

**Eötvös Loránd Tudományegyetem
Természettudományi Kar
Földrajz- és Földtudományi Intézet
Meteorológiai Tanszék**

**Új módszerek vizsgálata a légiforgalmi irányításban
használatos, látástávolságra vonatkozó döntéstámogató
célprognózisok készítésében Budapest Liszt Ferenc
Nemzetközi Repülőtéren**

DIPLOMAMUNKA



Készítette:

Nagy Roland

II. éves Meteorológus mesterszakos hallgató
Időjárás-előrejelző szakirány

Témavezető:

Kardos Péter



HungaroControl
Magyar Légiforgalmi Szolgálat Zrt.

HungaroControl Magyar Légiforgalmi Szolgálat Zrt., FMET részlegvezető

Tanszéki konzulens:

Soósné dr. Dezső Zsuzsanna

ELTE TTK, Meteorológiai Tanszék

Budapest, 2014.

Tartalomjegyzék

1. Bevezetés.....	4
2. A látástávolság mérésének és előrejelzésének szerepe	6
3. Szakirodalmi áttekintés.....	10
3.1. Látástávolság-előrejelzési módszerek.....	10
3.1.1. Lineáris regressziós modellek.....	10
3.1.2. Neurális hálózatok	11
3.1.3. Tapasztalati összefüggések	13
3.2. Kategorikus előrejelzések verifikációja.....	15
4. Anyag és módszer	19
4.1. Felhasznált adatok.....	19
4.2. Az alkalmazott látástávolság-előrejelző algoritmus	20
4.2.1. A <i>FOGSI</i> index	20
4.2.2. A Módosított <i>FOGSI</i> (<i>M. FOGSI</i>) index	22
4.3. Neurális hálózatok	27
4.3.1. Felépítés	27
4.3.2. Az előrecsatolt neurális hálózatok	28
4.3.3. A hiba-visszaterjesztési algoritmus	30
4.3.4. A neurális hálózat tervezése	34
4.3.5. A látástávolság előrejelzéséhez készített neurális hálózat.....	36
4.3.5.1. Perfekt Prognosztikai megközelítésű neurális hálózat	37
4.3.5.2. Nowcasting célú neurális hálózat	39
5. Eredmények	41
5.1. A látástávolság-előrejelző algoritmusok során előálló látástávolság-kategóriák verifikációja	41
5.2. Neurális hálózatok	43
5.2.1. Perfekt Prognosztikai megközelítésű előrejelzések verifikációja.....	43

5.2.1.1. Érzékenységi vizsgálat	48
5.2.1.2. Esettanulmány – A 2013. november 16–17-i ködös helyzet elemzése	51
5.2.2. Nowcasting célú előrejelzések verifikációja.....	54
5.2.2.1. Esettanulmány – A 2013. november 1–2-i ködös helyzet elemzése	59
6. Összefoglalás	62
7. Jövőbeli tervek	63
8. Köszönetnyilvánítás.....	64
9. Irodalomjegyzék	65
10. Függelék.....	68

1. Bevezetés

A térben és időben jelentős változékonysággal rendelkező horizontális látástávolság nagy pontosságú előrejelzése napjainkban is komoly prognosztikai kihívást jelent. Ennek oka, hogy a komplex mikrofizikai, valamint a szinoptikus-, mezo-, és további mikroskálájú folyamatok látástávolságra gyakorolt hatása egzakt módon nem számszerűsíthető. A légiközlekedéssel szemben támasztott egyre nagyobb és szigorúbb követelmények miatt – az előrejelezhetőség korlátai ellenére – egyre fontosabb célként fogalmazódik meg a rossz látási viszonyok minél pontosabb prognosztizálása Budapest Liszt Ferenc Nemzetközi Repülőtéren is. Ezt a repülőtér meteorológiai műszerezettsége is bizonyítja, ugyanis a két futópálya mentén hat transzmisszométer található, amelyek az egyes pályák irányában az irányszerinti látásértékekkel ekvivalensnek tekinthető meteorológiai optikai mélységet (MOR) mérik. Munkám során ezeken a MOR értékeken túlmenően a repülőtéri mérőhálózat földfelszíni, valamint az OMSZ Marczell György Obszervatórium által mért magassági adatokkal (TEMP-távirat) végeztem vizsgálatokat.

Diplomamunkám fő célkitűzése, hogy különböző statisztikai módszerek alkalmazásával minél szorosabb kapcsolatot létesítsek a meteorológiai állapothatározók, valamint a horizontális látástávolság között, elősegítve ezzel a légiforgalmi irányításban használatos ultrarövidtávú, rövidtávú és középtávú döntéstámogató célprognózisok készítését.

Kutatásaim során két módszerrel végeztem vizsgálatokat. Elsőként dr. Wantuch Ferenc *látástávolság-előrejelző algoritmusát* adaptáltam. Ebben az esetben az egyes látástávolság-kategóriák meghatározása *Perfekt Prognosztikai (PP)* megközelítéssel egy széleskörű statisztikai elemzések során kapott index (*FOGSI*), a tőle függő lineáris regressziós egyenes, valamint további fizikai elkülönítést jelentő döntési fa alkalmazásán alapszik. Vizsgálataim során az index és a döntési fa olyan módosítását végeztem el, amellyel az általam tanulmányozott referencia- és tesztidőszakra a kategória előrejelzések verifikációja során alkalmazott mérőszámok tekintetében az eredeti módszerhez képest többnyire kedvezőbb értékek nyerhetők.

A látástávolság prognosztizálására alkalmazott másik módszer a hazai meteorológiai gyakorlatban még kevésbé ismert *neurális hálózatok* módszere, amelynek működése egy többváltozós, nemlineáris regresszió alapul. A módszer elnevezése onnan ered, hogy nagyszámú bemenő adatot (prediktort – jelen esetben a meteorológiai elemeket)

idegrendszerűen elágaztatunk, majd különböző súlyok és nemlineáris transzformációk megfelelő kombinációinak alkalmazásával becslést adunk a látástávolság várható értékére.

Dolgozatom *második fejezetében* a repülőtéri látástávolság-mérések és -előrejelzések szerepéről ejtek szót. A *harmadik fejezetben* áttekintést nyújtok a látástávolság előrejelzésére irányuló hazai és nemzetközi szakirodalomról, ahol részletesebben kitérek a látástávolság prognózisához alkalmazott lineáris regressziós modellekre, valamint a neurális hálózatokkal kapcsolatos kutatások ismertetésére. Ezután a *negyedik fejezetben* a korábban vázolt két módszert részletesen bemutatom. Mivel a neurális hálózatokat Magyarországon az operatív meteorológiai gyakorlatban még kevésbé alkalmazták, ezért azok elméleti hátterét is részletezni fogom. Az *ötödik fejezetben* az említett módszerek alkalmazása során előálló eredményeket, míg a *hatodik fejezetben* munkám rövid összegzését ismertetem. Végül a *hetedik fejezetben* bemutatásra kerülnek a látástávolság előrejelzésére irányuló neurális hálózatokkal elvégezhető, jövőbeli továbbfejlesztési lehetőségek.

2. A látástávolság mérésének és előrejelzésének szerepe

A repülés lételeme a levegő, a repülésmeteorológia ezért is a légiközlekedés egyik nélkülözhetetlen szakterülete (Takács, 2010). A repülőgépek megjelenése, a légiközlekedés térhódítása szükségszerűen megkívánta a repülésbiztonsági kockázatot jelentő időjárási jelenségek minél pontosabb megismerését és prognózisát egyaránt. Napjainkban a meteorológiai mérések és előrejelzések pontossági kritériumait már szigorú szabványok és ajánlott eljárások határozzák meg, amelyeket az ICAO¹ Tanácsa először 1948. április 16-án fogadott el a Nemzeti Polgári Repülési Egyezmény 37. cikkelyében foglalt előírásoknak megfelelően. A dokumentum a *III. Annex* jelölést kapta, *Szabványok és ajánlott eljárások – Meteorológiai Kódok* címen, amelyen utoljára 2013-ban végeztek módosításokat, jelenleg is ez utóbbi kiadás van érvényben (ICAO, Annex 3, 2013).


A repülésbiztonságot és a repülőtér üzemeltetési feladatait korlátozó meteorológiai elemek közül a horizontális látástávolság kiemelt jelentőséggel bír, ezért az *Annex 3* annak észlelési, valamint előrejelzési követelményeit részletesen taglalja. A talajmenti szélre, az aktuális időképre, a felhőzetre, a hőmérsékletre, a harmatpontra, a tengerszintre átszámított légnyomásra és a felhőzetre vonatkozó karakterisztikák mellett a látástávolság félóránként megfigyelt értékeit is pontos kritériumoknak megfelelően, METAR² táviratokban kell közölni. Az észlelők által megfigyelt, horizonton domináns látásértéket 800 méter alatti látástávolság esetén 50 méteres, 800 és 5000 méter közötti látástávolságnál 100 méteres, míg 5000 és 10000 méter közöttinél 1000 méteres lépésekben kell megadni. Mivel a 10 km feletti látásértékek már nem jelentenek repülésbiztonsági kockázatot, ezért azok további elkülönítésére nincs szükség. A horizonton domináns látásértékkel szemben a pilóták számára azonban az a látástávolság fontos, amelyről a pályafényeket látják. Ennek az igénynek a kielégítésére az ICAO bevezette a futópálya menti látástávolság (rövidítése RVR³) fogalmát (Sándor és Wantuch, 2005; ICAO, Annex 3, 2013). Budapest Liszt Ferenc Nemzetközi Repülőtér két futópályája mentén három-három transzmisszométer található, amelyek az egyes pályák irányában az irányszerinti látásértékekkel ekvivalensnek tekinthető meteorológiai optikai mélységet (MOR) mérik. A transzmisszométer (**1. ábra**) egy fénykibocsátó adóból (**a**) és egy vele szemben elhelyezett fotocellás vevőből (**b**) áll.

¹ ICAO: International Civil Aviation Organization, Nemzetközi Polgári Repülési Szervezet.

² METAR: Rendszeres repülőtéri meteorológiai jelentés.


³ RVR (Runway Visual Range): Az a távolság, amelyről a pálya középvonalán elhelyezkedő repülőgép pilótája látja a futópálya felületén levő jelzéseket, vagy a futópálya szegélyfényeit, illetve annak középvonalát meg tudja állapítani.

Az, hogy a kibocsátott fény hány százaléka érkezik az adóból a vevőbe, a köztük lévő vízszintes légoszlop átlátszóságától függ, ami kapcsolatba hozható a látástávolsággal (Sándor és Wantuch, 2005). A transzmisszométer által mért látástávolság elméleti minimuma 0 méter, míg maximális értéke 10000 méter. A műszer tehát az ennél nagyobb, repülésbiztonsági kockázatot nem jelentő látásértékeket nem számszerűsíti.



1. **ábra:** Budapest Liszt Ferenc Nemzetközi Repülőtér egyes futópálya 13R pályaküszöb mentén elhelyezkedő látástávolság mérő (a) Tx-adó és (b) Rx-15 m vevő berendezése.

A transzmisszométerek elhelyezkedését a repülőtér domborzati térképén is megfigyelhetjük (2. **ábra**). A látástávolság futópálya irányában megfigyelt műszeres megfigyeléseit is jelenteni kell a METAR táviratokban, amennyiben a pályamenti, vagy a horizonton domináns látástávolság, vagy mindkettő értéke 1500 méter alatt van. Ekkor már szigorúbb pontossági követelményeknek eleget téve az RVR értékét 400 méter alatt 25 méteres, 400 és 800 méter között 50 méteres, 800 méter felett pedig 100 méteres lépcsőben kell megadni a táviratban.



2. **ábra:** Budapest Liszt Ferenc Nemzetközi Repülőtér domborzati térképe. Az ábrán a meteorológiai műszerek, többek között a látástávolság-mérők elhelyezkedése is megfigyelhető.

A fent leírt követelmények jól érzékeltetik a látástávolság repülőtereken betöltött szerepének fontosságát, amelyre a repülés történetében számtalan, rossz látási viszonyok miatt bekövetkező baleset is felhívta a figyelmet. Ilyen volt többek között a 9 fős személyzettel, utasok nélkül Berlin Schönefeld (ETBS) repülőtérrel Budapest Ferihegre (LHBP) érkező MALÉV 801/A járatának 1975. január 15-én bekövetkezett szerencsétlensége. A szovjet gyártmányú IL-18V típusú repülőgép személyzetét már az útvonalon a ferihegyi időjárási helyzet romlásáról tájékoztatták: a látás 500, az RVR 1000 méterre csökkent, a korábbi nyitott köd bezárult, és csak függőleges látást lehetett megállapítani, melynek értéke 30 méter volt (Bottyán, 2008). Ennek ellenére a pilóta háromszor megpróbálta letenni a gépet a nagy ködben, de utoljára végzetesen elvettette a manővert: 120 méterrel a kifutópálya középvezetékétől balra, és mintegy 1,3 kilométerrel az ideális földet érési pont után a gép a földbe csapódott.



3. ábra: Korlátozott látási viszonyok egy repülőtéri futópálya mentén.
(Forrás: <http://www.mkirste.de/series/industry-traffic/de/#id326>)

A **3. ábra** jól tükrözi a futópálya irányában megfigyelhető korlátozott látási viszonyokat. A rossz látási körülmények fennállása elsősorban a VFR⁴ szerinti repülések korlátozását vonja maga után. A jelenleg érvényben lévő 14/2000. (XI. 14.) KöViM rendelet, valamint a Budapest TWR (irányítótorny) munkatechnológia is előírja, hogy 5000 méter alatti látástávolság esetén a VFR repüléseket a CTR-ben (toronykörzet) fel kell függeszteni. A látási körülmények további romlása esetén Budapest Liszt Ferenc

⁴ VFR (Visual Flight Rules): Látvarepülési szabályok.

