w(t-1) = \frac{f'(w(t))}{f'(w(t-1)) - f'(w(t))} \Delta w(t-1)$$

A Quickprop fő formuláját viszonylag egyszerű alkalmazni, viszont néhány kiegészítés szükséges az algoritmus megfelelő működéséhez. Az aktuális korrekció értékének kiszámításához, tehát a (18) egyenlet és a gradiens módszert kombináljuk. A (18) egyenlet kis nevezője nagy súlyváltozást eredményezhet a számítás során. Ennek megelőzése érdekében megadható egy v paraméter, amely az aktuális súlyváltozást a korábbi súlyváltozással azonos mértékűvé korlátozza. Az algoritmus tehát két főbb paraméterrel dolgozik: a tanulási paraméterrel (a gradiens módszerhez) és a lépések korlátozásáért felelős

v paraméterrel. A részletezett formulát felhasználva, ha az aktuális görbe meredeksége (gradiense) kisebb, mint az előző és egy irányúak, akkor a súly ugyanabba az irányba fog változni. Az iterációs lépés nagyságát az határozza meg, hogy az aktuális gradiens nagysága, mekkora a korábbi gradiens mértékéhez képest. Ha az aktuális gradiens ellentétes irányú az előző lokális gradienssel, akkor átugrottunk egy minimumon. Ebben az esetben a következő lépés a jelenlegi és az ezt megelőző helyzet közé kerül. (Riedmiller, 1994)

4.3.4. SARPROP algoritmus

A BP egyik hátránya, hogy hajlamos az algoritmus a globális minimum felderítése helyett egy lokális minimumban csapdázódni. A globális adaptív optimalizációs módszerek ezt hivatottak kiküszöbölni, ám ezek számítási költsége jelentősen megnövekszik, különösen az összetettebb hálózatok esetében. A már korábban említett RPROP és egy globális optimalizációs technika, a szimulált „hűtés” (Simulated Annealing – SA) módszerének kombinálásával alkották meg a SARPROP algoritmust.

A SARPROP nemcsak képes kiszabadulni a lokális minimumból, de megtartotta, sőt javította az RPROP-ra jellemző gyors konvergenciához szükséges tanulási időt. A RPROP, mint továbbfejlesztett BP algoritmus előnye, hogy a BP költséghatékonyságát megőrizte, mely tulajdonsága a modellezett jelenség komplexitásának növekedésével egyre fontosabb szerepet játszik. A SARPROP algoritmus lehetővé teszi a konvergencia eléréséhez szükséges idő lerövidülését, amellet költséghatékony egyszerű számításokból álló algoritmust használunk. Az SA zaj formájában és súly módosításon keresztül adódik hozzá az RPROP algoritmushoz. A SARPROP algoritmus a zaj segítségével lehetővé teszi a lokális minimumból történő kiszabadulást, valamint a súly pusztítással a hibafelületet képes módosítani azáltal, hogy csökkenti a nagyobb frissítési értékek további növekedését (Treadgold és Gedeon, 1998). A SARPROP a zajt az RPROP algoritmus súlyfrissítési értékeihez adja hozzá, amikor

- hiba gradiense előjelet vált az egymás után következő epoch-okban,
- a frissítési érték nagysága kisebb, mint az SA ciklusban meghatározott érték.

A zaj hozzáadásával így minimalizálhatjuk a frissítési érték illeszkedését zavaró hatásokat, ami azt jelenti, hogy a frissítési érték csak a zaj által módosul, ha ennek aránylag kicsi az értéke. Az SA nemcsak zaj hozzáadással, hanem ún. súly pusztítással (weight decay) is jár. A súly pusztítás azért felelős, hogy a kisebb értékű súlyok gyorsabban süllyedjenek, mint a nagyobbak. Ennek során az algoritmus egy ún. büntetőfüggvényen keresztül a 0 közelébe kényszeríti a kiválasztott súlyokat (Fazekas, 2013).

A SARPROP algoritmusban alkalmazott gradiens formáját az alábbi egyenlet írja le:

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial w_{ij}} - 0,01 \cdot \Delta w_{ij} \frac{w_{ij}}{1 + w_{ij}^2} \cdot SA \quad (21)$$


$$SA = 2_{ij}^{-T \cdot epoch}$$

ahol, T a hőmérséklet. A T szerepe, hogy az algoritmus olyan területeken is minimumot keressen, ahova más algoritmussal nem jutnánk el. A SARPROP csak ezzel az egy paraméterrel dolgozik, melynek optimális értéke problémafüggő, de általában 0,01 és 0,05 intervallumon belül megválasztva megfelelően működik, ezért mi a 0,015-tel dolgoztunk. A fejlesztése során azt a következtetést levonták le, hogy minél bonyolultabb a probléma, annál kisebb hőmérsékleti érték használatos. A SARPROP algoritmust az RPROP-ban előforduló hibák kompenzálása végett fejlesztették ki, mivel az RPROP-ban a frissítési érték exponenciális növekedése miatt átugorhat egy jó lokális (potenciális globális) minimumot és rossz lokális minimumhoz konvergálhat (*Treadgold és Gedeon, 1998*).

Az algoritmust lényegében úgy kell elképzelni, hogy egy labda megakad egy lokális minimumban (gradiens módszer) és felület rázásával kiugrasztjuk a labdát a lokális minimumból. Fontos, hogy mennyire erősen rázzuk a felületet, mert elegendően nagynak kell lennie ahhoz, hogy a lokális minimumból kiszabaduljon, viszont a globális minimumban bent kell maradnia. Az SA technikával először erősen megrázzuk (magas hőmérséklet) a felületet, majd csökkenjük a rázás intenzitását (hőmérsékletet) (*Russel és Norvig, 2003*). Az algoritmus megállítására is több módszer létezik, vizsgálataim során az epochok számát (20 000) vettem figyelembe a tanítás leállításánál.

5. Adatok és módszer

A kutatás során az volt a célkitűzésünk, hogy a neurális hálózatokat felhasználva készítsünk olyan ultrarövidtávú, kétórás látástávolság-előrejelzési módszereket, amelyek az operatív előrejelzői gyakorlatba is könnyen integrálhatók lesznek. A Liszt Ferenc Nemzetközi Repülőtéren telepített ALMOS mérőrendszerhez többek között a két futópálya mentén elhelyezett 3-3 transzmisszométer is tartozik. Vizsgálataink során a műszerek 13R, 31L, 13L és a 31R pályaküszöbökhöz tartozó méréseit használtuk fel (7. ábra). A látástávolság térben és időben is változhat a nagy területen fekvő repülőtéren, így erősen indokolt e paraméter leszállási pontok közelében, a futópályák több pontján történő mérése. A műszerek az egyes pályák melletti a futópályamenti látótávolságot (RVR) jól jellemző meteorológiai optikai mélységet (MOR^{13}) mérik. A transzmisszométer egy fénykibocsátó adóból és egy vele szemben elhelyezett fotocellás vevőből áll. A műszer az adóból a vevőbe kibocsátott fény gyengüléséből, a köztük levő vízszintes légoszlop átlátszóságától függően számítja a MOR-t. A műszer a levegő átlátszósága mellett a háttér megvilágítottságát és a pályafények erősségét is érzékeli (Sándor és Wantuch).



7. Ábra: A 13R, 31L, 13L és a 31R pályaküszöbhez tartozó transzmisszióméterek a Liszt Ferenc Nemzetközi Repülőtér domborzati térképén

¹³ Meteorological Optical Range

A mérési adatok 2005. januártól 2016 decemberéig terjedő időszakra álltak rendelkezésre, ebből jelöltük ki a tanuló, teszt, illetve referencia adatsort. A tanuló és teszt adatsort 2005-től 2015-ig *Kandya és mtsai.* (2012) eljárása alapján 70-30% arányban osztottuk két részre. A referencia adatbázisunk, amin a hálózatok működését teszteltük, a teljes 2016-os év volt. Annak érdekében, hogy a hálózat reprezentatív adatokkal végezze a tanulást, a tanuló adatsor leválasztása során a feltétel az volt, hogy a 13R vagy a 31R és a 31L mérési ponton mért MOR egyike 3000 m alatt legyen. Tehát a futópályák egyik pontjában 3000 méter feletti MOR is előfordulhatott, ezáltal nem csak alacsony látástávolsággal jellemezhető ködös napok kerültek az adatbázisba.

Neurális hálózatok olyan variációit készítettük el, amelyekhez különböző tanulási algoritmusok, aktivációs függvények tartoznak és az egyes hálózatok rejtett rétegeinek számai és a rejtett rétegbeli neuronok számai is eltérőek. Emellett minden hálózatnak elkészítettük azt a változatát, amely nem csak a sorban következő rétegbeli neuronokhoz kapcsolódik (továbbiakban soros kapcsolás), hanem azt kihagyva a következő rétegbeli neuronnal is kapcsolatot létesít (továbbiakban többszörösen kapcsolt hálózatok).

A vizsgálat során három, egymástól kis mértékben eltérő tanuló adatokkal tanítottuk a hálózatokat – a hálózatok a felépítésen kívül prediktoraik számában is eltértek egymástól. A hálózatok prediktoraikat tekintve abban különböztek, hogy a látástávolságot befolyásoló aktuálisan mért alapvető paraméterek mellett (év napja, óra, hőmérséklet, harmatpont, szélerősség, szélirány és MOR) tartalmaztak-e további információt.

A korábban említett analógiás módszer példáján hipotézisünk az volt, hogy a hálózat tanulását segítheti, ha az egyes időjárási paraméterek aktuális időpontra vonatkozó értéke mellett a korábbi mérések is a tanuló adatbázis részét képezik. A múltbeli időlépéseket az előrejelzési időlépcsőknek megfelelően határoztuk meg, azaz a 30, 60, 90 és 120 perccel korábbi mérések is a bemeneti adatok részét képezték. Tehát a hálózatok egy része a múltbeli és az aktuális paraméterekkel együtt 27 prediktorból álló tanuló adatokkal tanult.

Emellett az volt a feltevésünk, hogy az 5 cm-es és 20 cm-es mélységben mért aktuális talajhőmérsékleti értékek tanuló adatokhoz történő csatolása a hálózat előrejelzésének további javulását segítheti elő. Ebből kifolyólag múltbeli paraméterekkel és az aktuális talajhőmérsékleti mérésekkel kiegészített adatokkal is tanultak a hálózatok, amelyek így 29 prediktorral jeleztek előre.

Annak érdekében, hogy megvizsgáljuk a talajhőmérséklet és a múltbeli paraméterek tanuló adatokhoz történő hozzáadásának a hálózat előrejelzésére gyakorolt hatását, olyan hálózatok működését is elemeztük, amelyek tanuló adatai múltbeli paraméterekkel nem, csak az aktuális talajhőmérséklet mérésekkel voltak kiegészítve. Ebben az esetben a hálózatok prediktorainak száma 9 volt.