Nemzetközi Repülőtéren további működési fázisok lépnek életbe. A Felkészülési fázis (Preparation Phase) akkor, ha bármely $RVR \leq 800$ méternél, a rossz látási körülmények között alkalmazandó eljárások 1. fázis (Operation Phase 1./LVP1), valamint a rossz látási körülmények között alkalmazandó eljárások 2. fázis (Operation Phase 2./LVP2) pedig azokban az esetekben, ha bármely $RVR \leq 600$, illetve 400 méternél.

Látható tehát, hogy 1000 méternél kisebb látásértékek esetén is a látástávolság szigorúan vett küszöbértékei szerint kerülnek elkülönítésre a repülőtér működési fázisai. Ez az igény megköveteli, hogy a döntéshozók számára a megfelelő időben, a lehető legpontosabb látástávolság-prognózisokat szolgáltatassuk. Munkánk során e cél elérésére törekedtünk. Amíg a látástávolság-előrejelző algoritmusnál három látástávolság-kategória ($MOR \leq 1000$ m; 1000 m < $MOR \leq 5000$ m; 5000 m < MOR) helyes elkülönítését tartottuk szem előtt, addig a neurális hálózatokkal a mért és becsült látásértékek közötti hiba minimalizálását helyeztük előtérbe.

3. Szakirodalmi áttekintés

3.1. Látástávolság-előrejelzési módszerek

Napjainkban egyre több kutatási program foglalkozik a látástávolság előrejelzésének problémakörével, amelyek közül Európában a *COST* elnevezésű kormányközi program nyújt nemzetközi együttműködési lehetőséget. A program célja a rossz látási viszonyok társadalomra, közlekedési vállalatokra és légitársaságokra gyakorolt negatív hatásainak minimalizálása (*Niestovaara és Jacobs, 2008*). E célok eléréséhez azonban megbízható előrejelzési produktumokra van szükség. A programban résztvevő munkacsoportok kutatásai rávilágítanak arra, hogy a horizontális látástávolság minél pontosabb prognózisához a látástávolságot meghatározó komplex meteorológiai folyamatok megismerésén keresztül, múltbeli tapasztalati megfigyelések, valamint különböző numerikus és statisztikai módszerek alkalmazásával juthatunk el. A szakirodalomban fellelhető módszerek közül elsősorban azokat a statisztikai módszereket ismertetjük részletesebben, amelyek felhasználásával jelen kutatás során vizsgálatokat végeztünk. Nemcsak a *COST* program keretein belüli, hanem azon kívüli kutatások szakirodalmi hátterét is áttekintjük.

3.1.1. Lineáris regressziós modellek

A statisztikai modellek elsősorban a meteorológiai elemek (prediktorok), valamint a látástávolság között a matematikai statisztika eszközeivel igyekeznek minél szorosabb kapcsolatot létesíteni. Az egyik legelterjedtebb módszer, hogy a látástávolságot a prediktorok függvényében többszörös lineáris regressziós egyenessel közelítik. Ez többféleképpen is lehetséges. Egyrészt *MOS* (Modell kimenet statisztika) megközelítéssel, amelynek lényege, hogy a látástávolság becslése modelleredményekre illesztett lineáris regressziós egyenessel történik (*Vislocky és Fritsch, 1997*). Ennek hátrányai, hogy a modell outputok és az alkalmazott módszerből eredő hibák további hibás értékeket visznek a rendszerbe, valamint az algoritmus is csak az alkalmazott modell adott beállítása mellett működik helyesen. Ez utóbbi probléma kiküszöbölhető, ha a modell-kimenetek helyett a meteorológiai elemek és a látástávolság közötti tényleges fizikai kapcsolatokat térképezzük fel. Ez utóbbi megközelítéssel *Ruangjun és Exell (2008)* olyan módszert fejlesztettek ki, amely a téli évszakban az egyes meteorológiai állapothatározók és a látástávolság helyi idő szerint 1 órákor, valamint 5 órákor mért értékeiből többszörös lineáris regressziós egyenest

képezve valószínűségi becslést adnak a helyi idő szerint reggel 7 órakor várható látástávolságra, a Bangkoki Nemzetközi Repülőtérre. Munkájuk során vizsgálataikat a látástávolság logaritmikus értékeivel végezték, amelynek oka a logaritmus függvény tulajdonságaiban keresendő. A függvény az előrejelzés szempontjából kiemelt jelentőségű kis látásértékekre nagyobb változékonyságot mutat, mint a kevésbé fontos, nagyobb látásértékekre. Mivel a módszer nem veszi figyelembe a légkör dinamikai változásait, ezért csak megfelelő körütekintés mellett alkalmazható, főként a hat órával későbbi látástávolság várható értékének statisztikai módon történő becsléséhez.

Az eddigieknél hatékonyabb prognosztikai modellt készíthetünk, ha az előző módszerhez hasonlóan a látástávolság és az egyes prediktorok közötti tényleges fizikai kapcsolatot számszerűsítjük, és ezt építjük be egy dinamikai modellbe, amelynek kimeneteiről feltételezzük, hogy azok tökéletesek. Ezt az eljárást *Perfekt Prognosztikai (PP)* megközelítésnek nevezzük. A dr. Wantuch Ferenc által fejlesztett, a magyarországi operatív előrejelzési gyakorlatban elsőként alkalmazott látástávolság-előrejelző algoritmus (Wantuch, 2001) is ez előbbi megközelítésen alapul. Az algoritmusban az egyes látástávolság-kategóriák meghatározása egy széleskörű statisztikai elemzések során kapott index (FOGSI), a tőle függő lineáris regressziós egyenes, valamint további fizikai elkülönítést jelentő döntési fa alkalmazásán alapszik.

Az ELTE TTK Meteorológiai Tanszéken korábban már Deák Bianka is foglalkozott a látástávolság, valamint a köd rövidtávú előrejelzéseinek lehetőségeivel (Deák, 2010). Diplomamunkájában a Szolnoki Repülőtérre összehasonlító vizsgálatokat végzett az előbb említett látástávolság-előrejelző program, valamint egy analógia keresési módszer (Wantuch et al., 2010) között, amely utóbbi azon a feltételezésen alapul, hogy hasonló időjárási helyzetekhez hasonló látástávolság-értékek tartoznak. Bianka munkája összefoglalásában arra a következtetésre jutott, hogy jó esély van egy klímaadatokon alapuló látástávolság-előrejelző módszer alkalmazására. Jelen munkánk során bár nem állt rendelkezésünkre klimatológiai szempontból elegendő mennyiségű adat, a budapesti repülőtér ALMOS adatbázis nyolc éves adatsorának órás felbontásban rendelkezésünkre álló értékeivel azonban lehetőségünk nyílt arra, hogy több ezer mért adat felhasználásával reprezentatív kapcsolatot létesítsünk a meteorológiai elemek és a látástávolság között.

3.1.2. Neurális hálózatok

Számtalan meteorológiai folyamat pontos megértésének, így előrejelezhetőségének is egyaránt határt szab a folyamatok összetettsége és nemlineáris viselkedése. A komplex

meteorológiai folyamatok minél pontosabb prognosztizálása iránti igény következtében a meteorológiai célú kutatások esetén egyre nagyobb teret hódítanak az ún. *neurális hálózatok*, amelyek működése egy többváltozós, nemlineáris regresszió alapul. A neurális hálózatokat az elmúlt években számos meteorológiai jelenség vizsgálatához alkalmazták, többek között Doppler-radar adatok alapján történő tornádódetektálásra (*Marzban és Stumpf*, 1996), csapadékmennyiség prognosztizálására (*Hall et al.*, 1999; *Khalili et al.*, 2011), valamint zivatar előrejelzésre (*Ali et al.*, 2011) is. Neurális hálózatokat nemcsak általános, hanem repülésmeteorológiai célú prognosztikai feladatok ellátásához is készítettek, többek között repülőgépek felületi jegesedésének (*McCann*, 2005), valamint repülőtereken az adott repülőtérre jellemző, repülésbiztonsági kockázatot jelentő szignifikáns időjárási események előrejelzésére. Például San Francisco-ban a nyári hónapokban az éjszaka folyamán gyakran keletkezik alacsony szintű stratus felhőzet, amely a reggeli órákban disszipálódik. A San Francisco-i Nemzetközi Repülőtéren neurális hálózat segítségével adnak becslést e felhőzet disszipálódásának várható időpontjára (*Dean és Fiedler*, 2001). A legtöbb repülőtéren azonban a horizontális látástávolság előrejelzése jelenti a legnagyobb prognosztikai kihívást, ezért ez utóbbi elem előrejelzésére is egyre gyakrabban alkalmaznak neurális hálózatokat.

A látástávolság neurális hálózatok módszerén alapuló előrejelzésének első kísérletei alig több mint egy évtizeddel ezelőttre nyúlnak vissza. *Pasini és mtsai.* (2001) az elsők között készítették el azt a neurális hálózatok módszerén alapuló látástávolság-előrejelző modellt, amellyel a téli évszakra, Milánóra a meteorológiai elemek felszínközeli pillanatnyi értékeit, valamint a napszakokat prediktorként figyelembe véve becslést adtak a látástávolság ultrarövid távú időskálán várható értékére. Munkájuk során az észlelők által megfigyelt látástávolság-értékekkel végezték vizsgálataikat, azonban néhány kutató (*Bremnes és Michaelides*, 2005) a repülőtéri látástávolság előrejelezhetőségének vizsgálatához az objektív műszeres méréseken alapuló látásértékeket vette alapul.

Bremnes és Michaelides (2005) neurális hálózat segítségével valószínűségi előrejelzést készítettek öt látástávolság-kategóriára vonatkozóan. A kategorikus előrejelzés vitathatatlan előnye, hogy segítséget nyújt a köd-előfordulás lehetőségének becslésére is. Ekkor a neurális hálózatok két értéket adnak vissza kimeneti értéként, egyet, ha várható, míg nullát, ha nem valószínű köd. Ezt a megközelítést a Canberrai Nemzetközi Repülőtéren *Fabbian és mtsai.* (2007) TAF (Terminal Aerodrome Forecast) táviratok készítéséhez, döntéstámogató jelleggel vették figyelembe. Mindazonáltal, hogy a neurális hálózatok adott időpontbeli mérések és megfigyelések esetén megbízható eredményeket képesek

produkálni ultrarövidtávú előrejelzésekhez, statisztikai modell révén rövid- és középtávú prognózisok készítéséhez már kevésbé alkalmasak. Így a TAF táviratokban a neurális hálózatok három-hat óránál hosszabb időintervallumra vonatkozó előrejelzéseit jobbára tájékoztató jelleggel érdemes csak figyelembe venni. Köd előrejelzéséhez a neurális hálózatok olyan megközelítését is alkalmazták (*Costa et al.*, 2006), amely esetén a látástávolság prognózisa egynél több neurális hálózat működését igényli. Ez utóbbi kutatás során hat meteorológiai elem jövőbeli várható értékét hat neurális hálózat felhasználásával becslik, majd ezek a becsült értékek képezik a látástávolság előrejelzéséhez alkalmazott újabb neurális hálózat bemeneteit. Itt a hálózat kimenetei 0 vagy 1 bináris értékeket adnak eredményül aszerint, hogy várható-e köd, vagy sem. Ennél a módszernél hátrányt jelent, hogy az egyes prediktorok jövőbeli értékeit is becsüljük, így adott hibával terhelt értékek képezik a végső, látástávolság-előrejelzéshez alkalmazott neurális hálózat bemeneteit.

Az eddig bemutatott szakirodalmak többsége a látástávolságot a meteorológiai elemek függvényében többszörös lineáris regressziós egyenes illesztésével, illetve neurális hálózatok felhasználásával közelítette. Felmerülhet a kérdés, vajon melyik módszerrel kaphatunk pontosabb eredményeket. Egyes kutatások (*Chi és Wang*, 2011) összehasonlító vizsgálatokat végeztek annak megállapítására, hogy a lineáris regressziós egyenesek, vagy a neurális hálózatok kimeneteként előálló látásértékek tekinthetők-e megbízhatóbbaknak. Az eredmények arról tanúskodtak, hogy komplexebb felépítésűeknek, valamint nemlineáris tulajdonságuknak köszönhetően jobbnak bizonyultak a neurális hálózatok, így kutatásunk során mi is ez utóbbi eredményeket vártuk.

3.1.3. Tapasztalati összefüggések

Az előző két alfejezetben olyan módszerek kerültek bemutatásra, amelyek a meteorológiai elemek függvényében, matematikai eszközök alkalmazásával adnak becslést a látástávolság várható értékére, vagy kategóriájára nézve. Nem szabad megfeledkeznünk azonban arról, hogy az egyes módszerek esetén elsősorban azok a meteorológiai állapothatározók képezik a bemeneteket, amelyek megváltozásai különböző fizikai törvényszerűségeken keresztül járulnak hozzá a látástávolság növekedéséhez, illetve csökkenéséhez. Az első hazai numerikus modellkísérletek előtti időszakban *Makainé és Tóth* (1978) is arra hívta fel a figyelmet, hogy egy prognózis összeállítása során állandóan figyelembe kell venni azokat a kapcsolatokat, amelyek a látástávolság és különböző időjárási jelenségek között fennállnak. Az előző alfejezetek során bemutatott módszerek alapja is ezekre a kapcsolatokra és tapasztalati összefüggésekre épül, az időjárási

jelenségeket a meteorológiai elemek kvantitatív értékén keresztül figyelembe véve. A fizikai kapcsolatok közül a legfontosabbakat ismertetjük.

A látástávolságot meghatározó meteorológiai tényezők közül kulcsfontosságú szerepet tölt be a hőmérséklet és harmatpont egymáshoz való viszonya. Páráság, valamint köd kialakulásának feltétele, hogy a harmatpont-depresszió értéke $0\text{ }^{\circ}\text{C}$ -hoz közelítsen, azaz a levegő telítetté váljon. A levegőben lévő vízgőz kicsapódásához azonban szükség van kellő mennyiségű kondenzációs mag jelenlétére is, ezzel azonban nem foglalkozunk, mert a magvak gyakorlatilag mindig elegendő mennyiségben vannak jelen. (Sándor és Wantuch, 2005). A légkör telített állapotában minél több vízgőz kondenzálódik ki egy-egy részecskére, annak keresztmetszete annál nagyobb lesz. Mivel a fényszórás intenzitását meghatározza a keresztmetszet nagysága, ezért a keresztmetszettől való függés az okozója annak a megfigyelt ténynek, hogy a látástávolság a levegő relatív nedvességének növekedésével csökken (Mészáros, 2005). A hőmérséklet-értékek vertikális eloszlása is kapcsolatba hozható a látástávolsággal, ugyanis a kis látásértékek, ezáltal a ködök hőmérsékleti inverzióval, vagy a földfelszín közelében izotermiával vannak kapcsolatban (Makainé és Tóth, 1978). Ennek oka, hogy a földfelszín közelében a magasabb légrétegekhez képest megfigyelhető hidegebb levegő adott abszolút nedvességi viszonyok mellett kisebb telítési hiánnyal rendelkezik, illetve telített állapotba kerülve a látási viszonyok nagymértékű romlásához is vezethet. Az inverziós réteg alatt nagy mennyiségű nedvesség, por és füst gyűlhet össze, így gyakran köd is képződik (Makainé, 1962; Fodor, 2006).

A ködös helyzetek tehát kapcsolatba hozhatók a hőmérsékleti inverzióval, a hőmérsékleti inverzió pedig kapcsolatban áll a talajközeli szélesebséggel, ugyanis a felszíni kisugárzás okozta hőmérsékletcsökkenés hővezetés útján adódik át a szomszédos levegőrétegnek, azután turbulencia útján a magasabb rétegeknek. Következésképpen a hőmérsékleti inverzió vastagabb légrétegre történő kiterjedése csak gyenge légmozgás okozta átkeveredési folyamatok következtében tud érvényesülni. Ezzel szemben a túlságosan nagy szélesebség hatására az inverzió felemelkedik, a már kialakult köd általában széteszlik (Makainé és Tóth, 1978). Ekkor a látástávolság értékében javuló tendencia figyelhető meg. Bernoulli törvénye értelmében az átkeveredési folyamatok intenzitását a szélesebség magasság szerinti növekedése is erősíti, ezért a magasabb légrétegek szélviszonyait sem hagyhatjuk figyelmen kívül. A szélesebség mellett a szélirány adott területi sajátosságoknak megfelelően elsősorban a ködadvekción, vagy az advekción köd jelenségen keresztül befolyásolja a látási viszonyokat.

A látástávolság kapcsolatba hozható a szinoptikus skálájú folyamatokkal is, amelyeket a tengerszintre átszámított légnyomás értékén keresztül vehetünk figyelembe. Köd, illetve párásság tartós fennmaradása elsősorban anticiklonális időjárási helyzethez köthető, ugyanis az előző feltételek többnyire e nagyskálájú folyamatok jelenléte mellett figyelhetők meg. A legtöbb inverziós eset hazánk felett tartózkodó anticiklonnal áll kapcsolatban (Cséki, 2010), továbbá a téli hidegpárnás helyzet is anticiklonális időjárási helyzetben, kisugárzás útján alakul ki, derült éjszakákon (Fodor, 2006). Végül, de nem utolsónak érdemes szem előtt tartanunk azt a tényt, hogy hazánk éghajlatában a látástávolságnak felismerhető napi és évi menete van (Varga-Haszonits *et al.*, 2000).

A fenti tapasztalati összefüggések elsősorban a köd, párásság előfordulásának lehetőségére, valamint a látástávolság-változások tendenciáira mutatnak rá. A látástávolság előrejelzésére irányuló módszerek (Wantuch, 2001; Bremnes és Michaelides, 2005; Pasini *et al.*, 2001; Ruangjun és Exell, 2008) hátterében többnyire az említett fizikai törvényszerűségek és tapasztalati összefüggések állnak, amelyeket a rendelkezésre álló adatsor függvényében jelen kutatás során figyelembe vettünk.

3.2. Kategorikus előrejelzések verifikációja

A látástávolság-előrejelzések verifikációja során elterjedt módszer, hogy az egyes látásértékeket kategóriába sorolásuk helyessége szerint hasonlítjuk össze. Ebben az esetben diszkrét eloszlású verifikációról beszélhetünk. A kategóriák száma (n) szerint megkülönböztethetünk két- és többkategóriás előrejelzéseket. Munkánk során egy-egy látástávolság-előrejelző módszer vizsgálatakor annak megbízhatóságát $n = 3$ látáskategória elkülönítésével elemezzük.

1. táblázat: A kategorikus előrejelzések verifikációja esetén alkalmazott 2x2-es kontingencia táblázat.

	Megfigyelt esemény	Nem megfigyelt esemény	Összes előrejelzés
Előrejelzett esemény	a	b	$a + b$
Nem előrejelzett esemény	c	d	$c + d$
Összes megfigyelés	$a + c$	$b + d$	$a + b + c + d$

Két kategória esetén 2x2-es kontingencia táblázat (**1. táblázat**) áll rendelkezésünkre, amelyben a mérések és a becslések szempontjából vizsgált esemény lehet helyes találat (a), téves riasztás (b), hibás elvetés (c) és helyes elvetés (d). Három kategória esetén 3x3-as kontingencia táblázatot alkalmazva a **4. ábra** szerint az egyes eseményekre vonatkozó beválásokat visszavezethetjük három, egyenként 2x2-es táblázatra (Wilks, 2011).

Előrejelzés	Megfigyelés								
	Kód	Páráság	Jó látás						
Kód	r	s	t	Kód	<table><tr><td>$a = r$</td><td>$b = s + t$</td></tr><tr><td>$c = u + x$</td><td>$d = v + w + y + z$</td></tr></table>	$a = r$	$b = s + t$	$c = u + x$	$d = v + w + y + z$
$a = r$	$b = s + t$								
$c = u + x$	$d = v + w + y + z$								
Páráság	u	v	w	Páráság	<table><tr><td>$a = v$</td><td>$b = u + w$</td></tr><tr><td>$c = s + y$</td><td>$d = r + t + x + z$</td></tr></table>	$a = v$	$b = u + w$	$c = s + y$	$d = r + t + x + z$
$a = v$	$b = u + w$								
$c = s + y$	$d = r + t + x + z$								
Jó látás	x	y	z	Jó látás	<table><tr><td>$a = z$</td><td>$b = x + y$</td></tr><tr><td>$c = t + w$</td><td>$d = r + s + u + v$</td></tr></table>	$a = z$	$b = x + y$	$c = t + w$	$d = r + s + u + v$
$a = z$	$b = x + y$								
$c = t + w$	$d = r + s + u + v$								

4. ábra: 3x3-as kontingencia táblázat események szerinti felosztása 2x2-es táblázatokra.

A fent említett a, b, c, d elemek alkalmazásával különböző mérőszámok vezethetők be. Kutatásunk során hat ilyen mérőszámot ($PC, POD, FAR, CSI, BIAS, HSS$) alkalmaztunk, amelyek definícióit és tulajdonságait röviden ismertetjük.

A legegyszerűbb, diszkrét verifikációs terminológiában alkalmazott mérőszám a helyes előrejelzések aránya (Percent Correct – PC), definíciója:

$$PC = \frac{a + d}{a + b + c + d} \quad (1)$$

Ez az index bizonyos esetekben csak megfelelő körülmények mellett alkalmazható (WMO, 2000). Ennek egyik oka, hogy a repülési szempontból nem szignifikáns látástávolság-értékek előrejelzése meglehetősen egyszerűbb feladatnak tekinthető a kis (1000, illetve 5000 méternél kisebb) látástávolság-értékek sikeres prognózisához képest. Másrészt, egy adott időszakban előforduló ködös, vagy párás órák számának relatív gyakorisága akár nagyságrendekkel kisebb is lehet azoknak az óráknak a számához képest, amikor a látástávolság nem csökken 1000, illetve 5000 méter alá. Következésképpen kód és páráság esetén az előre nem jelzett és be nem következett események száma (d), valamint az előrejelzett és be is következett esetek száma (a) között is megfigyelhető az említett nagyságrendbeli különbség ($d \gg a$). Ugyanez a gondolatmenet a nagy relatív gyakoriságú, kisebb prognosztikai kihívással járó időjárás eseményekre ($a \gg d$) is érvényes. A bináris (igen/nem) előrejelzések egyenlő értékelése tehát félrevezető lehet, amennyiben az egyszerűbb prognosztikai feladatot jelentő események relatív gyakorisága nagyobb. A kategorikus előrejelzések beválásának számszerűsítéséhez célszerű tehát további verifikációs indexeket is alkalmazni, amelyek figyelembe veszik a téves, valamint az elmaradt riasztások számát is. Ilyen mérőszámok a POD , FAR és a CSI .

A POD (Probability Of Detection – Találati arány) megadja, hogy adott kategórián belül a bekövetkezett események számának hányad részét sikerült helyesen előrejelezni:

$$POD = \frac{a}{a + c} \quad (2)$$

A *POD* érzékeny a találatokra, azonban a téves riasztások számát figyelmen kívül hagyja. Célszerű tehát egy olyan index használatát is bevezetni, amely a hamis riasztásokról ad információt. Ez a mérőszám a *FAR* (False Alarm Ratio – Téves riasztási arány), ami a kategórián belüli téves riasztások és előrejelzett események számának arányáról tájékoztat minket.

$$FAR = \frac{b}{a + b} \quad (3)$$

Előrejelzéseink akkor tekinthetők pontosabbnak, ha a találati arányt maximalizálni, míg a hamis riasztási arányt minimalizálni tudjuk. Ebből kifolyólag a két mérőszámot célszerű együttesen vizsgálni.

Szigorúbb verifikációs indexnek tekinthető a ritka eseményekre széles körben alkalmazott kritikus sikerességi index (*CSI* – Critical Success Index), amely megadja a pontos előrejelzések, valamint a téves és hamis riasztások, illetve pontos előrejelzések összegének arányát.

$$CSI = \frac{a}{a + b + c} \quad (4)$$

Az előbb ismertetett négy verifikációs index $[0;1]$ intervallumon belüli értéket ad eredményül. A *PC*, *POD* és *CSI* esetén az ideális érték 1, míg a *FAR* esetén 0.

Érdemes megvizsgálni, hogyan viszonyulnak egymáshoz a megfigyelt és bekövetkezett események számértékei. Erről a *BIAS* index tájékoztat bennünket, amely az adott kategórián belüli előrejelzett és megfigyelt esetek arányának mérőszáma:

$$BIAS = \frac{a + b}{a + c} \quad (5)$$

A *BIAS* értéke mindig nagyobb 0-nál, ideális értéke pedig 1. Ha $BIAS > 1$, akkor adott eseményt többször jeleztek előre, mint ahányszor az valójában bekövetkezett. Amennyiben $BIAS < 1$, akkor adott eseményt kevesebbszer jeleztek előre, mint az valójában előfordult. Az első esetben a kategória túlbiztosítottnak, míg utóbbi esetben alulhatározottnak tekinthető.

A *PC* kivételével az eddigi mérőszámok a kontingencia táblázatnak mindössze kettő, esetleg három elemét tartalmazták. Felmerülhet az igény egy olyan index használatára is, amely mind a négy elemet egyszerre figyelembe véve egy mérőszámként nyújt átfogó,

reprezentatív képet az előrejelzés jóságáról. Az előbbi tulajdonságokkal rendelkező, leggyakrabban alkalmazott beválási mutató a véletlen eseményektől nem függő Heidke Skill Score (HSS). A HSS (6) értéke mínusz végtelentől egyig terjed, ideális értéke egy. A negatív HSS azt jelenti, hogy a véletlenszerű előrejelzés jobbnak tekinthető.

$$HSS = \frac{2(ad - bc)}{(a + c)(c + d) + (a + b)(b + d)} \quad (6)$$


4. Anyag és módszer

4.1. Felhasznált adatok

Munkánk során vizsgálatainkat mind felszínközeli, mind pedig magaslégköri mért adatok felhasználásával végeztük. A meteorológiai elemek felszínközeli mért értékei Budapest Liszt Ferenc Nemzetközi Repülőtér meteorológiai mérőhálózatából (ALMOS), míg a magaslégköri adatok az Országos Meteorológiai Szolgálat Marcell György Főobszervatórium rádiószonda adatsoraiból származnak. A látástávolság pillanatnyi értékeihez transzmisszométer által mért műszeres megfigyelések adatait használtuk. Amint azt a **2. fejezetben** ismertettük, a látástávolság meghatározása az észlelő megfigyelése alapján is történhet, azonban az alábbi három indok miatt a műszeres megfigyelések adataival dolgoztunk:

1. A műszeres megfigyelések objektív méréseket tesznek lehetővé, így kiküszöbölhető az emberi szem érzékenysége és alkalmazkodóképességének (ez egyénenként változik) hatása.
2. A pilóta számára az a távolság fontos, amelyről a pályafényeket látja. Az észlelő által a látástávolság becslése azonban nem a futópálya irányában történik, hanem az irányítótornynál lévő észlelési pontból, ahonnan a horizonton domináns látásértéket kell a METAR táviratokban jelenteni.
3. Vizsgálataink során annak a transzmisszométernek az adataival dolgoztunk, amelynek közvetlen közelében a földetérési ponthoz tartozó ALMOS mérőrendszer is található. Így lehetőségünk nyílt arra, hogy egyazon helyen és időben a meteorológiai elemek és a látástávolság összetartozó értékei alapján a közöttük lévő legszorosabb fizikai kapcsolatot térképezzük fel.