Vizsgálataink során a tanuló adatsorban az outputot többféle módon adtuk meg a hálózat számára, így tesztelni tudtuk, hogyan teljesít a hálózat ugyanazon adatok módosított formájával. Meg kell említenünk, hogy a tanuló adatsorok változtatása során a bemeneti adatok (prediktorok) száma és formája nem változott. Elsőként maga a látástávolság négy időlépcsőben mért méterben kifejezett értékeiből álló outputok-kal tanultak a különböző hálózatok (továbbiakban decimális hálózatok), amelyek várt kimeneteit is a látástávolság konkrét, méterben kifejezett számértékei adják.

A látástávolság előrejelzéséről szóló fejezetben láthattuk, hogy a látástávolság előrejelzése különböző tartományok szerint különböző pontossággal történik és a kritériumtartományok közötti változások nagymértékben befolyásolják a repülőtér működését. A légi társaságok a látástávolság különböző kategóriáinak pontos meghatározását várják el az időjárás előrejelzőktől, mert a döntéseikben a látástávolság egyes határértékeit kell figyelembe venniük. Ebből kifolyólag vizsgálataink során mi is a látástávolság kategóriák minél pontosabb elkülönítésére törekedtünk. Ennek érdekében ugyanezen tanuló adatsorok output-jain egy átalakítást végeztünk el: az egyes időlépcsőkben mért látástávolságokhoz kategóriaváltozókat rendeltünk, annak megfelelően, hogy 400 m, illetve 800 m fölött vagy alatt alakult a látástávolság értéke. A hozzárendelés a következő módon történt: ha 400 m vagy 800 m alatti a MOR értéke, akkor 1-et rendeltünk hozzá, ellenkező esetben 0-t. A hálózat (továbbiakban kategóriás hálózat) előrejelzései is 0 és 1 közötti tartományban mozogtak és a kimeneti neuronok száma nyolc darab volt, mivel mind a négy időlépcsőhöz tartozó MOR értéket a két feltétel szerint egyenként vizsgálta.

A hálózatok működésének értékeléséhez a látástávolság verifikációja során széles körben alkalmazott Heidke Skill Score (HSS) verifikációs indexet használtuk fel. A HSS indexet azért választottuk a verifikáció során, mert képes azt is kiszűrni, ha egy algoritmus előrejelzése a véletlennek köszönhetően egyezett a méréssel egyes esetekben. Mivel egy teljes évhez képest alacsony a látástávolsággal jellemezhető esetek száma, ezért azt is fontosnak tartottuk, hogy olyan indexet válasszunk, amely az ilyen ritka események

előrejelzésének verifikációja során reprezentatív mérőszámként szolgál (Tuba és Bottyán, 2017).

Az index kiszámításához (22) az alábbi 2x2-es kontingencia a táblázatot (3. táblázat) kell felhasználnunk. A HSSI értéke mínusz végtelentől egyig terjed és az előrejelzés akkor ideális, ha az index értéke 1. Az ultrarövid távú előrejelzésnek akkor van információ értéke, ha jobb prognózist képes adni a perzisztencia prognózisnál, amely ilyen rövid időtávon kifejezetten jól teljesít. Repülésmeteorológiai szempontból viszont fontos tudni, hogy mikor várható változás a látástávolságot illetően, a neurális hálózatokkal éppen ezen változások előrejelzésére törekszünk.

3. Táblázat: Az előrejelzés verifikálásához szükséges 2x2-es kontingencia táblázat

	Megfigyelt esemény	Nem megfigyelt esemény
Előrejelzett esemény	a (találat)	b (téves riasztás)
Nem előrejelzett esemény	c (elmulasztott esemény)	d (helyes elvetés)

$$HSS = \frac{2(ad-bc)}{(a+c)(c+d)+(a+b)(b+d)} \quad (22)$$

A decimális hálózatok verifikációja során a táblázat kitöltéséhez az előrejelzett és a mért MOR értékeit hat különböző intervallumra osztottuk (0–400 m, 400–600 m, 600–1000 m, 1000–1500 m, 1500–10 000 m) és a HSSI értékét az egyes csoportokra számítottuk ki. A kategóriás hálózatok esetében értelemszerűen az egyes kategóriákra történt a HSS indexek kiszámítása.

6. Eredmények

Mint ahogy azt korábban említettük, hálózatok rengeteg különböző kombinációjával dolgoztunk, amely nagy mennyiségű adat feldolgozásával járt együtt. A hálózatok teljesítményeinek ellenőrzése a perzisztencia prognózis és a hálózatok HSSI értékeinek összevetésével történt meg. Több hálózat esetében előfordult, hogy a perzisztenciát tanulta meg, így a HSS különbségeinek kinyerésével tudtuk kiszűrni, hogy melyek azok a hálózatok, amelyek a referencia adatbázison alkalmazva a perzisztenciához képest információ többlettel szolgáltak. E fejezetben e kiszűrt hálózatokkal végeztünk különféle vizsgálatokat.

6.1. A decimális hálózatok

6.1.1. A decimális hálózatok prediktorainak hatása az előrejelzésre

A hálózatok különböző kombinációi közül kiválasztott három decimális hálózattal egy összehasonlító elemzést készítettünk. Ezek topológiája megegyezett, viszont bemeneti adataikban a prediktorok száma eltérő volt a három hálózatban. A vizsgálat során célunk az volt, hogy megállapítsuk mennyiben befolyásolja a hálózat működését, ha a bemeneti adatok talajhőmérsékletet vagy múltbeli paramétereket is tartalmaznak. A hálózatok azonos felépítését a különböző számú prediktorok mellett úgy értük el, hogy a hálózatok rejtett rétegbeli neuronjainak száma közel azonos arányban volt a bemeneti réteg neuronjainak, azaz a prediktorok számával. Tehát a 9 prediktorral tanult hálózat (9–4–4–4) esetében 4 darab, a 27 és a 29 prediktorral tanult hálózat esetében 14 darab (27–14–14–4, illetve 29–14–14–4) neuronból álló rejtett rétegek kötik össze a bemeneti és a kimeneti neuronokat.

A hálózatok Gauss aktivációs függvényvel, RPROP algoritmussal tanultak és a neuronok soros kapcsolatban álltak egymással. A 29, 27 és 9 bemeneti adattal tanult hálózatok több látástávolság intervallumra vonatkozó HSS indexeit a 4. táblázat foglalja össze. A táblázat alapján megállapítható, hogy az intervallumok többségében a talajhőmérséklettel és a múltbeli paraméterekkel (29 bemeneti adattal) tanult hálózat előrejelzése érte el a legmagasabb HSS indexet. A három különböző hálózatot összevetve a múltbeli paraméterekkel, talajhőmérséklet nélkül (27 bemeneti adattal) tanult hálózat HSS indexei voltak legtöbbször alacsonyabbak a másik két hálózathoz képest, az 1500 m-es kategóriában viszont a 30 és a 60 perces időlépcsőben a másik két hálózathoz képest a legjobban teljesített. Az, hogy a 27 bemenettel tanult hálózatok előrejelzései szerepeltek legtöbbször a leggyengébben a HSS indexek alapján. Ez azt mutatja, hogy a talaj

hőmérsékletének tanuló adatokban való megjelenése a hálózat működését az esetek túlnyomó részében elősegítette.

4. Táblázat: Az azonos felépítésű, prediktoraik számában eltérő (27, 29 és 9) hálózatok HSS indexei a különböző látástávolság intervallumokban az egyes időlépcsőkre vonatkozóan (a három hálózat közül az egyes időlépcsőkben legjobban teljesítő hálózat HSS indexe pirossal jelölve)


Perc	0-400 m			400-600 m		
	27	29	9	27	29	9
30	0,6382	0,6652	0,3535	0,7366	0,7442	0,6260
60	0,3756	0,5110	0,2631	0,5469	0,6499	0,4632
90	0,2794	0,3685	0,2789	0,3859	0,5019	0,4026
120	0,2058	0,3263	0,2671	0,2865	0,4107	0,3426
	600-1000 m			1000-1500 m		
	27	29	9	27	29	9
30	0,7461	0,7580	0,7470	0,7597	0,7320	0,7429
60	0,6387	0,6777	0,6446	0,6772	0,6703	0,6724
90	0,5050	0,6063	0,5363	0,5960	0,5920	0,6140
120	0,4044	0,5290	0,4567	0,5079	0,5518	0,5044

6.1.2. A decimális hálózat előrejelzéseinek hatásvizsgálata

A másik két hálózathoz képest kevésbé eredményes, 27 bemeneti adattal tanult hálózat 31R mérései alapján történő négy időlépcsőre vonatkozó előrejelzése a 8. ábrán látható egy általunk kiválasztott ködös napon (2016. 01.28.).

A teljes évre vonatkozóan 30 és a 60 perces időlépcsőre jól teljesítő hálózat előrejelzései jól megközelítik a mért MOR értékeket és a változás tendenciáját is képes viszonylag jól meghatározni ezekben az időlépcsőkben. A négy időlépcsőre vonatkozó előrejelzést bemutató ábra alapján megállapítható, hogy a hálózat előrejelzése az idő lépcső növekedésével bizonytalanabbá válik és hajlamos a látástávolság értékének felülbecslésére.


Az előbb említett, 27 prediktorral működő hálózat előrejelzéseivel egy hatásvizsgálatot is elvégeztünk ugyanerre a napra vonatkozóan, amellyel a hálózat viselkedésének megfigyelése volt a célunk. A hatásvizsgálat során módosítottuk a bemeneti mérési értékeket és összehasonlítottuk az így előrejelzett értékeket a valós mérések alapján történt előrejelzéssel és így láthattuk, hogy a hálózat mennyire képes követni a valóságban várható változást, ha a bemeneti mérések értékeit megváltoztatjuk. A vizsgálat során a



8. Ábra: A 27 prediktorral előrejelző hálózat¹⁴ négy időlépcsőre (30, 60, 90, 120 perc) vonatkozó előrejelzése (kék árnyalatai) és a **mért MOR** 2016. 01. 28-án

jelenlegi szélsőbesség, a harmatpont és a hőmérséklet bemeneti mérési értékein változtattunk.