Az említett fizikai kapcsolatok meghatározására az 1-es futópályához tartozó, 13R pályaküszöb menti méréseket használtuk fel. Ennek oka, hogy ez a mérési helyszín található a rádiószondás mérések helyszínéhez legközelebb. A közöttük lévő távolság 3,98 km (**5. ábra**), amelyen belül a rádiószonda által a meteorológiai elemek 925 és 850 hPa-os főizobárszinteken mért értékeit konstansnak feltételeztük. A látástávolság ultrarövidtávú előrejelzéséhez a felhőzettel való borítottság mértékét, valamint a legalacsonyabb felhő alapját az észlelők megfigyelései alapján vettük számításba.



5. **ábra:** Az Országos Meteorológiai Szolgálat Marcell György Főobszervatórium, valamint Budapest Liszt Ferenc Nemzetközi Repülőtér 13R pályaküszöb menti ALMOS mérőállomás elhelyezkedése.
(Forrás: [Google Earth](https://www.google.com/earth/))

4.2. Az alkalmazott látástávolság-előrejelző algoritmus

4.2.1. A FOGSI index

Amint azt célkitűzéseink között korábban már említettük, olyan statisztikai módszerek adaptálásával és tesztelésével foglalkoztunk, amelyek háttérében az egyes meteorológiai állapothatározók és a látástávolság közötti valódi fizikai kapcsolatok minél pontosabb feltérképezése áll. Az alkalmazott statisztikai módszerek közül elsőként dr. Wantuch Ferenc *Perfekt Prognosztikai (PP)* megközelítésű látástávolság-előrejelző algoritmusát adaptáltuk (Wantuch, 2001), amely a hagyományos módszereken túl képes segítséget nyújtani az előrejelzőknek (Deák, 2010). Az algoritmus egy széleskörű statisztikai elemzések eredményeként kapott indexet, a *FOGSI*-t (FOG and viSibility index) használja a látástávolság és a különböző fizikai mennyiségek közötti kapcsolatok leírására:

$$FOGSI = 2|T_{2m} - T_{850}| + 2(T_{2m} - T_{d,2m}) + 2W_{850} \quad (7)$$

A fenti index figyelembe veszi a felszínközeli és a 850 hPa-os főizobárszint közötti hőmérsékleti gradienst, a 2 méteres harmatpont-deficitet, valamint a 850 hPa főizobárszinti szélességet. Összességében az első tag a légkör alsó, közel 1500 méter vertikális kiterjedésű rétegének stabilitási viszonyairól, a második tag a felszínközeli nedvességi viszonyokról, míg a harmadik tag a Bernoulli-hatás okozta átkeveredésről nyújt információt. Egy két éves adatbázis esetén a következő lineáris regressziós kapcsolat figyelhető meg az index és látástávolság között, (Wantuch, 2001) alapján:

$$\text{Látástávolság (km)} = -1,33 + 0,45 \cdot \text{FOGSI} \quad (8)$$

Vizsgálataink során több, mint hat éves adatsorra (2005. november – 2011. december) minden olyan esetben meghatároztuk a *FOGSI* index és a vele lineáris kapcsolatban álló látástávolság értékét, amikor a MOR értéke 10000 méter alattinak adódott. Mivel a budapest-lőrinci szondaadatok maximum napi kétszer álltak rendelkezésünkre, ezért maximum napi két adatsor (00 UTC, 12 UTC) elemzésére nyílt lehetőségünk. Így a hibás adatok kiszűrése után 985 esettel végezhattünk vizsgálatokat. Arra a kérdésre kerestük a választ, hogy a *FOGSI* index és a MOR között mennyire szoros kapcsolat figyelhető egy kétévesnél hosszabb időszakra vonatkozóan, az egyes évszakok és napszakok elkülönítése nélkül. Mivel a *FOGSI* és a MOR értékek között az algoritmus értelmében lineáris kapcsolat áll fenn, ezért a két adatsor közötti kapcsolat számszerűsítésére a korrelációs együtthatót választottuk, amelynek értéke $[-1;1]$ intervallumban mozoghat. Független változók esetében az együttható értéke 0, ugyanakkor két adatsor közötti szorosabb összefüggés esetén az együttható abszolút értéke 1 körüli. Vizsgálatunk során a korrelációs együttható gyengének, 0,30-nek adódott. Mivel a *FOGSI* és a látástávolság között (8) szerint lineáris kapcsolat figyelhető meg, ezért a számított és a mért látástávolság közötti korrelációs együttható értéke is 0,30. Nagyobb korrelációs együtthatóhoz (0,45) jutottunk, amikor a *FOGSI* adott kritikus tartományába eső értékeit egy ún. döntési fa (Wantuch, 2001) segítségével kategorizáltuk. Ennek lényege, hogy adott kritikus *FOGSI* intervallumba kerülő eseteknél további fizikai jellegű szétválasztásra van szükség. A kategorizálás során az egyes látástávolság-kategóriák a meteorológiai elemek és a belőlük származtatott fizikai mennyiségek meghatározott küszöbértékei szerint kerültek elkülönítésre. Eltérő küszöbértékek kerültek megállapításra a Kárpát-medence szinoptikus-klimatológiai sajátosságai közül elsősorban az őszi-téli félévre jellemző hideg légpárnás helyzetekben, amelyek elsősorban a légkör nagyon stabil állapotáért felelősek. Az alkalmazott döntési fát az **1. számú mellékletben** tüntettük fel.

A döntési fa alkalmazásával 16 döntési ág három csoportra különíthető el. Egyrészt az adatsorra vonatkozó lineáris regressziós egyenessel (8) való közelítésre, másrészt az 1000 méter alatti, valamint az 1000 és 5000 méter közötti látástávolságra. Következésképpen a kritikus *FOGSI* intervallumba tartozó esetek közül kizárólag azok kerülnek a MOR > 5000 méter látástávolság-kategóriába, amelyek esetén a lineáris regressziós egyenessel való közelítés 5000 méternél nagyobb látásértéket eredményez.

A látástávolság-kategóriák mindegyikéhez egy 2x2-es kontingencia táblázatot készítettünk. Ennek segítségével meghatároztuk a **3.2. fejezetben** bemutatott verifikációs indexeket, amelyek értékeit a későbbiek során ismertetni fogjuk.

A *FOGSI*–MOR közötti, valamint a döntési fa alkalmazása után a MOR–számított látástávolság közötti gyenge korrelációs együttthatók ismeretében felmerült az igény egy új mérőszám, valamint új döntési algoritmus bevezetésére, amely szorosabb kapcsolatba hozható a látástávolsággal, és amely felhasználásával a diszkrét verifikációs terminológiában alkalmazott mérőszámok értékei tekintetében kedvezőbb eredmények érhetők el. Az újonnan bevezetett indexet Módosított *FOGSI* (*M.FOGSI*) indexnek neveztük el, elméleti háttérét a következő alfejezetben ismertetjük részletesen.

4.2.2. A Módosított *FOGSI* (*M.FOGSI*) index

Az új index bevezetése során az (7) egyenlethez képest a következő változásokat iktattuk be:

1. Az indexben három tag helyett öt tagot vettünk figyelembe.
2. Az egyes tagokat eltérő együttthatókkal (súlyokkal) láttuk el (A, B, C, D, E).
3. Külön tagokként kezeltük a 2 méteres és 925 hPa közötti ($T_{2m} - T_{925}$), valamint a 925 hPa és 850 hPa főizobárszintek közötti hőmérsékleti gradienseket ($T_{925} - T_{850}$).
4. Az egyes főizobárszintek közötti hőmérsékleti gradiensek esetén a tényleges hőmérsékleti rétegződést szem előtt tartva nem alkalmaztunk abszolút értéket.
5. Az új indexnél figyelembe vettük a felszínközeli turbulenciát, amelyet a 10 méteres magasságban mért, 10 perces átlagszéllel (W_{10m}) jellemeztünk.

A fenti öt módosítás alkalmazása után a következő egyenletet nyertük:

$$M.FOGSI_i = A_i(T_{2m} - T_{d,2m})_i + B_i(T_{2m} - T_{925})_i + C_i(T_{925} - T_{850})_i + D_i(W_{850})_i + E_i(W_{10m})_i; \quad (9)$$

ahol A_i, B_i, C_i, D_i, E_i ($i = 1, 2, 3$) konstans együttthatók. Három rétegződési típust különítettünk el, így három különböző *M.FOGSI* egyenletet határoztunk meg. Az egyes rétegződési típusok elkülönítése a 925 és 850 hPa főizobárszintek közötti hőmérsékleti gradiens értékek alapján történt. Az első kategóriába ($i = 1$) azok az esetek kerültek, amikor a 850 hPa-os szint hőmérséklete több, mint 4 °C-kal nagyobb volt a 925 hPa-os hőmérsékleti értéknél. A második kategóriákba ($i = 2$) azok az esetek, ahol a két szint közötti hőmérsékleti gradiens értéke –4 és 0 °C közöttinek adódott, míg a harmadik

kategóriába ($i = 3$) minden olyan eset belekerült, ahol a légkör normál hőmérsékleti rétegződésének megfelelően a 925 hPa-os főizobárszint hőmérséklete nagyobb volt a 850 hPa-os szinthez képest.

A (9) egyenlet együtthatóinak optimalizálásához referencia időszakként a 2005. novembertől 2011. decemberig tartó körülbelül hatéves adatsort választottuk, míg a 2012–2013 kétéves független adatsort tesztelésre használtuk fel. Külön tesztidőszak vizsgálata kulcsfontosságú az új módszer hitelességének bizonyítása céljából, azaz annak a feltételnek az igazolására, hogy az alkalmazott módszer egy rövidebb időszakra, és független eseteket tartalmazó adatsorra is megbízható eredményeket produkál. A vizsgált időszakra 985, míg a tesztidőszakra 271 eset verifikációjára nyílt lehetőségünk.

A különböző rétegződési típusokra vonatkozó $M.FOGSI_i$ együtthatókat az említett körülbelül hatéves adatsorra egy optimalizálási folyamat során a *SOLVER* nevű programmal határoztuk meg úgy, hogy az új index és a MOR közötti korrelációs együttható értéke maximális legyen, továbbá az $M.FOGSI_i$ értéke egyik esetben sem legyen negatív. Így lehetőségünk nyílt az $M.FOGSI_i$ és a látástávolság közötti legszorosabb lineáris kapcsolat létrehozására, továbbá kiküszöböltük, hogy különböző előjelű látástávolság-értékeket nyerjünk. A (9) egyenlet tagjainak egy-egy rétegződési típus esetén előálló együtthatóit, valamint az $M.FOGSI_i$ és a MOR közötti korrelációs együtthatókat a **2. táblázatban** tüntettük fel.

2. táblázat: Az egyes rétegződési típusokba eső esetek száma a referencia időszakban, a (9) egyenlet együtthatói, valamint az $M.FOGSI_i$ indexek és a látástávolság közötti korrelációs együtthatók értékei az egyes rétegződési típusok esetén.


Rétegződési kategória	Esetek száma	Együtthatók értékei					Korrelációs együttható
		<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>	<i>E</i>	
1. $T_{925} - T_{850} < -4\text{ °C}$	48	4,81	0,35	-1,17	0,99	2,30	0,65
2. $-4\text{ °C} \leq T_{925} - T_{850} < 0\text{ °C}$	114	1,89	0,19	-0,29	0,31	0,84	0,64
3. $0\text{ °C} \leq T_{925} - T_{850}$	823	3,44	0,64	2,22	0,30	2,69	0,55

A látástávolság becsült értékét az $M.FOGSI_1$ és az $M.FOGSI_2$ függvényében az első két rétegződési típus esetén a következő, lineáris regressziós egyenesekkel közelítettük:

$$Látástávolság_1 [km] = 0,13 \cdot M.FOGSI_1 \quad (10)$$

$$Látástávolság_2 [km] = 0,37 \cdot M.FOGSI_2 \quad (11)$$

(10) és (11) egyenletekből látható, hogy az adatsorokra origóból kiinduló lineáris regressziós egyeneseket illesztettünk **(6.a, b ábra)**, amelyekkel lehetőségünk nyílt a legkisebb négyzetek módszerével kifejezhető $f(x) = ax + b$ alakú lineáris regressziós egyenesek b együtthatójától való függésének kiküszöbölésére. Erre azért volt szükség, mert az említett b együttható mindkét esetben 1-nél nagyobb értéket eredményez, ezért még a 0-hoz közeli $M.FOGSI_i$ értékek esetében is mindig 1000 méternél nagyobb látástávolságot kapnánk eredményül. Következésképpen az első két rétegződési típusra vonatkozóan ez utóbbi módszer alkalmatlan lenne köd előrejelzésére, valamint a látástávolság helyesen kategorizált eseteinek száma is kevesebb lenne.