A 9.ábra a hálózat a valódi mérések és a szélsőbesség 20 csomóval növelt értékei alapján előrejelzett értékeit mutatja be. A bemeneti adatokban megnövelt szélsőbesség alapján történő előrejelzés a várakozásoknak megfelelően többnyire magasabb látástávolság értékeket adott, mint a valódi mérések alapján történő előrejelzés. Az alacsonyabb




9. Ábra: A 27 prediktorral tanult hálózat¹⁵ valós mérések (31R), a 20 csomóval csökkentett szélsőbesség alapján előrejelzett MOR és a mért MOR értékek 2016. 01. 28-án

¹⁴ 27 – 14 – 14 – 4 topológiájú, sorosan kapcsolt, Gauss aktivációs függvényvel és RPROP algoritmussal tanult hálózat

¹⁵ 27 – 14 – 14 – 4 topológiájú, sorosan kapcsolt, Gauss aktivációs függvényvel és RPROP algoritmussal tanult hálózat

látástávolságoknál több esetben a valódi előrejelzéshez képest nem történt változás, sőt alacsonyabb értékek is előfordultak, amely a szélsébség hálózat előrejelzését kevésbé befolyásoló hatásával magyarázható.

A szélsébség mellett azt is megvizsgáltuk, hogy a hálózat előrejelzésére milyen hatást gyakorol a harmatpont 4 °C-kal történő csökkentése, azaz, ha a mérések szárazabb feltételekről árulkodnak. Az 10. ábrán a valóságban mért értékek alapján és a módosított mérési értékek alapján történő előrejelzést láthatjuk. Az alacsonyabb harmatponttal készült előrejelzés a szárazabb feltételek következtében nagyobb látástávolságot becsült, azaz a valóságban ilyen esetben bekövetkező változás jelent meg a hálózat előrejelzésében. A megnövelt szélsébség alapján történő előrejelzéssel ellenben a harmatpont csökkentett értékével történő előrejelzés az alacsonyabb látástávolságoknál is magasabb értékeket becsült a hálózat valós mérések alapján történő előrejelzéséhez képest. Ez alapján megállapítható, hogy a harmatpont változásának hatása erőteljesebben megjelenik a neurális hálózat előrejelzésében, mint a szélsébség megváltozása.




10. Ábra: A 27 prediktorral tanult hálózat¹⁶ valós mérések (31R), a 4 °C-kal csökkentett harmatpont alapján előrejelzett MOR és a mért MOR értékek 2016. 01. 28-án

Az eddigi paraméterek mellett azt is megvizsgáltuk, hogy a hőmérséklet 4 °C-kal történő megnövelése milyen változást idéz elő a hálózat előrejelzésében. Az 11. ábra alapján

¹⁶ 27-14-14-4, Gauss aktivációs függvény, RPROP algoritmus, soros kapcsolás

rögtön szembetűnik, hogy a hőmérséklet módosítása az előző paraméterekhez képest jelentősebb befolyással volt a hálózat előrejelzésére. A száraz feltételek hatása a hőmérséklet magasabb értékén keresztül erőteljesebben megjelent a hálózat előrejelzésében, mint a harmatpont csökkentésén keresztül. Emellett a hálózat feltehetően a tanuló adatok alapján az alacsonyabb hőmérséklettel jellemezhető órákban valószínűsíti látástávolság nagyobb mértékű lecsökkenését. A száraz feltételek alapján készült előrejelzés így többnyire a valós mérésekkel előrejelzett legalacsonyabb látástávolságok idején is párásságot jelzett előre a fizika törvényeinek megfelelően. Az ábrák alapján az is megállapítható, hogy az időlépcső növekedésével a magasabb hőmérséklet az eredeti mérés alapján történő előrejelzéshez képest egyre növekvő eltérést idéz elő a hálózat előrejelzésében.



11. Ábra: A 27 prediktorral tanult hálózat¹⁷ valós mérések (31R), a 4 °C-kal magasabb hőmérséklettel előrejelzett MOR és a mért MOR értékek 2016. 01. 28-án

A hatásvizsgálat alapján összességében levonhatjuk azt a következtetést, hogy a szélsősebesség és a harmatpont megváltozása kisebb mértékben, míg a hőmérséklet megváltozása jelentősen befolyásolta a hálózat előrejelzését. A vizsgálat azt is megmutatja, hogy ez, a többi hálózathoz képest az esetek nagy részében kevésbé jól teljesítő hálózat is képes a fizika törvényeinek megfelelően módosítani az előrejelzését, ha a bemeneti állapotváltozók más időjárási körülményekről árulkodnak.


¹⁷ 27-14-14-4, Gauss aktivációs függvény, RPROP algoritmus, soros kapcsolás

6.2. A kategóriás hálózatok

6.2.1. A küszöbindex hatása a kategóriás hálózatok előrejelzésére

A hálózatok teljesítménye nemcsak a hálózat tulajdonságaitól függhet, hanem attól is, hogy ugyanazon tanuló adatokat milyen formában bocsátottuk a tanítási algoritmus rendelkezésére. A kategóriás hálózatok esetében egy további szabadsági fok nyílik az egyes kategóriákat elválasztó küszöbszámok megválaszthatóságával, tehát a hálózat tesztelése során mi állíthatunk be egy küszöbértéket, ami két különböző kategória között határt szab. Mivel a teljes évre számított 400 m-re és a 800m-re számított HSS indexek értékeiben is megmutatkozik a küszöbindex megválasztása, így tovább javíthatjuk a hálózat előrejelző képességét.

A hálózatok előrejelzésének küszöbindextől való függését két talajhőmérséklettel és múltbeli paraméterekkel tanult kategóriás hálózaton mutatjuk be a teljes 2016-os évre számított HSS indexeket felhasználva. Az elsőként bemutatott kategóriás hálózatban egy 28 és 14 neuronokból álló rejtett réteg köti össze a bemeneti (29 neuron) és a kimeneti réteget (8 neuron). E hálózat Gauss aktivációs függvényt és RPROP algoritmust használt a tanulás során és benne többszörös kapcsolat áll fenn a neuronok között. A 12. ábrán a perzisztencia




12. Ábra: A perzisztencia prognózis és a 29 prediktorral tanult hálózat¹⁸ (ANN) előrejelzéseinek 400 m-re és 800 m-re vonatkozó HSS indexei a küszöbérték függvényében az egyes időlépcsőkben

prognózisra és a különböző küszöbindexekkel tesztelt hálózat becsléseire vonatkozó HSS indexek láthatók 400 m, illetve 800 m-es csoportosítás szerint. Egyértelműen látszik, hogy az előrejelzés minőségét nagyban meghatározta, hogy a hálózat tesztelése során milyen küszöbértékeket választunk meg a 0 és az 1 kimenet szétválasztásához.

¹⁸ (29-28-14-8, Gauss aktivációs függvény, RPROP algoritmus, többszörös kapcsolat)

A 400 m-es HSSI indexek esetében a 0-1 intervallum első felén megválasztott küszöbértékek esetében, míg a 800 m-es HSSI esetében az első felénél kissé tágabb intervallumból megválasztott küszöbértékek esetében a hálózat előrejelzései meghaladják a perzisztencia prognózist a 2016-os évre vonatkozóan.

Annak érdekében, hogy a hálózat és a perzisztencia prognózis HSS indexei közötti különbséget jobban szemléltessük, külön ábráztuk azt a tartományt, ahol a hálózat becsléseinek HSS indexei meghaladták a perzisztencia prognózis HSS indexeit az egyes időlépcsőkben (13. ábra). Láttuk, hogy a 400 m-hez és a 800m-hez tartozó magasabb HSSI értékek eltérő intervallumon jelentkeztek, ezért a 400 m-re és a 800 m-re ábrázolt szűkített tartomány is eltér egymástól.




13. Ábra: A perzisztencia prognózis és a 29 prediktorral tanult hálózat¹⁹ (ANN) előrejelzéseinek 400 m-re és 800 m-re vonatkozó HSS indexei a küszöbértékek azon tartományában, ahol hálózatok előrejelzései meghaladták a perzisztencia prognózist az egyes időlépcsőkben

Az ábrán megfigyelhető, hogy az egyes időlépcsőkre vonatkozó HSSI görbéken több maximum is kirajzolódik és szembeűnő az is, hogy a hálózat HSS indexei főleg a nagyobb időlépcsőkben haladták meg jóval a perzisztencia HSS indexeit. A hálózat és a perzisztencia HSS indexei között a legnagyobb különbség 400 m-re vonatkozóan 0,39-nél, 800 m-re vonatkozóan pedig a 0,48-as küszöbszámnál volt a 90 perces időlépcsőben. Ekkor a hálózat rendre 0,14-dal és 0,12-dal haladta meg a perzisztencia prognózis HSS indexeit, ami az összes általunk vizsgált hálózatkombinációkat tekintve a legnagyobb különbség volt, mivel általában századnyi – mégis sokat érő – különbségek voltak jellemzőek.

¹⁹ (29-28-14-8, Gauss aktivációs függvény, RPROP algoritmus, többszörös kapcsolat)

E hálózat mellett egy másik hálózat működésének küszöbértéktől való függését is vizsgáltuk (14. ábra). A második hálózatunk bemeneti és kimeneti rétegeit két darab 28 neuronból álló rejtett réteg köti össze. A hálózat az előzőhöz hasonlóan Gauss aktivációs függvényt és RPROP algoritmust használt a tanulás során, viszont a neuronjai között az előzővel ellentétben többszörös kapcsolat helyett soros kapcsolat áll fenn a neuronok között.

E hálózat HSS indexei az előzőhöz képest alacsonyabbak, viszont e hálózat is nagyobb intervallumban képes volt meghaladni a perzisztencia prognózis HSS indexeit. E hálózat esetén mind 400 m-re, mind 800m-re vonatkozóan az előző hálózat küszöbértékeitől eltérő küszöbértékeknél jelentkeztek az egyes időlépcsőkhöz tartozó maximális értékek, amely azt mutatja, hogy minden hálózat működése másképpen függ a küszöbindexek értékétől.



14. Ábra: A perzisztencia prognózis és a 29 prediktorral tanult hálózat²⁰ (ANN) előrejelzéseinek 400 m-re és 800 m-re vonatkozó HSS indexei a küszöbértékek azon tartományában, ahol hálózatok előrejelzései meghaladták a perzisztencia prognózist az egyes időlépcsőkben


6.2.2. A kategóriás hálózatok prediktorainak hatása az előrejelzésre

A bemeneti adatokat tartalmazó paraméterek hatását is vizsgáltuk azonos felépítésű kategóriás hálózatokon. A decimális hálózatoknál elvégzett elemzéshez hasonlóan 29, 27 és 9 prediktorral tanult hálózatokat vetettünk össze. Ezzel lehetőségünk volt megvizsgálni, hogy a talaj hőmérsékleti adatok és a múltbeli paraméterek befolyását a kategóriás hálózat előrejelzésére. A decimális hálózatokhoz hasonlóan ebben az esetben a bemeneti és a rejtett réteg neuronjainak aránya azonos volt mindegyik hálózatban (29-14-14-8/27-14-14-8/9-4-4-8), ami azért fontos, hogy a felépítésbeli különbségek ne befolyásolják a bemeneti adatok különbözőségéből adódó eltéréseket. A hálózatok szigmoid aktivációs függvényrel és

²⁰ (29-28-28-8, Gauss aktivációs függvény, RPROP algoritmus, soros kapcsolat)

RPROP algoritmussal tanultak és többszörös kapcsolat áll fent a neuronok között. A kategóriás hálózatok előrejelzését, mint láttuk a küszöbindexek megválasztása is befolyásolja, ezért mind a három hálózat esetében azzal küszöbindexekkel végeztem az összehasonlítást, amellyel egyenként a legjobban teljesítettek a 2016-os évre vonatkozóan.