6. ábra: A MOR értékek a Módosított FOGSI ($M.FOGSI_i, i = 1,2$) függvényében **(a)** az 1. rétegződési típus, valamint **(b)** a 2. rétegződési típus esetén, az alkalmazott lineáris regressziós egyenesekkel.

Összességében a **2. táblázatban** található együtthatók, valamint (10) és (11) alkalmazásával az első rétegződési típus esetén 26 %-ról 77 %-ra, míg a második rétegződési esetben 50 %-ról 72 %-ra növelhető az egyes látástávolság-kategóriákba helyesen besorolt esetek aránya. Mindez azért is fontos, mert így pontosabb képet nyerhetünk a hideg légpárnás helyzetekben uralkodó látási viszonyokról, hiszen az első két rétegződési típus magába foglalja az összes olyan lehetőséget, amikor hőmérsékleti inverzió figyelhető meg a 925 és 850 hPa-os szintek között. A többi esetben hőmérsékleti inverzió a légkör alsó 1500 méteres rétegének legalsóbb szintjeire korlátozódik. Ilyenkor azonban hideg légpárna helyett kisugárzási inverzióról beszélhetünk. A kisugárzási inverzió vastagsága nyáron minimális, tavasszal, de különösen ősszel jelentős lehet, télen viszont az 1 km-t is meghaladhatja az inverziós réteg vastagsága, habár itt már nemcsak a kisugárzásnak van szerepe, hanem advektív okok is közrejátszhatnak (hideg légpárna) (Cséki, 2010). Következésképpen az első két rétegződési típus egyértelműen tartalmazza azokat az eseteket, amelyekre teljesül, hogy hőmérsékleti inverzió nemcsak a 925 és 850 hPa-os főizobárszintek között, hanem a földfelszín és a 925 hPa-os szint között is megfigyelhető, tehát az inverziós réteg vastagsága ténylegesen meghaladja az 1 km-t.

Az első két rétegződési típus esetén az $M.FOGSI_1$, $M.FOGSI_2$ és a mért MOR értékek között mérsékeltén erős ($r > 0,6$) korrelációs együtthatókat nyertünk. Mivel a lineáris regressziós egyenesek alkalmazásán túl további fizikai jellegű szétválasztással megbízhatóbb látástávolság-kategória elkülönítések nem eszközölhetők, ezért további döntési fa nem került bevezetésre.

Az előző két rétegződési csoportba be nem sorolt esetek számára nem hoztunk létre több, hőmérsékleti gradiens szerint elkülönített kategóriát. Ennek oka, hogy a fennmaradó esetek további lehetséges elkülönítéskor nem nyertünk nagyobb korrelációs együtthatót az index és a MOR között. Így az adatsor fennmaradó része egy harmadik rétegződési csoportba került besorolásra, azonban a MOR értékének elsődleges becslése az előzőektől eltérően nem lineáris regressziós egyenessel történt, hanem az $M.FOGSI_3$ egy meghatározott küszöbértéke szerint. A **7.a ábrán** megfigyelhető, hogy a $M.FOGSI_3 > 35$ értékekhez (I. csoport) néhány kivételtől eltekintve egyaránt 5000 méter feletti látástávolság tartozik, következésképpen e küszöbérték feletti esetek túlnyomó többségében repülési szempontból nem szignifikáns, jó látási viszonyok uralkodnak. Nem figyelhető meg hasonló elkülönítési lehetőség az $M.FOGSI_3 \leq 35$ eseteknél, továbbá nem határozható meg egyértelműen olyan alsó küszöbérték sem, amelyre kis látásértékeket, esetleg ködöt prognosztizálhatunk. Az előbbi okok, valamint a harmadik rétegződési típusba kerülő nagyszámú eset miatt tehát szükségessé válik további fizikai jellegű szétválasztás alkalmazása. Megoldásként egy, az **1. számú mellékletben** található döntési fához hasonlóan egy új döntési fát (**2. számú melléklet**) hoztunk létre, azzal a különbséggel, hogy eltérő kategorizálási algoritmusokat, valamint más küszöbszámokat vezettünk be, amelyekkel a látásértékek a **7.a ábrán** megfigyelhető II., III., illetve IV. csoportba sorolhatók.



7. ábra: A MOR értékek a Módosított FOGSI ($M.FOGSI_3$) függvényében (a) a teljes adatsorra vonatkozóan, a fizikai mennyiségek küszöbértékei szerint elkülönített MOR kategóriák feltüntetésével, valamint (b) $M.FOGSI_3 \leq 35$ adatsorra illesztett lineáris regressziós egyenessel.

A IV. csoportba kerülő nagyszámú eset fizikai jellegű elkülönítése további újításnak számít. Az eredeti módszer (Wantuch, 2001) esetén a kritikus intervallumon belül a repülésbiztonsági kockázatot nem jelentő, jó látásértékek elkülönítése csak akkor figyelhető meg, ha a (8) lineáris regressziós egyenessel való közelítés 5000 méter feletti értékeket eredményez. Az általunk fejlesztett módszer a kritikus intervallumon belüli jó látási viszonyok szétválasztásához is külön döntési ágot alkalmaz.

A II., III. és IV. csoportokon kívül az $M.FOGSI_3 \leq 35$ esetekre az első két rétegződési típushoz hasonlóan origóból induló lineáris regressziós egyenest illesztettünk, amelynek egyenlete a következő:

$$Látástávolság_3 [km] = 0,22 \cdot M.FOGSI_3, \quad (12)$$

így néhány döntési ág esetén a látástávolság a (12) egyenlettel nyert látásérték szerint került besorolásra (**7.b ábra**).

Az $M.FOGSI_3 \leq 35$ esetekben alkalmazott döntési fa küszöbértékeinek meghatározásánál elsődleges szempontként azt vettük alapul, hogy a vizsgált időszakra vonatkozóan az egyes látástávolság-kategóriákra számított verifikációs indexek a lehető legkedvezőbb értékekkel rendelkezzenek. Például adott látástávolság-kategória esetén nagy POD értékhez ne tartozzon nagy FAR érték, mert akkor a sikeres előrejelzések számának növekedésével a hibás előrejelzések száma egyaránt növekszik. Ugyanakkor nem szabad figyelmen kívül hagyni azt sem, hogyan viszonyul egymáshoz az adott kategóriába tartozó előrejelzett és a megfigyelt esetek száma, azaz mekkora a $BIAS$ verifikációs index értéke. Ügyelni kellett arra, hogy ez a mérőszám lehetőleg 1 körüli értéket adjon. Így elkerülhetővé vált, hogy adott kategória túlbiztosított (többször lett előrejelezve, mint ahányszor bekövetkezett), illetve alulhatározott (többször következett be, mint ahányszor előrejelezték) legyen. Az előbbi szempontok figyelembevételével olyan döntési fát készítettünk, amely a küszöbszámok szubjektív meghatározásán alapul, ugyanakkor alkalmazásával minden látástávolság-kategóriára nézve hasonló minőségű prognosztikai teljesítmény érhető el.

A kategorizálás az eredeti döntési fához (Wantuch, 2001) hasonlóan az alsó légkör átlagos nedvességi viszonyai ($\frac{RH_{925}+RH_{2m}}{2}$) alapján történt az eredetitől eltérő küszöbértékek alkalmazásával. Így négy csoportot különítettünk el, továbbá minden átlagolt nedvességi értékhez további két vagy három döntési ágot kapcsoltunk. Ezek a mellékágak a hőmérsékleti inverzió jelenlétéről, illetve annak erősségéről adnak információt. Mivel a harmadik rétegződési típusban vagyunk, ezért olyan esetekkel kell

foglalkoznunk, amelyeknél a 925 és 850 hPa-os főizobárszintek között már nem figyelhető meg hőmérsékleti inverzió. Következésképpen olyan helyzeteket vizsgálunk, amikor a stabil hőmérsékleti rétegződés a talajszintről 925 hPa-ig megfigyelhető, azonban 925 és 850 hPa között már nem. Így a hideg légpárna helyett kisugárzási inverzióról beszélhetünk. Kisugárzási inverziós helyzetnek definiáltuk tehát azokat az eseteket, amikor a 925 hPa-on mért hőmérséklet nagyobb a 2 méteres magasságban, továbbá a 850 hPa-on mért hőmérsékletéhez képest is. Így lehetőségünk nyílt a hideg légpárna, valamint a radiációs hűlés következtében kialakuló kisugárzási inverzió elkülönítésére.

További mellékágakon a végső kategóriába sorolás a 2 méteres relatív nedvesség (RH_{2m}), a 10 méter magasan mért átlagos szélsősebesség (W_{10m}), illetve az $M.FOGSI_3$ meghatározott küszöbértékei szerint történt. A teljes algoritmust a **2. számú mellékletben** tüntettük fel. Az algoritmus további tesztelése céljából C programozási nyelven programot írtunk, amely a Liszt Ferenc Nemzetközi Repülőtér Meteorológiai részlegén operatíván alkalmazott WRF modellbe is beépítésre került.

4.3. Neurális hálózatok

4.3.1. Felépítés


A biológiában az idegrendszer legkisebb egységét neuronnak, míg a neuronok összekapcsolt hálózatát neurális hálózatnak nevezzük. Modern szóhasználatban, így a későbbiekben is a neurális hálózatok kifejezés alatt azokat a mesterséges neurális hálózatokat értjük, amelyek mesterséges neuronok sokaságából állnak. A módszer elnevezése onnan ered, hogy nagyszámú bemenő adatot (*prediktort* – például a meteorológiai elemeket) idegrendszer-szerűen elágaztatunk, majd különböző súlyok és nemlineáris transzformációk megfelelő kombinációinak alkalmazásával egy adott célérték (*prediktandusz* – például a látástávolság) várható értékére becslést adunk.

A neurális hálózatok struktúrájukat tekintve két fő csoportra oszthatók: hurokmentes, előrecsatolt (*feed-forward networks*), valamint visszacsatolt (*recurrent network*) hálózatokra. Az előrecsatolt hálók a pillanatnyi bemenet függvényét reprezentálják, nem csatolják vissza a kimeneteiket a bemeneteikre, míg a rekurrens hálók igen. A neurális hálózatok meteorológiai célú felhasználásához a szakirodalomban leginkább előrecsatolt hálózatokat alkalmaznak (Marzban és Stumpf, 1996; Khalili et al., 2011; Pasini et al., (2001)), így részletesen ezek felépítését ismertetjük. Mivel a hazai meteorológiai témájú

kutatások között kevés szó esik a neurális hálózatokról, ezért a szakirodalomban fellelhető, magyar nyelvre lefordított kifejezések eredeti, angol megfelelőit is ismertetni fogjuk.

4.3.2. Az előrecsatolt neurális hálózatok

Az előrecsatolt hálózatok neuronjai a hálózaton belül csak meghatározott számú neuronnal állnak összeköttetésben, ezért szerkezetükre a réteges felépítés jellemző. Minden egyes egység (*neuron*) kizárólag az őt közvetlenül megelőző réteg egységeitől (*neuronjaitól*) kap bemeneti jelet. Innen ered az *előrecsatolt* elnevezés. A legegyszerűbb ilyen típusú neurális hálózat mindössze egy bemeneti és egy kimeneti rétegből áll, amelyet perceptronnak nevezünk. Összetettebb problémák kezelésére, többek között a látástávolság neurális hálózattal történő prognózisához többretegű, előrecsatolt neurális hálózatokat (*multi-layer feed-forward neural network*) alkalmaznak, amelyek szerkezete három fő részre osztható: bemeneti (*input*), rejtett (*hidden*), valamint kimeneti (*output*) rétegekre. A bemeneti réteg neuronjai a bemeneti jelek (prediktorok) továbbítását végzik a hálózat felé, a rejtett réteg neuronjai azok feldolgozását, míg a kimeneti réteg neuronjainak feladata az információ külvilág felé történő továbbítása. Az **8. ábrán** egy többretegű előrecsatolt neurális hálózat egy lehetséges konfigurációját **(a)**, valamint egy neuron felépítésének sematikus rajzát **(b)** tüntettük fel, ahol egy bemeneti, két rejtett, valamint egy kimeneti réteget alkalmaztunk.



8. ábra: **(a)** Többretegű, előrecsatolt neurális hálózat szerkezetének egy lehetséges konfigurációja, valamint **(b)** egy neuron felépítésének sematikus rajza.