Az 15. ábra a három hálózat 400 és 800 m-re vonatkozó HSS indexeit mutatja be az egyes időlépcsőkben. Az összehasonlító ábrán egyértelműen látszik, hogy az időlépcső növekedésével a perzisztencia és a hálózatok előrejelzése is egyre bizonytalanabbá válik, azaz a HSS indexeik is egyre alacsonyabb értéket vesznek fel. A talajhőmérséklettel együtt 29 bemenettel tanult hálózat 800 m-es HSS indexeit kivéve a hálózatok a 30 perces időlépcsőben perzisztenciához közeli HSS indexeket produkálnak. Az időlépcsők növekedésével a hálózatok előrejelzésének HSS indexei egyre nagyobb mértékben



15. Ábra: a három azonos felépítésű, de különböző számú prediktorral tanult hálózat²¹ és a perzisztencia prognózis 400 m-re és 800 m-re vonatkozó HSS indexei az egyes időlépcsőkben a teljes 2016-os referencia adatbázisra vonatkozóan

meghaladták a perzisztencia prognózis HSS indexeit 400 m-re és 800 m-re vonatkozóan is. Megállapítható, hogy a 30 és a 60 perces időlépcsőre vonatkozóan a talajhőmérséklettel és a múltbeli paraméterekkel tanult hálózatok előrejelzései bizonyultak leghatékonyabbnak. Tehát az első két időlépcsőben e hálózat pontosabban megtudta határozni, hogy a látástávolság az előrejelzett időlépcsőben 400 és 800 m alatt vagy fölött fog-e alakulni, mint a másik két hálózat. A 90 perces időlépcsőben a múltbeli paraméterekkel tanult hálózatok teljesítménye azonos volt a 2016-os évet tekintve, a 120 perces időlépcsőben viszont a talajhőmérséklet nélkül, múltbeli paraméterekkel tanult hálózat előrejelzése bizonyult a legjobbnak a HSS indexek alapján. A 15. ábra alapján az is megállapítható, hogy a 30 perces lépcsőben a talajhőmérséklet nélkül, 27 bemenettel tanult hálózat bizonyult a

²¹ (29-14-14-8 (küszöbérték: 0,35; 0,44)/ 27 -14-14-8 (0,35;0,38) /9-4-4-8 (0,48; 0,48), szigmoid aktivációs függvény, RPROP algoritmus, többszörös kapcsolat)

leggyengébbnek, viszont a többi időlépcsőben a múltbeli paraméterek nélkül tanult hálózat előrejelzései voltak kevésbé pontosak a többi hálózathoz képest a HSS indexek alapján, de még így is meghaladták perzisztencia prognózis előrejelzését.


Mindent összevetve elmondható, hogy a hálózat tanulóadatainak talajhőmérséklettel történő kiegészítése a hálózat jobb előrejelzését eredményezte a 30 perces időlépcsőre vonatkozóan, mivel a múltbeli paramétereket nem, de talajhőmérsékletet tartalmazó adatokon tanult hálózat is meghaladja a 27 bemenettel tanult hálózat előrejelzését is ebben az időlépcsőben, amelyből a talajhőmérséklet meghatározó szerepére következtethetünk. A múltbeli paraméterek előrejelzést javító hatása érvényesül a távolabbi időlépcsőkben, mivel a talajhőmérséklettel tanult hálózatokat meghaladta 27 bemeneti neuronból álló hálózat.

7. Esettanulmányok

2016. január 8-át azért választottuk a neurális hálózat előrejelzésének gyakorlatban történő tesztelésére, mert a nap során a látástávolság jelentős változékonysága volt megfigyelhető. Az ilyen változóan ködös napokon nagy nehézséget jelent a MOR előrejelzése az operatív gyakorlatban, mivel semmilyen hatékony, bevált eszköz nincs az előrejelző segítségére döntéshozása során. Az esettanulmányon keresztül bemutatjuk, hogy a hálózat mennyire képes a hirtelen kiugró változásokat előrejelezni a gyakorlatban.


7.1. Időjárási helyzet 2016. január 8-án

2016. január 8-án kontinensünk nyugati felén többközepcentű ciklonrendszer örvénylett, míg Közép- és Dél-Európa területén anticiklonális hatások érvényesültek. Hazánktól északnyugatra egy peremciklon örvénylett, amelynek középpontját a sztratoszférikus levegő leáramlásához köthető piros területek jelölik ki az Meteosat Second Generation (MSG) SEVIRI infravörös és vízgőztartományú csatornák kombinációjával előállított Airmass műhold képeken (16. ábra).



16. Ábra: a MSG Airmass műholdképei 2016. január 8-án és a CFS reanalízis térképe (500 hPa geopotenciál (gpm)) 0 UTC-kor (bal, fent) és a nap végén, 18 UTC-kor (jobb, lent) (forrás: wetterzentrale.de, eutmetrain.org)

A ciklonrendszer hullámozó frontja a hajnali órákban megközelítette a Kárpát-medencét (17. ábra). Az ehhez kapcsolódó középszintű felhőzet (okkersárga) átvonulását az MSG műholdfelvételein is nyomon követhetjük. Az éjszaka folyamán a felhőzet északkeleti irányba tolódott el, csapadék nem hullott belőle (16. ábra).




17. Ábra: Frontanalízis 2016 január 8-án 0, 6, 12 és 18 UTC-kor és január 9-én 0 UTC-kor (forrás: ZAMG)

Január 8-án délután délnyugat felől egy Spanyolország felett örvénylő ciklon melegfronti felhőzete érte el a Kárpát-medencét, amely a nagyobb vertikális kiterjedésű felhőzethez köthető fehér színnel látható az MSG műholdképén (16. ábra). A ciklon következtében többfelé eleredt az ónos eső a fagypont körüli területeken, amelyet később eső váltott fel az enyhébb légtömegek érkezésének következtében. A zöld területek a melegfront mögötti a reanalízisen is látható melegebb légtömegek benyomulását jelöli (16. ábra).


A köd képződésének megértéséhez vissza kell tekintenünk az elmúlt napok időjárására is. Január elején sarkvidéki eredetű levegő által okozott erős lehűlésnek köszönhetően $-10\text{ }^{\circ}\text{C}$ körüli minimum hőmérsékletek voltak jellemzőek Budapest területén. Január 8-át megelőző napokban enyhébb, nedvesebb légtömegek határozták meg a Kárpát-medence időjárását. Január 4-én egy mediterrán ciklon okozott országszerte havazást, délnyugaton hullott a legtöbb hó, amely a következő napokban tartósan meg is maradt (18. ábra).

Az ezt követő napokban a magasban beáramló melegebb léghullámok következtében ónos eső hullott az ország több részén, de kisebb havazás is előfordult. A január 8-át megelőző napon is többfelé hullott hó, majd késő délután a csapadékmező kelet felé hagyta el az országot. A hóval borított tájakon többfelé átmenetileg felszakadozott a felhőzet és az erős kisugárzás alacsony hőmérsékleteket eredményezett a felszín közelében (18. ábra).



18. Ábra: a hóvastagság és felszínközeli hőmérsékletminimum, 2016. 01.08.
(forrás: met.hu)

A kiválasztott napon az éjszakai órákban az MSG felhőzet típus (Cloud Type) produktumon (19. ábra) a délnyugat felől kék színnel jelölt elgyengült okklúziós front közepes szintű felhőzet áthaladása is követhető, amely mögött már 0 UTC-kor köd képződött a délnyugati országrészben. A köd kialakulásához legfontosabb feltételek adottak voltak: a csapadékhullás utáni párolgás útján megnövekedett a vízgőz tartalom, a levegő a harmatpontra hűlése és különböző hőmérsékletű, de telítettséghez közel álló levegő fajták keveredtek. Jelen esetben délnyugat felől beáramló enyhébb levegő volt a meghatározó,



19. Ábra: az MSG NWC SAF²² Cloud Type produktumai 2016. 01. 08-án


amely a hideg felszín feletti alacsony hőmérsékletű levegővel keveredve alacsonyszintű Stratus és köd képződését idézte elő. Tulajdonképpen áramlási ködnek is tekinthetjük.

²² Nowcasting Satellite Application Facilities

Kezdetben a nyugati országrészben, majd a keleti országrészben képződött köd, mivel a légmozgás is mérsékelt maradt. Reggelre a nyugati országrészben felszakadozott a köd és változóan felhős volt az ég, viszont a Duna vonalától keletre, így a Liszt Ferenc Nemzetközi Repülőtéren is köd volt.

A kora délutáni órákban a szél megerősödésével – a repülőtéren 11 órakor a változó irányú, 1-2 csomós szél 8 csomóra erősödött – északon többfelé felszakadozott a felhőzet, ám keleten a nap többi részében is tartósan megmaradt a köd.

Az északon felszakadozott felhőzet és a keleti országrészben tartósan megmaradó köd fölé nyúló hegycsúcsok a finomfelbontású műholdképen is jól látszódnak (20. ábra). Budapest a változóan felhős területek és a ködös területek határán helyezkedett el, amely a látástávolság napi változékonyságát idézte elő.




20. Ábra: MSG HRVIS RGB nagyfelbontású műholdképe VIS és felhő hőmérséklet detektálására alkalmas IR 10.8 tartományban 2016.01.08-án
(forrás: eumetrain.org)

A keleti országrészben különösen kedvezőek a feltételek a köd tartós fennmaradásához. Az ezen a területen kialakult köd gyakran hajlamos a légnyomásgradiens növekedésének hatására északnyugati irányba elmozdulni, amely Budapesten rövid idő alatt a látástávolság hirtelen lecsökkenését idézheti elő. Gyakran előfordul, hogy nyugaton felszakadozik a felhőzet, keleten pedig tartósan megmarad a köd és ennek következtében az ország két része között hőmérsékletkülönbség alakul ki, ami a nyomási gradiens megerősödését vonja maga után. A ködös terület felett ilyenkor egy kisebb „anticiklon” figyelhető meg, míg a ködmentes területen alacsonyabb a légnyomás. A nyomáskülönbség hatására a hideg ködös levegő mezoléptékű áramlást követve az ország középső és nyugati vidékei felé helyeződhet át (Sándor és Wantuch, 2005). Jelen esetben is a köd ehhez hasonló áthelyeződése volt megfigyelhető, ám a nyomásgradienst ezen a napon nem a nyugaton napos, keleten ködös területek hőmérsékletkülönbsége, hanem a melegfront közeledése idézte elő. A talajszél iránya megtévesztő lehet ilyen esetekben, mivel a köd

áthelyeződésének irányáról semmilyen információval nem szolgál, mivel a köd ilyen jellegű mozgását egy magasban – valahol 50 m és 300 m között – elhelyezkedő vezetőáramlás határozza meg (Sándor és Wantuch, 2005). Az áthelyeződő ködfoszlány területi kiterjedése különböző nagyságú lehet. A kisebb átmérőjű ködfoszlányok (60-80 km) szoktak a kiválasztott napunkon is tapasztalható néhány órás látásromlást okozni a repülőtéren. A hideg légpárnához kapcsolódó ködöktől az ilyen esetek abban különböznek, hogy ilyenkor a köd kisebb területet borít és nem áll fent több napja anticiklonális helyzet, emellett a ködfoszlányok repülőtérre történő beáramlásuk után sem maradnak meg ott tartósan.

Az MSG felhőtípus térképén (19. ábra) a késő délutáni órákban az Airmass műholdképen is megfigyelhető fehér színnel jelölt, vastag melegfronti felhőzet érkezését is nyomon követhetjük. A délutáni órákban átlagosan négy öt csomós szél volt jellemző a repülőtéren, amely déli, délkeleti irányú volt. 20 órától a szél a délről érkező melegfronttal párhuzamos – keleti – irányba front fordult.

A magaslégköri mérésen a nedvesebb levegő beáramlása a 700 hPa-os és 500 hPa-os nyomási szint között megnövekvő harmatpontra keresztül mutatkozik meg. A magaslégköri mérésen az is látható, hogy 0 UTC-kor 900 hPa-os szintig felnyúló inverziós réteg akadályozta meg a levegő átkeveredését.



21. Ábra: pestszentlőrinci rádiószondás felszállás adatai 2016.01.08. 0 és 12 UTC-kor

A levegő stabilitását a talajszinten felnyúló inverziós réteg mellett további inverziós rétegek erősítették a 800 hPa-os és 750 hPa-os nyomási szinten. 12UTC-re a határréteg inverziójának magassága 950 hPa-os nyomási szintre csökkent és a szél megerősödése következtében a talaj közelében felszakadt. A melegadvekción a szél irányának magassággal történő jobbra fordulása és a 12 UTC-kor 700 és 750 hPa-os nyomási szint közötti izoterma réteg árulkodik. A korábbi magasszintű inverzió tehát magasabbra tolódott

és csökkent a stabilitása, amely már a gyenge átkeveredést lehetővé tette. A magaslégkörben a fronthoz kötődő jet okozott szárazodást a 300 hPa-os nyomási szint közelében.

7.2. A decimális hálózatok esettanulmánya

A decimális hálózatok vizsgálata során láthattuk, hogy az esetek túlnyomó többségében a talajhőmérsékletet és a múltbeli paramétereket tartalmazó bemeneti adatokkal tanult hálózatok HSS index értékei érték el a magasabb értékeket, azaz teljes évre ezek előrejelzései bizonyultak legjobbnak. Az esettanulmányokban ilyen, két különböző topológiájú hálózat előrejelzését fogom bemutatni ugyanarra a kiválasztott kódos napra (2016.01.08.) vonatkozóan a 13R mérései alapján. Ezzel megfigyelhetjük azt is, hogy a hálózatok a topológiától és tanulási algoritmustól függően hogyan képesek előrejelezni a gyakorlatban.


Az elsőként bemutatott hálózat bemeneti és kimeneti rétegeit egy 28 és egy 14 neuronból álló rejtett réteg köti össze. A hálózat RPROP algoritmussal tanult és Gauss aktivációs függvényt használt a többszörösen kapcsolódó neuronok között. A hálózat és a perzisztencia prognózis teljes 2016-os évre számított 1500 m-es csoportra vonatkozó HSS indexeit az 5. táblázat mutatja be. A hálózat a 90 perces és a 120 perces időlépcsőben haladta meg perzisztencia HSS indexeit, amely azt jelenti, hogy ezekben az időlépcsőkben a hálózat pontosabban megtudta állapítani a teljes 2016-os év során, hogy a látástávolság értékek 1500 m alatt vagy felett lesznek, mint a perzisztencia prognózis.

5. Táblázat: a hálózat és a perzisztencia prognózis teljes 2016-os évre számított 1500 m-es csoportra vonatkozó HSS indexei az egyes időlépcsőkben

29-28-14-4	30 min	60 min	90 min	120 min
Perz. HSSI _{1500 m}	0,7645	0,6920	0,6078	0,5406
ANN HSSI _{1500 m}	0,7533	0,6707	0,6249	0,5761

A hálózat 30 perces és mind a négy idő lépcsőre történő előrejelzéseit külön ábrán mutatom be, annak érdekében, hogy a 30 perces időlépcső becsült értékei és tendenciái külön ábrázolva láthatóak legyenek.

A hálózat 30 perces előrejelzései (22.ábra) a valóságban mért értékeket mindenütt viszonylag jól közelíti. A hálózatnak a változás tendenciáját több esetben sikerült pontosabban közelítenie a perzisztencia prognózis változást nem előrejelző tendenciájához képest.




22. Ábra: A hálózat 30 percre vonatkozó előrejelzése (kék árnyalatai) és a *mért MOR* 2016. 01. 28-án

Az időlépcsők növekedésével természetesen növekszik a bizonytalanság is, így a hálózat hajlamosabb a látástávolság felülbecslésére (23. ábra). Viszont néhány túlságosan magas becsléstől eltekintve a hálózatnak több esetben sikerült a mért értékekhez viszonylag közeli becslést adnia. A hálózat nem szisztematikus felülbecslését bizonyítja, hogy 4 óra és 6 óra között a látástávolság kiugróan nagy emelkedését becsüli, amely 6 órakor be is következik, majd a hálózat a látástávolság kisebb mértékű változását jelzi előre, amely a valóságot jól közelíti.

Az előrejelzett MOR értékeit az állomáson mért napi hőmérsékleti menettel összevetve egyből szembetűnik, hogy a hőmérséklet emelkedésére kifejezetten érzékeny a hálózat előrejelzése. A hajnali órákban a felszakadozott felhőzet és a hóval borított felszín okozta erőteljes kisugárzásnak következtében – 7 °C alá süllyedt a hőmérséklet. Látható, hogy a hajnali órákban az elgyengült melegfronti felhőzet átvonulásával az éjszaka átmenetileg megemelkedett a hőmérséklet és a stabil rétegződést tovább erősítve a látástávolság csökkenését idézte elő.

A délelőtti folyamán megerősödött a szél, amelynek köszönhetően a köd kissé felszakadozott és a besugárzásnak köszönhetően a hőmérséklet erőteljesen megemelkedett. A hálózat az ilyen mértékű hőmérséklet emelkedéshez a látástávolság jóval nagyobb mértékű emelkedését jelezte előre. A délutáni folyamán délkeletről a repülőtérről sodródó köd foszlányokat, amelyek rövid idő alatt 15 órára és 17 órára rendkívül lecsökkentették látástávolságot kevésbé jól tudta előrejelezni a hálózat. Ám a 15:30-kor hirtelen megemelkedett látástávolság után bekövetkező, csökkenő tendenciát több idő lépcsőben is képes volt megfogni a hálózat. Késő este, amikor is a melegfronti felhőzet hazánk felé húzódott a hőmérséklet és a látástávolság értékei stabilizálódtak, ekkor a hálózat pontosabb becsléseket adott a várható látástávolságról.



23. Ábra: A hálózat négy időlépcsőre (30, 60, 90, 120 perc) vonatkozó előrejelzése (kék árnyalatai) és a **mért MOR** (felül), illetve a hőmérséklet napi menete 2016. 01. 28-án (alul)

A következő talajhőmérséklettel és múltbeli paraméterekkel tanult hálózat, amelynek az előrejelzését a gyakorlatban is verifikáltuk egy eltérő algoritmussal tanult, egyszerűbb felépítésű hálózat. A hálózat kimeneti és bemeneti rétegeit egy 14 neuronból álló rejtett réteg köti össze. A hálózat szigmoid aktivációs függvénnyel és Quickprop algoritmussal tanult. A hálózat felépítése abban is eltér az előző hálózat felépítéséhez képest, hogy ennek neuronjai soros kapcsolatban vannak egymással.


A perzisztencia prognózisra és a hálózat előrejelzéseire vonatkozó 1500 m-es HSS indexek alapján megállapítható (6. táblázat), hogy ez a hálózat a 30 perces időlépcsőben is képes volt felülmúlni az ilyen rövid időtávon rendkívül jól teljesítő perzisztencia prognózis előrejelzését. Természetesen a perzisztencia prognózis az időlépcsők növekedésével egyre rosszabbul teljesít, így a hálózat 1500 méterre vonatkozó HSS indexei a 90 és a 120 perces időlépcsőben is meghaladta a perzisztencia prognózis HSS indexeit.

6. Táblázat: a hálózat és a perzisztencia prognózis teljes 2016-os évre számított 1500 m-es csoportra vonatkozó HSS indexei az egyes időlépcsőkben

29-14-4	30 min	60 min	90 min	120 min
Perz. HSSI_{1500 m}	0,7645	0,6920	0,6078	0,5406
ANN HSSI_{1500 m}	0,7667	0,6853	0,6114	0,5611


A hálózat gyakorlatban 30 percre és mind a négy időlépcsőre január 8-án előrejelzett értékeit a 24. és a 25. ábra mutatja be. A neurális hálózat természetéből adódóan olykor előállíthat negatív látástávolság értékeket is, amelyeket a legalacsonyabb észlelhető

látástávolságnak (50 m) feleltettük meg. Az 22. ábra alapján láthatjuk, hogy 3:30-tól 4:30-ig, 7:30-kor, 10:00-kor, 11:00-kor, 12:30-kor, 14:30-kor, 17:00-kor és 18:30-kor a hálózat a látástávolság 30 perc múlva bekövetkező konkrét értékét jelezte előre. Az előrejelzések ilyen nagy számú beválása egy ilyen változékony látástávolság értékekkel jellemezhető napon nem elhanyagolható teljesítmény, főleg ilyen rövid távon. Emellett még a hálózat több esetben is képes volt (például 2 órakor és 8 órakor) a tendencia irányának ellentétes megváltozását megfelelően előrejelezni. Az ábra alapján az is látható, hogy a hálózat az előző hálózathoz képest több esetben adott jobb közelítést a változás tendenciájáról.