Az ábrán megfigyelhető, hogy a bemeneti réteg minden egyes bemeneti egysége (x_i) az első rejtett réteg összes egységével kapcsolatban áll. Minden egyes összekötő vonal egy-egy súlyt (*weight*) hívatott kifejezni. Ha az ábra szerint 10 bemeneti egységet alkalmazunk, amelyek mindegyikét kapcsolatba hozzuk az első rejtett réteg mind az 5 egységével, akkor tehát 50 súlyra van szükségünk. A **8.a ábrán** w_{ij} reprezentálja az i -edik bemeneti egységtől az első rejtett réteg j -edik egységéhez kapcsolódó súly értékét. Az első rejtett réteg minden egyes neuronjához tehát 10 súly érkezik. Mind az öt esetben képezzük a tíz bemenő érték súlyozott összegét, amelyhez egy további eltolássúlyt (*bias*) is hozzáadunk. A rejtett és kimeneti rétegekhez rétegenként egy-egy eltolássúly tartozik, amelyet az első rejtett réteg esetében θ_j -vel jelöltünk. Az így kapott összeg általában nemlineáris leképezésével kapjuk meg a kimeneti értéket. A nemlineáris leképezéshez használt függvényeket transzferfüggvényeknek nevezzük. Fontos, hogy ezek a függvények nemlineárisak legyenek, ugyanis ennek hiányában a neurális hálózat egy lineáris függvénnyé fajulna. Ezt szeretnénk elkerülni, hiszen egy lineáris modellel az előző fejezetben leírtak alapján már végeztünk vizsgálatokat. A transzferfüggvények esetén további előnyt jelent, ha folytonosan differenciálhatók, ugyanis ennek a tulajdonságnak, amint azt a későbbiekben látni fogjuk, a súlytanulási algoritmusban kiemelt szerepe lesz. A neurális hálózatok esetén leggyakrabban alkalmazott transzferfüggvények a szigmoid (13), valamint a tangens hiperbolikus (14) függvények.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (13)$$

$$f(x) = \text{th}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (14)$$

Az eddig bemutatott folyamat alapján az első rejtett réteg j -edik kimenetének értéke a **8.a ábrán** használt jelölésekkel a következőképpen írható fel:

$$a_j = f\left(\sum_{i=1}^{10} w_{ij}x_i + \theta_j\right), \quad (15)$$

ahol f a (13) és (14) transzferfüggvények valamelyike. A (15)-höz hasonló alakú egyenletet használjuk fel a_k , valamint a végső kimeneti érték (a_l) (**8.a ábra**) kiszámításához is.

A látástávolság-előrejelző algoritmusoknál korábban bemutatott döntési fák (**1., 2. számú melléklet**), valamint a neurális hálózatok **8.a ábrán** feltüntetett szerkezete

között megfigyelhetünk néhány hasonlóságot. A két módszer közös tulajdonsága, hogy fizikai mennyiségeket úgy hozunk egymással kapcsolatba, hogy egy adott célértékre nézve a lehető legmegbízhatóbb becsléseket nyerjük. Amíg a neurális hálózatoknál minden fizikai mennyiség között a rejtett- és kimeneti neuronokon keresztül kapcsolatot létesítünk, addig a döntési fa esetén csak néhány fizikai mennyiség közötti összeköttetést hagyunk meg. A két szerkezetet összehasonlítva összességében elmondható, hogy a döntési fa felfogható úgy, mint egy leegyszerűsített neurális hálózat, ezzel szemben a neurális hálózat egy összetett, komplex döntési fának tekinthető. A neurális hálózatok elméletével tehát egy olyan matematikai módszer áll rendelkezésünkre, amely lehetővé teszi, hogy tényleges fizikai mennyiségek között a lehető legszorosabb kapcsolatot létesítsük.

A neurális hálózatok használatát mindig egy tanulási folyamat előzi meg, amely során előzetes megfigyeléseink, vagyis a múltbeli ismeretek alapján kerülnek módosításra a kezdetben véletlenszerűen generált hálózati súlyok. A múltbeli ismeretek olyan tanító mintákat jelentenek, amelyek esetén az adott bemeneti értékekhez tartozó kimeneti minták is ismertek. A mi esetünkben ezeket a bemeneti értékeket elsősorban a mért és megfigyelt meteorológiai elemek, míg a kimeneti adatokat a MOR mérések képezik. A hálózat tanulási folyamata során az a cél, hogy az ismert kimeneti minták értékeit kapjuk vissza eredményül. Ezt akkor érhetjük el, amikor a súlyokat úgy módosítjuk, hogy a kimenetek (*outputs*) minél közelebb kerüljenek a célértékekhez (*targets*), azaz a mi esetünkben a MOR mérések értékeihez. Minden egyes minta esetén meghatározható a kimeneti és a célérték közötti hiba, amelyet tehát a hálózat tanítása során minimalizálni szeretnénk. Ehhez nyújt egyfajta lehetőséget az ún. hiba-visszaterjesztési (*back-propagation*) algoritmus, amelynek lényege, hogy a kimeneti hibát visszaterjeszti a hálózat összeköttetéseire, és a súlyokat a hiba bizonyos mértékével (*tanulási/bátorsági faktor – learning rate*) változtatja meg. Ennek az algoritmusnak a matematikai háttérét a következő fejezetben ismertetjük.

4.3.3. A hiba-visszaterjesztési algoritmus

Az algoritmus során kezdetben a súlyok megválasztása önkényes, majd a hiba minimalizálása iteratív módon történik. A tanuló algoritmus összes mintaadatra történő egyszeri végigfutását *epoch*nak nevezzük. A hálózat a tanulási folyamat során a hiba csökkenésének értéke és iránya szerint változtatja a súlyokat mindaddig, amíg egy előre meghatározott leállási feltétel nem teljesül. A hiba-visszaterjesztési algoritmusban a súlyfrissítés kétféleképpen történhet. Egyrészt úgy, hogy a súlyfrissítés a teljes minta

adatsor egyszeri végigpásztázása (azaz egy teljes epoch) után történik, másrészt pedig úgy, hogy minden egyes tanuló minta után frissítésre kerülnek a súlyok (Svozil *et al.*, 1997). Mivel munkánk során a hiba-visszaterjesztési algoritmusban ez utóbbi módszert alkalmaztuk, ezért az algoritmus ezen részének matematikai hátterét ismertetjük, Kröse és van der Smagt (1996) alapján.

Tekintsünk egy olyan tanuló adatsort, amelyben előzetes megfigyeléseink számát, azaz a rendelkezésre álló mintákat p -vel jelöljük. Ekkor az egyes hálózati rétegek k -adik neuronjának p -edik mintára vonatkozó kimenete a következőképpen adható meg:

$$y_k^p = \mathcal{F}(s_k^p); \quad (16)$$

ahol $\mathcal{F}$ a bemeneti értékektől függő, folytonosan differenciálható transzferfüggvény, amelyben a k -adik neuron bemenete az alábbi módon írható fel:

$$s_k^p = \sum_j w_{jk} y_j^p + \theta_k. \quad (17)$$

A fenti egyenletben w_{jk} a j -edik egységtől a k -adik egységhez kapcsolódó súly értéke, y_j^p a p -edik minta j -edik bemenetét jelenti, míg $\theta_k = w_{0k}$ a bias eltolássúly értéke. (16) és (17) egyenlet együttesen bár eltérő jelölésekkel, de formailag megfelel az (15) egyenletnek. A p -edik minta kimeneti (y_o^p)- és célértéke (d_o^p) közötti hiba számszerűsítésére a négyzetes hibát alkalmazzuk, amelynek alakja a következő:

$$E^p = \frac{1}{2} \sum_{o=1}^{N_o} (d_o^p - y_o^p)^2. \quad (18)$$

Ebben az egyenletben az összegzés egy adott minta esetén a kimeneti réteg N_o számú neuronjára vonatkozik. A látástávolság PP megközelítésű előrejelzéséhez egy, míg nowcasting célú prognózisához két kimeneti neuron, tehát két célérték tartozik. Az algoritmus során az összegzett négyzetes hiba csökkentése a cél. Ennek megoldására egy gradiensalapú optimalizálási eljárást, az ún. delta-szabályt használjuk. Ehhez E^p minden egyes súlyra vonatkozó parciális deriváltját meg kell határoznunk, s a szabály értelmében az egyes mintákra vonatkozó súlyváltozások mértéke arányos lesz az adott minta kimeneti- és célértéke közötti hibafüggvény (18) negatív gradiensével:

$$\Delta_p w_{jk} = -\gamma \frac{\partial E^p}{\partial w_{jk}}; \quad (19)$$

ahol $\gamma > 0$ arányossági tényező a tanulási faktor, a $-\frac{\partial E^p}{\partial w_{jk}}$ negatív gradiens pedig a hiba legnagyobb csökkenésének pillanatnyi irányát mutatja. Ha kis lépésekben az így számított irányok mentén haladunk, akkor lehetőségünk nyílik a globális minimum megközelítésére.

A p -edik mintához tartozó hiba adott súly szerinti megváltozását a következőképpen is felírhatjuk:

$$\frac{\partial E^p}{\partial w_{jk}} = \frac{\partial E^p}{\partial s_k^p} \frac{\partial s_k^p}{\partial w_{jk}}. \quad (20)$$

Vegyük észre, hogy (17) alapján:

$$\frac{\partial s_k^p}{\partial w_{jk}} = y_j^p; \quad (21)$$

valamint definiálva a következő mennyiséget (hibatagot):

$$\delta_k^p = -\frac{\partial E^p}{\partial s_k^p}; \quad (22)$$

a (19) súlyfrissítésre vonatkozó egyenletet a következő alakra hozhatjuk:

$$\Delta_p w_{jk} = \gamma \delta_k^p y_j^p. \quad (23)$$

A továbbiakban tehát az a célunk, hogy olyan δ_k^p értékeket találjunk, amelyek a hálózat tetszőleges k neuronjára egyaránt alkalmazhatók. Ha (22) egyenletet tovább alakítjuk, akkor egy olyan formulát kapunk eredményül, amellyel lehetőségünk nyílik a δ_k^p hibatagoknak a kimeneti rétegtől a megelőző rétegekre történő visszaterjesztésére, így az egyes rétegek közötti súlyfrissítésre is. A láncszabály értelmében (22)-t a következőképpen is felírhatjuk:

$$\delta_k^p = -\frac{\partial E^p}{\partial s_k^p} = -\frac{\partial E^p}{\partial y_k^p} \frac{\partial y_k^p}{\partial s_k^p}; \quad (24)$$

ahol az egyenlőség jobb oldalának első tényezője a p -edik minta kimeneti hibájának a k -adik neuron kimeneti értéke szerinti megváltozását jelenti, míg a második tényező ez utóbbi kimeneti értéket a bemenetben történő változás függvényében fejezi ki. A második tényező a (16) egyenlet s_k^p szerinti deriválásával a következő alakot ölti:

$$\frac{\partial y_k^p}{\partial s_k^p} = \mathcal{F}'(s_k^p). \quad (25)$$

Amennyiben $k=o$ a kimeneti réteg egy neuronja, akkor (24) egyenlet jobb oldalának első tényezőjére teljesül a következő:

$$\frac{\partial E^p}{\partial y_o^p} = -(d_o^p - y_o^p). \quad (26)$$

(25) és (26) alapján tehát:

$$\delta_o^p = (d_o^p - y_o^p) \mathcal{F}'(s_o^p) \quad (27)$$

egyenletet kapjuk tetszőleges o kimeneti neuronra.

Bonyolultabb helyzetet idéz elő, amikor k nem a kimeneti réteg neuronja, hanem $k=h$ rejtett rétegbeli neuron. Ekkor ugyanis nem tudjuk, hogy ezek a neuronok milyen mértékben járulnak hozzá a hálózat kimeneti hibájához. Ekkor az E^p hibát a rejtett rétegbeli neuronok kimeneti értékeinek megváltozása szerint a következőképpen írhatjuk fel:

$$\frac{\partial E^p}{\partial y_h^p} = \sum_{o=1}^{N_o} \frac{\partial E^p}{\partial s_o^p} \frac{\partial s_o^p}{\partial y_h^p} = \sum_{o=1}^{N_o} \frac{\partial E^p}{\partial s_o^p} \frac{\partial}{\partial y_h^p} \sum_{j=1}^{N_h} w_{ho} y_j^p = \sum_{o=1}^{N_o} \frac{\partial E^p}{\partial s_o^p} w_{ho} = - \sum_{o=1}^{N_o} \delta_o^p w_{ho}. \quad (28)$$

Ez utóbbi egyenletben N_o (18)-hoz hasonlóan a kimeneti, míg N_h a rejtett rétegbeli neuronok számát jelenti. (28) lehetőséget biztosít arra, hogy a kimeneti neuronok hibáját visszaterjesszük a rejtett rétegre. Az egyenletben s_o^p a p -edik minta kimeneti rétegbeli neuronjainak bemeneti értékeit fejezi ki, míg w_{ho} a rejtett réteg h -edik neuronjától a kimeneti réteg o -edik neuronjához kapcsolódó súly értéke. (28) végeredményét behelyettesítve a (24) egyenletbe, $k = h$ mellett a következő alakot kapjuk:

$$\delta_h^p = \mathcal{F}'(s_h^p) \sum_{o=1}^{N_o} \delta_o^p w_{ho}. \quad (29)$$

(27) és (29) egyenletek a hálózat bármely egységére vonatkozóan egy rekurzív algoritmust biztosítanak a δ_h^p és δ_o^p értékek kiszámítására, amelyek segítségével lehetőség nyílik a (23) egyenletbeli súlyváltozások kiszámítására is.

Érdemes odafigyelnünk a súlyváltozások mértékét meghatározó tanulási faktor értékének helyes megválasztására is. Ha túl kicsi Y értéket választunk, akkor a tanulási folyamat számítási igénye jelentősen megnő, míg nagy Y értékek esetén gyakran előfordul, hogy a rendszer a valós megoldás körül oszcillál, esetleg divergál tőle. Következésképpen tanulási faktornak azt a maximális értéket érdemes adni, amellyel ez utóbbi probléma még elkerülhető. Az említett oszcillációt nagy Y értékek esetén az ún. momentum-együttható

(α) bevezetésével is elkerülhetjük. Az új együttható segítségével a súlyváltozást a megelőző súlyváltozás függvényében a következőképpen adhatjuk meg:

$$\Delta_p w_{jk}(t+1) = Y \delta_k^p y_j^p + \alpha \Delta_p w_{jk}(t), \quad (30)$$

ahol t -t prezentációs számnak nevezzük. Munkánk során mind a tanulási faktor, mind pedig a momentum faktor értékének 0,7-t választottunk.