24. Ábra: A hálózat 30 percre vonatkozó előrejelzése (kék árnyalatai) és a *mért MOR* 2016. 01. 28-án

A hálózat négy időlépcsőre vonatkozó előrejelzését bemutató 23. ábra alapján megállapítható, hogy a hálózat kevesebb helyen volt hajlamos a látástávolság felülbecslésére és a 30 perces előrejelzésekhez hasonlóan a többi időlépcsőre is több esetben jól közelítette a változás tendenciáját. A 4 és 6 óra közötti időszakban a valóságnak megfelelően alacsony látástávolságot jelzett előre és az előző hálózattal ellentétben nem reagált túl érzékenyen az éjszakai hőmérséklet megemelkedésére, hanem megközelítőleg a megfelelő időpontra becsülte a látástávolság megugrását. A hálózat délelőtti és a kora délutáni felülbecslése leginkább a délutáni hőmérséklet-emelkedéshez volt köthető.



25. Ábra: A hálózat négy időlépcsőre (30, 60, 90 és 120 percre) vonatkozó előrejelzése (kék árnyalatai) és a *mért MOR* 2016. 01. 28-án

A hálózatok előrejelzése alapján levonhatjuk azt a következtetést, hogy a decimális hálózatok esetében egy kevesebb neuronból álló és kevésbé bonyolult felépítésű hálózat képes viszonylag jó előrejelzést produkálni egy ilyen nehezen előrejelezhető, változóan ködös napon is. Természetesen a hálózatok működését szükséges tovább javítani a pontosabb előrejelzés érdekében, de már az, hogy a hálózatnak a nap jelentős részében valamely időlépcsőre sikerült a változás irányát jól közelíteni, nagy segítséget nyújthat az operatív gyakorlatban.

7.3. A kategóriás hálózatok esettanulmánya

A vizsgálat során a kategóriás hálózatok 2016-os teljes évre vonatkozó teljesítményeit vetettük össze és megnéztük hogyan teljesítenek e hálózatok a kiválasztott napon. Több olyan hálózat is volt, amelyek a teljes évre kiemelkedően jól teljesítettek, viszont a kiválasztott napon a vártnál gyengébb volt az előrejelzése. Ebben a fejezetben küszöbindexek körültekintő megválasztásával olyan hálózatok előrejelzéseit mutatjuk be, amelyek a teljes évre vonatkozóan és a kiválasztott napon gyakorlatban történő alkalmazása során is hasznos információkkal szolgált a perzisztenciához képest.

A kategóriás előrejelzés verifikációját a küszöbindextől való függését vizsgáló fejezetben bemutatott két hálózat (29–28–14–8, Gauss, RPROP, többszörösen csatolt és 29–28–28–8, Gauss, RPROP, sorban csatolt) előrejelzéseire végeztük el január 8-ára vonatkozóan. Az első hálózat²³ 400 m-re vonatkozó küszöbértékeit 0,38-nak, a 800 m-re vonatkozót pedig 0,36-nak választottuk meg, mivel e hálózat küszöbindextől való függését bemutató 13. ábra szerint ennél a küszöbindexeknél minden időlépcsőben jóval a perzisztencia fölött volt a neurális hálózat előrejelzéseiből, a teljes 2016-os évre számított HSS index. Tehát a neurális hálózat 0,38 alatti kimeneti értékeihez 400 m alatti, afelett pedig 400 m feletti kategóriát rendeltünk hozzá és ugyanarra az időlépcsőre vizsgálva 0,36 alatt 800 m alatt, 0,36 fölött pedig 800 m feletti látástávolság kategóriát vettünk figyelembe.

A hálózat és a perzisztencia prognózis HSS indexeit egyes időlépcsőnként összehasonlító 7. táblázat alapján megállapítható, hogy a neurális hálózat előrejelzése minden időlépcsőben meghaladta perzisztencia prognózis előrejelzését a teljes 2016-os évre vonatkozóan.

²³ (29–28–14–8, Gauss, RPROP, többszörösen csatolt, 0,38; 0,36)

A decimális hálózatoknál ugyanilyen felépítésű hálózat működését teszteltük az esettanulmányok segítségével, ám a decimális hálózatok előrejelzéseinek csupán az 1500 m-re vonatkozó HSS indexei haladták meg a perzisztencia prognózis HSS indexeit két időlépcsőben, míg a kategóriás hálózat esetében az előrejelzés minden időlépcsőben meghaladta a perzisztencia 400 és a 800 m-es HSS indexeit. Ebből levonhatjuk azt a következtetést, hogy azonos felépítésű és azonos paraméterekkel tanult hálózatok esetében a kategóriás formátumban tanult hálózat működése eredményesebb, mint a decimális hálózaté.


7. Táblázat: a perzisztencia prognózis és a hálózat 400 és 800 m-re vonatkozó HSS indexeit az egyes időlépcsőkben

	Min	HSSI _{perzisztencia}	HSSI _{ANN}
400 m	30	0,7671	0,7828
	60	0,6591	0,7088
	90	0,5585	0,7002
	120	0,5259	0,6271
800 m	30	0,7724	0,7869
	60	0,6669	0,7232
	90	0,5866	0,6994
	120	0,5456	0,6527

A 26. ábra a hálózat január 8-án különböző időlépcsőben előrejelzett és mért látástávolság kategóriákat mutatja be. Ahogy ezt a decimális hálózatnál is láttuk, egy nagy kihívást jelentő feladatot adtunk a hálózat számára ezen a változóan ködös napon.

A hálózat sok esetben a perzisztenciát jelezte előre, ami azt bizonyítja, hogy a tanuló adatai alapján ezen az időtávon az esetek többségében bevált. A hálózatot a perzisztencia előrejelzése mellett hirtelen változásokat is több esetben képes volt előre jelezni. Például a hálózat 30 perccel korábban pontosan megbecsülte, hogy 6:30-kor 400 m és 800 m között látástávolság 800 m fölé emelkedik. Emellett a látástávolság 400 m alatti látástávolság 10:30-kor 800 m fölé emelkedését is sikerült 90 perccel korábban előrejeleznie.

A hálózat emellett az esetek túlnyomó részében meg tudta határozni, hogy a következő időlépcsőben a látástávolság 800 m alatt vagy felett fog alakulni.



26. Ábra: A hálózat kategorikus (0-400 m / 400-800 m / 800 m felett) előrejelzései és a mért kategóriák

A következő hálózat, amelynek gyakorlatban történő alkalmazását mutatjuk be a küszöbindextől való függést vizsgáló részben elemzett, másik hálózat²⁴. A hálózat küszöbértékeit is a korábban elvégzett vizsgálat (14.ábra) szerint választottuk meg. A 400 m-re vonatkozó 0,36 és a 800 m-re vonatkozó 0,47 küszöbértékeknél a hálózat minden időlépcsőben jól teljesített. A neurális hálózat e küszöbindexekkel kapott 400 m-re és 800 m-re vonatkozó HSS indexeit a perzisztencia HSS indexeivel összevetve az alábbi táblázat mutatja be (8. táblázat). Láthatjuk, hogy a hálózat HSS indexei nem olyan magasak,

²⁴ (29-28-28-8, Gauss aktivációs függvény, RPROP algoritmus, soros kapcsolat, 0,36;0,47)


mint az előző hálózat indexei, viszont ez a hálózat is minden időlépcsőben meghaladja a 400 m-re és a 800 m-re vonatkozó perzisztencia HSS indexeit. A legnagyobb különbség (0,064) a perzisztencia és a hálózat HSS indexe között a 120 perces időlépcsőben, a 400 m-es kategóriában volt.

8. Táblázat: a perzisztencia prognózis és a hálózat 400 és 800 m-re vonatkozó HSS indexeit az egyes időlépcsőkben

	Min	HSS _I _{perzisztencia}	HSS _I _{ANN}
400 m	30	0.767072	0.771388
	60	0.659052	0.687187
	90	0.558479	0.616696
	120	0.525905	0.589705
800 m	30	0.772416	0.772938
	60	0.666864	0.705471
	90	0.586626	0.638417
	120	0.545602	0.599183

A kategóriás hálózat a 31R mérései alapján készült, 2016. 01. 08-ra történő előrejelzéseit a 27. ábra mutatja be. A hálózat a 30 perces és a 60 perces előrejelzésében nagyrészt képes volt előrejelezni, hogy a látástávolság 800 m alatt vagy felett alakul-e.

A hálózat a teljes év során a 90 perces és a 120 perces időlépcsőben teljesített a legjobban a perzisztencia prognózishoz képest és ez a gyakorlatban történő alkalmazása során is meglátszik: 90 perccel korábban előrejelezte, hogy 10:30-ra a 400 m alatti látástávolság 800 m fölé emelkedik; a 800 m feletti látástávolság 16:30-kor bekövetkező 400 m alá csökkenését pedig 120 perccel korábban sikerült előrejeleznie.



27. Ábra: A hálózat kategorikus (0-400 m / 400-800 m / 800 m felett) előrejelzései és a mért kategóriák

Összefoglalás

A kutatás során az volt a célkitűzésünk, hogy a neurális hálózatokat felhasználva olyan ultrarövidtávú, kétórás látástávolság-előrejelzési módszert fejlesszünk ki, amely az operatív előrejelzői gyakorlatba is könnyen integrálható lesz. A látástávolság mint repülés-meteorológiai szempontból kiemelkedő fontossággal bíró időjárási paraméter előrejelzése máig kihívást jelent az előrejelzők számára, mivel a látástávolságot olyan folyamatok határozzák meg, amelyek explicit ismerete hiányos.

A repülésmeteorológiai gyakorlatban a látástávolság nowcasting-ja a következő két órára terjedő időszakra történik, ezért numerikus előrejelzést többek között a nagy számítási igény miatt sem szoktak a gyakorlatban készíteni. A nemzetközi kutatási eredmények azt bizonyítják, hogy e feladat megoldásához a statisztikai alapú modellek nyújtanak leginkább segítséget. A neurális hálózat egy olyan statisztikai modell, amely múltbeli helyzetekből (tanuló adatsor) tanul meg a prediktorok (látástávolságot befolyásoló paraméterek) és a prediktandusz (látástávolság) között alapvető (nemlineáris) összefüggéseket és nem előre meghatározott szabályok alapján hajtja végre a műveletet (numerikus modell), így segítségével kiküszöbölhető a látástávolságot meghatározó bonyolult folyamatok pontos leírása.