4.3.4. A neurális hálózat tervezése

A neurális hálózatok szerkezetének tervezése során nem kell szigorú, merev szabályokat követnünk. Ennek ellenére nem hagyhatjuk figyelmen kívül azokat a szakirodalomban fellelhető javaslatokat, amelyek nélkülözhetetlenek a hálózat megfelelő működéséhez. Ezek többsége elsősorban a rejtett rétegek, valamint a rétegeken belüli rejtett neuronok számának meghatározására irányul. Különböző kutatások eltérő tapasztalati összefüggéseket ajánlanak, közülük néhányat ismertetünk.

A megoldandó probléma felvázolása, a be- és kimeneti neuronok számának meghatározása után a rejtett rétegek számát kell megadnunk. A tapasztalat azt mutatja, hogy nem érdemes kettőnél több rejtett réteget alkalmazni. Ennek oka egyrészt az, hogy a rejtett rétegek számának növelése nemcsak az algoritmus futási idejét növelheti meg drasztikusan, hanem a hibagradienst is instabilabbá teszi (Svozil *et al.*, 1997). Másrészt a legtöbb probléma kezelésére maximum két rejtett réteg használata elegendő. Svozil és mtsai. (1997) azt ajánlják, hogy kizárólag egy rejtett réteget alkalmazzunk, és amennyiben nagyszámú rejtett rétegbeli neuron nem képes megoldani az adott problémát, akkor érdemes egy második rejtett réteget is bevezetni. Mivel a neurális hálózatok meteorológiai célú felhasználásai során számtalan esetben (Bremnes és Michaelides (2005); Pasini és mtsai. (2001)) egy rejtett réteget alkalmaztak, ezért mi sem alkalmaztunk többet.

A rejtett rétegbeli neuronok számának meghatározására szintén nincs egzakt szabály, így érdemes többféle javaslatot is megfontolni. Egy háromrétegű neurális hálózat esetén, ha n a bemeneti neuronok, m pedig a kimeneti neuronok száma, akkor $\sqrt{mn}$ népszerű megoldás a rejtett neuronok számának megválasztására (Kaastra és Boyd, 1996)). Baily és Thompson (1990) azt ajánlja, hogy a rejtett neuronok száma a bemeneti neuronok számának 75 %-a legyen, míg Katz (1992) szerint ezt az értéket a bemeneti neuronok számának felétől háromszorosáig változtathatjuk. Mivel a neurális hálózatok meteorológiai célú felhasználására irányuló kutatások többsége maximálisan kétszer annyi rejtett rétegbeli neuront alkalmaz, mint amennyi a prediktorok száma, ezért munkánk során mi

sem használtunk fel többet. Ez előbbi javaslatokat figyelembe vettük a hálózat szerkezetének tervezésekor.

Nem hagyhatjuk figyelmen kívül azonban azt sem, hogy hogyan viszonyuljon egymáshoz a hálózati súlyok, valamint a tanulási algoritmusban részt vevő mintaadatok száma. *Klimasauskas* (1993) azt ajánlja, hogy legalább ötször annyi mintaadat álljon rendelkezésünkre a tanulási folyamat során, mint amennyi a súlyok száma. Így meghatározható a bemeneti és rejtett rétegbeli neuronok számának maximális értéke is. A tanulási folyamathoz szükséges minták minimális számát egy L rétegű előrecsatolt neurális hálózat esetén a következő egyenlet felhasználásával is meghatározhatjuk (*Messer és Kittler*, 1998):

$$N = \sum_{l=1}^L (n_{l-1} + 1)n_l; \quad (31)$$

ahol N a szabad paraméterek (súlyok és bias értékek), n_l pedig az l rétegbeli neuronok számát jelenti. Az egyenletben az összegzés az előrecsatolt neurális hálózat L számú rétegeire történik, a bemeneti réteg kivételével. E tanulmány szerint legalább ötször annyi tanulási mintára van szükségünk, mint amennyi a (31) egyenlettel meghatározott szabad paraméterek száma.

Azért szükséges körültekintően meghatározni a rejtett rétegek és neuronok, valamint a tanulási algoritmushoz szükséges mintaadatok számát, mert a neurális hálózatok a többi statisztikai modellhez hasonlóan hajlamosak a túltanulásra, más néven túlilleszkedésre (*overtraining, overfitting*) (*Kröse és van der Smagt*, 1996; *Priddy és Keller*, 2005). Ez azt jelenti, hogy a hálózat képes lesz memorizálni az összes példát, de nem feltétlenül lesz képes az új, korábban nem látott bemenetekre jól általánosítani.

A túltanulás elkerülése érdekében célszerű a rendelkezésre álló adatsort két részre bontani: egy tanulási, valamint egy validációs (kiértékelő) részre. Egyes meteorológiai vonatkozású kutatások (*Kandya et al.*, 2012; *Naik és Pathan*, 2013) a rendelkezésre álló adatsor jelentős részét, 70%-át tanulásra, míg a fennmaradó 30%-ot validálásra használják. Ennek értelmében a hálózat tanítására csak a tanulási adatsor kerül felhasználásra, míg a független adatsort képező validációs adatok a hálózat általánosító képességének javításában jutnak szerephez. A neurális hálózat végső konfigurációjának meghatározására gyakran alkalmazott eljárás a korai leállítási (*early stopping*) módszere (*Svozil et al.*, 1997), jelen munkában is ezt használtuk. A korai leállítási azt jelenti, hogy a két adatsorra vonatkozóan együtt vizsgálunk egy előre meghatározott hibafüggvényt, és azelőtt állítjuk

le a tanítási folyamatot, mielőtt a validációs adatsorra vonatkozó hiba szignifikánsan növekedni kezd. Ekkor ugyanis a két adatsorra vonatkozó hiba már nem egyazon lokális minimumhoz konvergál. Tehát a független adatsor bevonásával lehetőség adódik a túltanulás problémájának megelőzésére. A korai leállítási módszerét eddig a tréning- és validációs adatsor adott kombinációja esetén alkalmaztuk, azonban meg kell győződnünk arról, hogy hasonló és megbízható eredményeket érhetünk el a rendelkezésre álló adatok eltérő módon történő szétválasztásakor is. Amennyiben igen, akkor a fent leírt szakirodalmi adatok és javaslatok figyelembevételével meggyőződhetünk a felépített neurális hálózat működésének helyességéről, valamint a túltanulás sikeres megelőzéséről is.

4.3.5. A látástávolság előrejelzéséhez készített neurális hálózat

A neurális hálózatok első kísérleti alkalmazása során arra kerestük a választ, hogy a meteorológiai elemek és a MOR megfigyelések között mennyire szoros kapcsolat figyelhető meg akkor, amikor mind a tanuló adatsor, mind pedig a független, validálásra szánt minták esetén megbízható eredményeket kapunk. A neurális hálózat működése pedig, amint azt az előzőekben is láthattuk, akkor tekinthető megbízhatónak, ha a korábban nem látott bemenetekre nézve jól tud általánosítani. A neurális hálózatok tanításához egy ingyenesen hozzáférhető programot (Multiple Back-Propagation (with CUDA) version 2.2.4) alkalmaztunk. A program működése során minden egyes epoch után számszerűsíti a két adatsor közötti átlagos négyzetes hiba négyzetgyökét (32).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (MOR_{mért} [méter] - MOR_{előrejelzett} [méter])^2} \quad (32)$$

A fenti egyenletben az összegzés a minta adatsor n számú elemére történik. (32) figyelembevételével nyomon követhető, mikor kezd a validációs adatbázisra vonatkozó $RMSE$ szignifikánsan növekedni. Így megállapítható, mikor érdemes leállítani a hálózat tanítását, valamint megkapjuk azokat a súlyokat is, amelyek az optimális eredményeket produkálják az adatsorokra nézve.

A PP és nowcasting megközelítésű neurális hálózat esetén eltérő szempontok szerint kerültek kiválogatásra a prediktorok, azonban a két megközelítés néhány jellemzője a tanulási folyamat során közösnek tekinthető. Egyrészt, hogy a prediktorok mindegyikét lineárisan a $[-1;1]$ intervallumba transzformáljuk. Erre a transzferfüggvény tulajdonságai

miatt van szükségünk (Svozil *et al.*, 1997), ugyanis az általunk is alkalmazott (13) és (14) függvények az előbbi intervallumon rendelkeznek a legnagyobb értékészlettel. További közös tulajdonság, hogy nem a látástávolság közvetlenül mért értékét közelítjük a hálózati tanítás során, hanem annak természetes alapú logaritmusát, tehát a logaritmikus MOR értékek közötti *RMSE* értéket szeretnénk minimalizálni. Mindez azért előnyös, mert a látástávolság logaritmikus értéke nagyobb változékonyságot eredményez a kisebb látásértékek esetén, mint a nagyobbaknál. Az operatív előrejelzési gyakorlatban, elsősorban repülőtereken pedig fontos követelmény, hogy a kis látásértékeket nagy megbízhatósággal becsüljük.


4.3.5.1. Perfekt Prognosztikai megközelítésű neurális hálózat

A *PP* megközelítés esetén elsődleges vizsgálatainkat a 2006–2012 adatsorra végeztük. Elsőként az adatokat két részre osztottuk, amely során a 2006–2010 ötéves adatsort tanulásra, míg a 2011–2012-es kétéves adatsort validálásra használtuk fel. Ez a felosztás a rendelkezésre álló mintaelemek számának tekintetében megfelel a korábban említett 70%–30%-os felosztásnak. Abból a célból, hogy a neurális hálózat tanítására és validálására minél több minta álljon rendelkezésünkre, a látástávolság-előrejelző algoritmusnál felhasznált mintákon kívül annyi véletlenszerűen válogatott MOR = 10000 méter esetet is figyelembe vettünk, hogy az 5000 méter alatti, valamint 5000 méter feletti látásértékekkel rendelkező esetek száma megegyezzen. Mindez azért szükséges, hogy a hálózat a repülési szempontból kiemelt jelentőségű és kevésbé fontos látásértékekre egyaránt jól tudjon általánosítani. Amennyiben a hálózattal csak a kis látásértékeket taníttatnánk meg, jó látási viszonyok esetén mindig ködöt, illetve páráságot prognosztizálnánk, ezáltal jelentősen megnövelnénk a kis látásértékek téves riasztásainak számát.

A minták szétválogatása után a következő lépést a hálózat bemeneti rétegét képező prediktorok meghatározása jelentette. Munkánk során eltérő számú prediktor alkalmazásával végeztük vizsgálatainkat, így lehetőségünk nyílt arra, hogy a legjobb eredményeket produkáló bemenetek adott kombinációját tartsuk meg a jövőben. A felhasználandó prediktorok meghatározása során elsődleges célunk az volt, hogy a lehető legkevesebb bemeneti értéket alkalmazzuk, ugyanakkor ne hagyjuk figyelmen kívül a látástávolságot meghatározó legfontosabb tényezők egyikét sem. Az *M. FOGSI* indexek és döntési fa során alkalmazott bemeneteken túl figyelembe vettük a tengerszintre átszámított légnyomást (*QNH*), a szélirányt, valamint az éven belüli időszakot is, hogy a látástávolság

szezonálisan jelentkező változásairól is információhoz jussunk. Ez utóbbihoz *Dean és Fiedler* (2001) alapján két prediktort alkalmaztunk úgy, hogy az év napjait $[0; 2\pi]$ intervallumba képeztük, majd azok szinuszt és koszinuszt vettük figyelembe. Mivel az *M.FOGSI* indexek és a döntési fa alkalmazásával a szélirány, a légnyomás és az éven belüli időszakok figyelembevételével nem tudtunk további, egyértelmű elkülönítést alkalmazni, ezért ott figyelmen kívül hagytuk őket. A neurális hálózatok alkalmazásával azt vártuk, hogy azok összetettségüknek és nemlineáris tulajdonságaiknak köszönhetően a látástávolság-előrejelző algoritmushoz képest kedvezőbb eredményeket érhetünk el mind a diszkrét verifikációs mérőszámok, mind pedig a korrelációs együttható tekintetében.

Kezdetben 17 prediktort vettünk figyelembe, később 15-öt, végül csak 12-t, amelyeket a **9. ábrán** tüntettünk fel.



9. ábra: A neurális hálózatok *PP* megközelítésű látástávolság előrejelzéséhez alkalmazott prediktorok és prediktandusz. A piros és zöld színnel jelölt tagokat később elhagytuk.

A kezdetben 17 prediktor közül először a légkör vertikális hőmérsékleti rétegződését kifejező tagokat ($T_{2m} - T_{925}$; $T_{925} - T_{850}$), később pedig az egyes szintek harmatpontdeficitjeire vonatkozó tagokat ($T_{2m} - Td_{2m}$; $T_{925} - Td_{925}$; $T_{850} - Td_{850}$) hagytuk el. Így a meteorológiai elemek közül kiküszöböltük azokat a prediktorokat, amelyek kifejezhetők egy-egy másik prediktor függvényében. Kevesebb prediktor bevonása a látástávolság-előrejelzésbe azért is előnyt jelent, mert megnövelhető a neurális hálózat variációs lehetőségeinek, többek között a rejtett rétegbeli neuronoknak a száma is anélkül, hogy túltanítanánk a hálózatot. A **4.3.4. fejezetben** leírtak szerint ugyanis ügyelnünk kellett arra, hogy fennálljon a tanuló minták és a súlyok, továbbá a bemeneti és

kimeneti neuronok, valamint a rejtett rétegbeli neuronok számának a szakirodalmi ajánlások szerinti aránya.