Vizsgálataink során a Liszt Ferenc Nemzetközi Repülőtéren telepített ALMOS mérőrendszer 13R, 31L, 13L és 31R pályaküszöbökhöz tartozó transzmisszió méréseit használtuk fel. A műszerek a futópályamenti látótávolságot jól jellemző mért optikai mélységet (MOR) mérik. A mérési adatok 2005. januártól 2016 decemberéig terjedő időszakra álltak rendelkezésre, ebből jelöltük ki a tanulót, a teszt, illetve a referencia adatsort. A FANN programnyelv felépítése lévén lehetővé tette a neurális hálózatok olyan variációinak egy időben történő tanítását, amelyekhez különböző tanulási algoritmusok (soros, kötegelt, RPROP, QuickPROP, SARPROP), aktivációs függvények (Gauss, szigmoid) tartoznak, valamint az egyes hálózatok rejtett rétegeinek számai és a rejtett rétegbeli neuronok számai is eltérőek. Emellett minden hálózatnak elkészítettük a soros és többszörösen kapcsolt változatát.

A vizsgálat során három, egymástól kis mértékben eltérő tanulótanulósorral tanítottuk a különböző felépítésű hálózatokat. A hálózatok prediktoraikat tekintve abban különböztek, hogy a látástávolságot befolyásoló alapvető paraméterek legutóbbi mérései mellett (év napja, óra, hőmérséklet, harmatpont, szélereősség, szélirány és MOR) tartalmaztak-e múltbeli méréseket vagy 5 cm és 20 cm mélységben mért talajhőmérsékletet. Ezzel lehetőségünk volt

megvizsgálni a talajhőmérsékleti adatok és a múltbeli paraméterek befolyását a kategóriás hálózat előrejelzésére.

A tanuló adatsorban az outputot többféle módon adtuk meg a hálózat számára, így tesztelni tudtuk, hogyan teljesít a hálózat ugyanazon kimeneti adatok módosított formájával. Elsőként maga a látástávolság konkrét, négy időlépcsőben mért, méterben kifejezett értékeiből álló outputok-kal tanultak a különböző hálózatok, ezeknek a decimális hálózatok elnevezést adtuk. Mivel a légi társaságok a látástávolság különböző kategóriáinak pontos meghatározását várják el az időjárás előrejelzőktől, ezért vizsgálataink során a látástávolság kategóriák minél pontosabb előrejelzése érdekében ugyanezen tanuló adatsorok output-jain egy átalakítást végeztünk el: az egyes időlépcsőkben mért látástávolságokhoz kategóriaváltozókat rendeltünk. A hálózatok előrejelzéseinek értékeléséhez a Heidke Skill Score (HSS) verifikációs indexet használtuk fel. Mivel az ultrarövidtávú előrejelzésnek akkor van információ értéke, ha az ilyen rövid időtávon kifejezetten jól teljesítő perzisztencia prognózist képes meghaladni, ezért a HSS indexek különbségeinek kinyerésével tudtuk kiszűrni, hogy melyek azok a hálózatok, amelyek a referencia adatbázison alkalmazva a perzisztenciához képest információ többlettel szolgáltak. A kiszűrt hálózatokkal végzett különféle vizsgálatok során a következő eredmények születtek:

- Három azonos felépítésű (topológia, algoritmus, aktivációs függvény, kapcsolattípus), de különböző számú prediktorral működő hálózatokat összehasonlítva a hálózat legjobb előrejelzései akkor születtek a 2016-os évre vonatkozóan, ha a prediktorok részét képezte a talajhőmérséklet és a néhány időlépcsővel korábbi mérési adatok is.
- A többi hálózathoz képest az esetek nagy részében kevésbé jól teljesítő decimális hálózat hatásvizsgálata során láthattuk, hogy a hálózat képes volt követni a valóságban várható változást, ha a szélsőbesség, a harmatpont és a hőmérséklet bemeneti mérési értékeit megváltoztattuk. A vizsgálat során a szélsőbesség és a harmatpont megváltozására kisebb, míg a hőmérséklet megváltozására nagyobb mértékű érzékenységet mutatott a hálózat előrejelzése.
- A kategóriás hálózat előrejelzését nagyban meghatározza, hogy a hálózat tesztelése során milyen küszöbértékeket választunk meg a kategóriák, azaz a 0 és az 1 kimenet szétválasztásához, így további szabadsági fok nyílik a hálózatok előrejelzésének javítására.
- Az összes általunk vizsgált hálózat variáció HSS indexét a perzisztenciával összevetve a legjobban teljesítő hálózat egy talajhőmérséklettel és múltbeli paraméterekkel tanult kategóriás hálózat volt, amelynek a 2016-ra vonatkozó HSS indexei a 400 m-es

kategóriában 0,14-dal, a 800 m-es kategóriában pedig 0,12-dal haladta meg a perzisztenciát a 90 perces időlépcsőben. E különbség nem elhanyagolható, mivel általában századnyi különbségek voltak jellemzőek.

- A kategóriás hálózat előrejelzései a teljes évet tekintve a 30 perces és a 60 perces időlépcsőkben kisebb mértékben, a nagyobb időlépcsőkben jóval meghaladták a perzisztencia prognózist a 2016-os évre vonatkozó HSS indexek alapján.
- Az időlépcsők növekedésével a kategóriás hálózatok előrejelzésének HSS indexei az időlépcsők növekedésével egyre nagyobb mértékben haladták meg a perzisztencia prognózis HSS indexeit 400 m-re és 800 m-re vonatkozóan is.
- A kiválasztott kategóriás hálózat tanulóadatainak talajhőmérséklettel történő kiegészítése a hálózat jobb előrejelzését eredményezte a 30 perces időlépcsőre vonatkozóan, viszont a 60 perces, 90 perces és 120 perces időlépcsőkben azok a hálózatok előrejelzései bizonyultak pontosabbnak, amelyekben a múltbeli paraméterek is szerepeltek a prediktorok között.

Esettanulmány segítségével megvizsgáltuk, hogy a talajhőmérséklettel és a múltbeli paraméterekkel tanult hálózatok hogyan teljesítenek egy előrejelzés szempontjából nagy kihívást jelentő, változóan ködös napon. A hálózatok gyakorlatban történő alkalmazása során a következőket figyeltük meg:

- A decimális hálózatok 30 perces előrejelzései általában jól közelítették a valóságban mért látástávolságot és annak várható tendenciáját. A kevesebb neuronból álló, egyszerűbb felépítésű decimális hálózat több esetben a látástávolság konkrét értékét jelezte előre 30 perccel korábban.
- A decimális hálózatok az időlépcsők növekedésével hajlamosak a látástávolság felülbecslésére, ha túlságosan érzékenyen reagálnak a hőmérséklet emelkedő tendenciájára.
- A kategóriás hálózatok esetében előfordult, hogy a látástávolság kategóriájának megváltozását 90 perccel sikerült jól előrejelezni.
- A kategóriás hálózatok az esetek túlnyomó többségében meg tudták határozni, hogy az előrejelzett időlépcsőben 800 m alatt vagy felett alakul a látástávolság.

A vizsgálataink alapján a legfontosabb eredmény az, hogy a hálózatok teljesítményére hatással volt, hogy ugyanazon tanuló adatokat milyen formában bocsátottuk a tanítási algoritmus rendelkezésére. Azonos felépítésű és azonos paraméterekkel tanult decimális és kategóriás hálózatok működését összehasonlítva a neurális hálózatok számára sokkal tanulhatóbb formának bizonyult a kategóriás besorolást tartalmazó adatbázis, mivel

előrejelzései több esetben hordoztak információtöbbletet a perzisztencia prognózishoz képest, mint a decimális hálózatok előrejelzései, így érdemes ebben az irányban tovább vizsgálni. Természetesen a hálózatok működését szükséges fejleszteni a pontosabb előrejelzés érdekében, de már az is nagy segítséget nyújtana az előrejelző szakemberek számára, hogy a hálózatnak a nap jelentős részében valamely időlépcsőre sikerül a változás irányát jól közelíteni. Ha sikerül még tovább pontosítani a becsléseket, akkor bemutatott módszertan akár a repülésmeteorológiában – ahol a MOR jövőbeli változásának iránya is fontos információ – az operatív gyakorlatban is alkalmazhatóvá válhat.

További terveink között szerepel az, hogy a neurális hálózatokat nem csak felszíni mérések és a látástávolság közötti kapcsolat feltárására alkalmazzuk, hanem az egyes változók Liszt Ferenc Nemzetközi Repülőtéren telepített SODAR légköri profilméréseit és modell kimeneti értékeit is felhasználjuk a látástávolság előrejelzése során.

Köszönetnyilvánítás

Köszönettel tartozom témavezetőmnek, Kardos Péternek, aki rengeteg hasznos tanáccsal látott el diplomamunkám írása során és a közös munka alatt építő javaslatai elősegítették szakmai fejlődésem. Köszönet illeti dr. Pongrácz Rita belső konzulensem, aki mindvégig támogatta munkámat. Köszönöm a HungaroControl Zrt.-nek és meteorológusainak, hogy a nyári gyakorlat során segítőkészségük gyanánt rengeteg hasznos ismeretet szerezhettem. Köszönöm páromnak, hogy mellettem állt és lelkesített a nehéz időszakokban is. Köszönöm családomnak, akik mindvégig bíztattak és támogattak egyetemi éveim alatt.

Irodalomjegyzék

- Bergot, T., és Guedalia, D., 1994: Numerical Forecasting of Radiation Fog. Part I: Numerical Model and Sensitivity Tests. *Monthly Weather Review*, doi:10.1175/1520-0493(1994)122<1218:NFORFP>2.0.CO;2
- Bottyán, Z., Hámori, I., és Sárközi, S., 2000: A mozgó köd jelenség első ismertetése, mint a repülésre veszélyes tényező — egy helikopter katasztrófa döntő tényezője. *Repüléstudományi közlemények*, 12, 239–250.
- Bottyán, Z., 2008: Kísérlet egy repülőgép-katasztrófa meteorológiai viszonyainak rekonstrukciójára - a Malév HA-MOH repülőgépének balesete. *Repüléstudományi Közlemények*, 20, 12.
- Bremnes, J.B., és Michaelides, S.C., 2007: Probabilistic visibility forecasting using neural networks. *Pure and Applied Geophysics*, 164, 1365–1381. doi:10.1007/s00024-007-0223-6
- Deák, B., 2010: A látástávolság és a köd rövidtávú előrejelzésének lehetőségei. 69. p.
- Duynerkerke, P.G., 1991: Radiation Fog: A Comparison of Model Simulation with Detailed Observations. *Mon. Wea. Rev.*, doi:10.1175/1520-0493(1991)119<0324:RFACOM>2.0.CO;2
- Ellrod, G.P., és Gultepe, I., 2007: Inferring low cloud base heights at night for aviation using satellite infrared and surface temperature data. *Pure and Applied Geophysics*, 164, 1193–1205. doi:10.1007/s00024-007-0214-7
- Fabbian, D., de Dear, R., és Lelhyett, S., 2007: Application of Artificial Neural Network Forecasts to Predict Fog at Canberra International Airport. *Weather and Forecasting*, 22, 372–381. doi:10.1175/WAF980.1
- Fahlman, S.E., 1988: An empirical study of learning speed in back-propagation networks. *Neural Networks*, 6, 1–19.
- Fazekas, I., 2013: *Neurális hálózatok*. Debreceni Egyetem, Informatikai Kar.
- Fricke, C., és Kardos, P., 2017: Neurális hálózatok alkalmazása a látástávolság ultrarövidtávú előrejelzésében. *Repüléstudományi Közlemények*, XXIX, 103–112.
- 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. doi:10.1016/S1352-2310(97)00447-0
- Glahn, H.R., és Lowry, D. a., 1972: The Use of Model Output Statistics (MOS) in Objective Weather Forecasting. *Journal of Applied Meteorology*, doi:10.1175/1520-0450(1972)011<1203:TUOMOS>2.0.CO;2
- Gulpe, I., Müller, M.D., és Boybeyi, Z., 2006: A new visibility parameterization for warm-fog applications in numerical weather prediction models. *Journal of Applied Meteorology and Climatology*, 45, 1469–1480. doi:10.1175/JAM2423.1
- Gulpe, I., Tardif, R., Michaelides, S.C., Cermak, J., Bott, A., Bendix, J., Müller, M.D., Pagowski, M., Hansen, B., Ellrod, G., Jacobs, W., Toth, G., és Cober, S.G., 2007: Fog Research: A Review of Past Achievements and Future Perspectives. *Pure Appl. Geophys.*, 164, 1121–1159. doi:10.1007/s00024-007-0211-x
- Gulpe, I., és Ellrod, G.P., 2013: *Fog and Boundary Layer Clouds: Fog Visibility and Forecasting*, Journal of Chemical Information and Modeling. 1689–1699 p. doi:10.1017/CBO9781107415324.004
- Habobács, K., Tuba, Z., Wantuch, F., Bottyán, Z., és Zoltán, V., 2013: A pilóta nélküli légijárművek meteorológiai támogató rendszerének kialakítása és alkalmazhatóságának bemutatása esettanulmányokon keresztül. *Repüléstudományi Közlemények*, XXV., 405–421.
- Hadobács, K., és Bottyán, Z., 2015: Neurális hálózatok és alkalmazásuk a repülésmeteorológiában. *Repüléstudományi Közlemények*, XVII, 36–48.
- Hansen, B., 2007: A Fuzzy Logic-Based Analog Forecasting System for Ceiling and Visibility. *Weather and Forecasting*, 22, 1319–1330. doi:10.1175/2007WAF2006017.1
- Haykin, S., 1995: *Neural networks. A comprehensive foundation. 2nd Edition.*, The Lancet. 1712 p. doi:10.1016/S0140-6736(95)92880-4
- Hung, N.Q., Babel, M.S., Weesakul, S., és Tripathi, N.K., 2008: An artificial neural network model for rainfall forecasting in Bangkok, Thailand. *Hydrology and Earth System Sciences*, 13, 1413–1425. doi:10.5194/hess-13-1413-2009
- ICAO, 2016: *Meteorological Service For International Air Navigation - Annex 3*, 16th ed.
- Jacobs, W., Nietosvaara, V., Bott, A., Bendix, J., Cermak, J., Michaelides, S., és Gulpe, I., 2008: *Short range forecasting methods of fog, visibility and low clouds - COST 722*, Final Repo. ed. Office for Official Publications of the European Communities, Luxembourg, 499 p.
- Jain, A.K., és Mao, J., 1996: Artificial Neural Network: A Tutorial. *Communications*, 29, 31–44. doi:10.1109/2.485891
- Kaastra, I., és Boyd, M., 1996: Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, 10, 215–236.
- Kandya, A., Sm, S.N., és Tiwari, V.K., 2012: Forecasting the Tropospheric Ozone using Artificial Neural Network Modelling Approach: A Case Study of Megacity Madras, India 1–5. doi:10.4172/2165-

- Leyton, S.M., és Fritsch, J.M., 2003: Short-Term Probabilistic Forecasts of Ceiling and Visibility Utilizing High-Density Surface Weather Observations. *Wea. Forecasting*, 18, 891–902. doi:10.1175/1520-0434(2003)018<0891:SPFOCA>2.0.CO;2
- Lippman, R.P., és Lippman, R.P., 1987: An Introduction to Computing with Neural Nets. *IEEE ASSP Magazine*, 4–22. doi:10.1109/MASSP.1987.1165576
- Marzban, C., és Stumpf, G.J., 1996: A neural network for tornado prediction based on Doppler radar-derived attributes. *Journal of Applied Meteorology*, doi:10.1175/1520-0450(1996)035<0617:ANNFTP>2.0.CO;2
- Marzban, C., és Stumpf, G.J., 1998: A Neural Network for Damaging Wind Prediction. *Weather and Forecasting*, 13, 151–163. doi:10.1175/1520-0434(1998)013<0151:ANNFDW>2.0.CO;2
- Marzban, C., Leyton, S., és Colman, B., 2007: Ceiling and Visibility Forecasts via Neural Networks. *Wea. Forecasting*, 22, 466–479. doi:10.1175/WAF994.1
- Müller, M.D., Schmutz, C., és Parlow, E., 2007: A one-dimensional ensemble forecast and assimilation system for fog prediction. *Pure and Applied Geophysics*, 164, 1241–1264. doi:10.1007/s00024-007-0217-4
- Nagy, R., 2014: Új módszerek vizsgálata a légiforgalmi irányításban használatos, látástávolságra vonatkozó döntéstámogató célprognózisok készítésében Budapest Liszt Ferenc Nemzetközi Repülő téren. Eötvös Loránd Tudományegyetem, 69 p.
- Pagowski, M., Gultepe, I., és King, P., 2004: Analysis and Modeling of an Extremely Dense Fog Event in Southern Ontario. *Journal of Applied Meteorology*, 43, 3–16. doi:10.1175/1520-0450(2004)043<0003:AAMOAE>2.0.CO;2
- Pasini, A., Pelino, V., és Potestà, S., 2001: A neural network model for visibility nowcasting from surface observations: Results and sensitivity to physical input variables. *Journal of Geophysical Research: Atmospheres*, 106, 14951–14959. doi:10.1029/2001JD900134
- Porter, C., 1995: Short-term high resolution forecasting of fog, cloud ceiling heights, and visibility with the PSU/NCAR mesoscale model. The Pennsylvania State University, 197 p.
- Puca, S., Biron, D., De Leonibus, L., Melfi, D., Rosci, P., és Zauli, F., 2005: A neural network algorithm for the nowcasting of severe convective systems. *Proceedings of the 2005 IEEE International Conference on Computational Intelligence for Measurement Systems and Applications, CIMS A 2005*, 2005, 81–84. doi:10.1109/CIMS A.2005.1522831
- Riedmiller, M., és Braun, H., 1993: A direct adaptive method for faster backpropagation learning: The RPROP algorithm. *IEEE International Conference on Neural Networks - Conference Proceedings, 1993-Janua*, 586–591. doi:10.1109/ICNN.1993.298623
- Riedmiller, M., 1994: Advanced supervised learning in multi-layer perceptrons—from backpropagation to adaptive learning algorithms. *Computer Standards & Interfaces*, 16, 265–278. doi:10.1016/0920-5489(94)90017-5
- Russel, S., és Norvig, P., 2003: *Artificial Intelligence. A modern approach. 2nd edition*. Pearson Education, New Jersey, 1132 p.
- Sándor, V., és Wantuch, F., 2005: *Repülésmeteorológia*, Második ja. ed. Országos Mteteorológiai Szolgálat, Budapest, 272 p.
- Shank, D.B., Hoogenboom, G., és McClendon, R.W., 2008: Dewpoint temperature prediction using artificial neural networks. *Journal of Applied Meteorology and Climatology*, 47, 1757–1769. doi:10.1175/2007JAMC1693.1
- Treadgold, N.K., és Gedeon, T.D., 1998: Simulated annealing and weight decay in adaptive learning: The SARPROP algorithm. *IEEE Transactions on Neural Networks*, 9, 662–668. doi:10.1109/72.701179
- Tuba, Z., 2008: Egy eseménytelen nap margójára avagy egy kódadvekcio tanulsagai 2008.
- Tuba, Z., Vidnyánszky, Z., Bottyán, Z., és Wantuch, F., 2013: Application of Analytic Hierarchy Process in fuzzy logic-based meteorological support system of unmanned aerial vehicles. *Academic and Applied Research in Public Management Science*, 12, 221–228.
- Tuba, Z., és Bottyán, Z., 2017: Fuzzy logic-based analogue forecasting and hybrid modelling of horizontal visibility. *Meteorology and Atmospheric Physics*, doi:10.1007/s00703-017-0513-1
- Wang, K., Zhao, H., Liu, A., és Bai, Z., 2009: The Risk Neural Network Based Visibility Forecast. *2009 Fifth International Conference on Natural Computation*, 338–341. doi:10.1109/ICNC.2009.152
- Wantuch, F., 2001: Visibility and fog forecasting based on decision tree method. *Idojaras*, 105, 29–38.
- Wantuch, F., Bottyán, Z., és Deák, B., 2010: A látástávolság és a köd rövidtávú előrejelzésének lehetőségei, In: Repüléstudományi Konferencia 2010 Szolnok.
- Wantuch, F., 2014: Módszerek a látástávolság előrejelzésére. *Repüléstudományi Közlemények*, XXVI, 35–42.
- Wilson, L.J., és Vallée, M., 2002: The Canadian Updateable Model Output Statistics (UMOS) System: Design and Development Tests. *Weather and Forecasting*, 17, 206–222. doi:10.1175/1520-0434(2002)017<0206:TCUMOS>2.0.CO;2

- WMO, 1991: *Lectures presented at the WMO training workshop on the interpretation of NWP products in terms of local weather phenomena and their verification - Programme on Short- and Medium-Range Weather Prediction Research (PSMP)*. WMO, Geneva.
- WMO CAeM Working Group, 1999: *Methods of Interpreting Numerical Weather Prediction Output for Aeronautical Meteorology*, 2. ed. 123 p.
- Zhang, G., Patuwo, B.E., és Hu, M.Y., 1998: Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14, 35–62. doi:10.1016/S0169-2070(97)00044-7
- Zhou, B., Du, J., Gultepe, I., és Dimego, G., 2012: Forecast of low visibility and fog from NCEP: Current status and efforts. *Pure and Applied Geophysics*, 169, 895–909. doi:10.1007/s00024-011-0327-x

Internetes hivatkozások:

www.eumetrain.org
www.wetterzentrale.de
www.weather.uwyo.edu/upperair/europe.html
www.zamg.ac.at