Egy-egy tanulási folyamatot ugyanazokkal a beállítással többször is megvizsgáltunk, s a korai leállítás módszerével a többszöri futtatás eredményeként kapott legjobb eredményt tartottuk meg. A neurális hálózat általánosító képességének végső bizonyítására az évek szerint tanuló- és validációs adatsorra elkülönített csoportok helyett olyan lehetőségeket is megvizsgáltunk, amikor a rendelkezésre álló adatokat véletlenszerűen választottuk szét két csoportba. Amennyiben hasonló eredményeket kaptunk ez utóbbi esetben is, végleg meggyőződhattünk a neurális hálózat működésének helyességéről.

4.3.5.2. Nowcasting célú neurális hálózat

Az elmúlt évek kutatásai arról tanúskodnak, hogy a látástávolság neurális hálózatokkal történő prognózisai *nowcasting* célú alkalmazások esetén a legmegbízhatóbbak. Ennek oka, hogy elsősorban a meteorológiai elemek ténylegesen mért és megfigyelt értékei képezik a prediktorokat, így a modellkimenetekből származó hiba nem befolyásolja prognózisainkat. Következésképpen lehetőségünk nyílik arra, hogy olyan bemeneteket is figyelembe vegyünk, amelyek előrejelezhetősége még napjainkban is nagy bizonytalanságot hordoz magában. Ilyen bemenetek többek között a csapadékösszeg, felhőalap és borultság is, amelyeket a dinamikai modellel való látástávolság-előrejelzések során nem alkalmaztunk. A *nowcasting* előrejelzések esetén ez utóbbi három mennyiségen túl a meteorológiai elemek felszínközeli értékeit használtuk prediktorként. A légkör magasabb szintjeinek hőmérsékleti- és nedvességi viszonyairól ekkor nem kaptunk pontos kvantitatív képet, azonban a rendelkezésünkre álló több tízezer, órás felbontású adat felhasználásával a látástávolság nemcsak éves és évszakos, hanem napi változékonyságáról is információhoz jutottunk. A felhőalap- és borultságértékek pedig jó indikátornak tekinthetők a rossz látási viszonyok, így a páráság, valamint köd kialakulásának esetében is. A felhőalap- és borultság értékeket észlelők megfigyelései alapján, METAR táviratokból származtattuk.

A táviratban maximálisan három felhőzetre utaló csoportot különböztethetünk meg, amelyek mindegyike egy-egy felhőalap magasságot és borultsági értéket tartalmaz. Ez utóbbi esetén négy felhőborítottság kategóriát különíthetünk el: *FEW* (1–2 okta), *SCT* (3–4 okta), *BKN* (5–7 okta) és *OVC* (8 okta), amelyeket sorra 1, 2, 3 és 4 kódokkal azonosítottunk, derült égbolt esetén pedig 0 borultsági értéket alkalmaztunk. Felhőalapként

a legalacsonyabb szintű felhőzet alapját, míg a felhővel való borítottság értékeként a különböző magasságokban megfigyelhető kategóriák közül a maximálisat vettük figyelembe. Munkánk során összesen 22 prediktort alkalmaztunk, amelyeket a **10. ábrán** tüntettünk fel.



10. ábra: A neurális hálózatok *nowcasting* célú látástávolság előrejelzéséhez alkalmazott prediktorok és prediktandusok.

A meteorológiai elemek és a MOR nemcsak adott időpontbeli (t), hanem egy órával korábbi ($t-1$) méréseit is figyelembe vettük, hogy azok tendenciáiról is legyen információnk. Az előző, *PP* megközelítésű neurális hálózathoz képest az új prediktorok bevezetésén túl további különbség, hogy a műszerszínti légnyomást (QFE) vettük figyelembe, elkerülve ezzel a tengerszintre történő átszámítás közelítéséből származó hibákat. A napszakokra vonatkozó információkat *Pasini és mtsai.* (2001) alapján két prediktor alkalmazásával (33) és (34) szerint vettük figyelembe:

$$\sin(napszak) = \frac{\sin\left[\frac{\pi T}{12}\right] + 1}{2}, \quad (33)$$

$$\cos(napszak) = \frac{\cos\left[\frac{\pi T}{12}\right] + 1}{2}, \quad (34)$$

ahol T az UTC-ben kifejezett órát jelenti. A *PP* megközelítésű neurális hálózathoz hasonlóan a 2006–2010 ötéves adatsort használtuk tanulásra, míg a 2011–2012-es kétéves adatsort validálásra.

5. Eredmények

5.1. A látástávolság-előrejelző algoritmusok során előálló látástávolság-kategóriák verifikációja

Ebben a fejezetben a korábban bemutatott *M. FOGSI* indexek, valamint a kapcsolódó döntési fa által becsült látástávolság-értékek megbízhatóságát ismertetjük három látástávolság-kategóriára vonatkozóan. Az egyes kategóriák esetén a becslések jóságát a diszkrét verifikációs terminológia **3.2. fejezetben** ismertetett hat verifikációs mérőszámának (*PC, POD, CSI, FAR, BIAS, HSS*) értékein keresztül mutatjuk be. Azért ezt a hat indexet választottuk, hogy az eredmények minden részletre kiterjedő, reprezentatív képet tükrözzenek az egyes látástávolság-kategóriák előrejelezhetőségének megbízhatóságáról és korlátairól egyaránt. Az arányszámok összehasonlításával lehetőségünk adódott az eredeti (*Wantuch*, 2001), valamint az újonnan bevezetett módszer közötti különbségek feltárására is. A **3. táblázat** e két módszer referencia időszakra (2005. november–2011. december), valamint tesztidőszakra (2012–2013) vonatkozó verifikációs mérőszámait tartalmazza.

3. táblázat: A két algoritmus esetén előálló látásértékek összehasonlító verifikációja.
(A megvastagított értékek az eredeti módszerhez képest kedvezőbb verifikációs mérőszámokat jelölik.)

MOR kategóriák	Index neve	Eredeti <i>FOGSI</i> index és döntési fa (<i>Wantuch</i> , 2001) alkalmazása		<i>M. FOGSI</i> indexek és az új döntési fa alkalmazása	
		Ref. időszak (2005–2011)	Tesztidőszak (2012–2013)	Ref. időszak (2005–2011)	Tesztidőszak (2012–2013)
<i>MOR</i> ≤ 1000 m	<i>PC</i>	0,780	0,810	0,832	0,863
	<i>POD</i>	0,540	0,538	0,545	0,407
	<i>CSI</i>	0,199	0,215	0,246	0,229
	<i>FAR</i>	0,760	0,735	0,689	0,656
	<i>BIAS</i>	2,250	2,038	1,757	1,185
	<i>HSS</i>	0,223	0,258	0,306	0,296
1000 m < <i>MOR</i> ≤ 5000 m	<i>PC</i>	0,556	0,583	0,638	0,586
	<i>POD</i>	0,500	0,492	0,619	0,620
	<i>CSI</i>	0,368	0,374	0,470	0,431
	<i>FAR</i>	0,416	0,390	0,338	0,413
	<i>BIAS</i>	0,857	0,808	0,937	1,058
	<i>HSS</i>	0,116	0,168	0,277	0,172
5000 m < <i>MOR</i>	<i>PC</i>	0,716	0,698	0,743	0,708
	<i>POD</i>	0,557	0,616	0,606	0,570
	<i>CSI</i>	0,427	0,448	0,474	0,435
	<i>FAR</i>	0,353	0,377	0,315	0,351
	<i>BIAS</i>	0,861	0,990	0,885	0,878
	<i>HSS</i>	0,381	0,370	0,443	0,376

A referencia időszakra valamennyi verifikációs index tekintetében, a tesztidőszakra pedig túlnyomó többségében kedvezőbb mutatókat értünk el. A találati arány (*POD*) értékek legnagyobb mértékű javulása páráság esetén, míg a legkisebb pozitív változás ködös helyzetekben figyelhető meg. Köd esetén a tesztidőszakra vonatkozó találati arány az eredeti módszerhez képest kisebbnek (0,407) adódott. Ugyanakkor nem szabad elfeledkeznünk a hiányos és téves riasztások számáról sem. Annak ellenére, hogy köd esetén az említett *POD* érték a referencia időszakra vonatkozóan kismértékben javult, illetve a tesztidőszak esetén valamelyest romlott, a téves riasztási arány (*FAR*) mindkét esetben csökkent, továbbá a hiányos riasztások számát is figyelembe vevő kritikus sikerességi index (*CSI*) értéke nőtt. Figyelemre méltó, hogy a gyengébb *POD* értékek ellenére köd esetén a legnagyobb a helyes előrejelzések aránya (*PC*). Ez azt jelenti, hogy minden olyan helyzetben további javulás figyelhető meg, amikor köd nem lett előrejelezve, és nem is következett be 1000 méternél kisebb látástávolság. További pozitív eredménynek számít, hogy köd esetén a *BIAS* érték 2,250-ről 1,757-re, illetve 2,038-ról 1,185-re csökkent. Ennek értelmében a köd előrejelzése túlbiztosított maradt, azaz az előrejelzett események száma továbbra is nagyobb a bekövetkezett esetek számához képest, azonban ez az arány már 2,0 alatti. A legösszetettebb beválási mutató, a Heidke Skill Score (*HSS*) minden látástávolság-kategóriára nézve javulást mutatott, legnagyobb mértékben a referencia időszakra vonatkozóan, páráság esetén, ahol több, mint kétszeres *HSS* értéket nyertünk.

Fontos, hogy az alkalmazott módszer ne csak a teljes adatsor tekintetében mutasson megbízható eredményeket, hanem azokban a helyzetekben is, amikor a rosszabb látási viszonyok relatív gyakorisága nagy. A két említett módszer verifikációs indexeinek öszre és télre, referencia időszakra vonatkozó értékeit a **4. táblázatban** tüntettük fel. A referencia időszakra vonatkozóan, tavaszra, valamint nyárra nem számoltunk verifikációs indexeket, ugyanis ezek az adatok a teljes adatsor mindössze 1/10-ed részét képezik.

Évszakos összehasonlításban az őszi és téli évszakokra a **3. táblázat** értékeihez képest valamivel kedvezőbb verifikációs mérőszámok születtek. Ebből arra következtethetünk, hogy tavasszal, de főként nyáron az alkalmazott látástávolság-előrejelző módszer kevésbé jól alkalmazható. Ennek oka elsősorban az, hogy a módszer a ködöt és páráságot többségében az egyes főizobárszintek között megfigyelhető hőmérsékleti gradiensek szerint kategorizálja. Nyáron a kisugárzási időszak rövidege miatt azonban a felszínközeli hőmérsékleti inverzió ritkán éri el a 925 hPa-os magasságot, inkább a felszínközeli néhány tízméteres rétegre korlátozódik. Így a sekély köd

detektálására a módszer kevésbé alkalmazható, ugyanakkor az őszi és téli félévben, amikor mind a páráság, mind pedig a köd relatív gyakorisága nagy, megbízható eredményeket kapunk.

4. táblázat: A két algoritmus esetén előálló látásértékek összehasonlító verifikációja őszi és téli, a referencia időszak esetén.
(A **megvastagított értékek** az eredeti módszerhez képest kedvezőbb verifikációs mérőszámokat jelölik.)

MOR kategóriák	Index neve	Ősz		Tél	
		Eredeti <i>FOGSI</i> index és döntési fa (Wantuch, 2001) alkalmazása	<i>M. FOGSI</i> indexek és az új döntési fa alkalmazása	Eredeti <i>FOGSI</i> index és döntési fa (Wantuch, 2001) alkalmazása	<i>M. FOGSI</i> indexek és az új döntési fa alkalmazása
<i>MOR</i> ≤ 1000 m	<i>PC</i>	0,794	0,851	0,755	0,824
	<i>POD</i>	0,655	0,724	0,539	0,516
	<i>CSI</i>	0,246	0,333	0,195	0,242
	<i>FAR</i>	0,716	0,618	0,765	0,686
	<i>BIAS</i>	2,310	1,896	2,301	1,645
	<i>HSS</i>	0,294	0,422	0,205	0,294
1000 m < <i>MOR</i> ≤ 5000 m	<i>PC</i>	0,595	0,659	0,541	0,652
	<i>POD</i>	0,519	0,658	0,462	0,610
	<i>CSI</i>	0,370	0,469	0,366	0,503
	<i>FAR</i>	0,436	0,379	0,361	0,258
	<i>BIAS</i>	0,922	1,062	0,723	0,823
	<i>HSS</i>	0,180	0,317	0,104	0,310
5000 m < <i>MOR</i>	<i>PC</i>	0,723	0,758	0,743	0,778
	<i>POD</i>	0,572	0,588	0,618	0,698
	<i>CSI</i>	0,476	0,517	0,432	0,498
	<i>FAR</i>	0,260	0,188	0,410	0,365
	<i>BIAS</i>	0,774	0,725	1,049	1,100
	<i>HSS</i>	0,424	0,495	0,414	0,500

5.2. Neurális hálózatok

5.2.1. Perfekt Prognosztikai megközelítésű előrejelzések verifikációja

Ebben a fejezetben a *PP* megközelítésű neurális hálózatok alkalmazása során nyert eredményeket ismertetjük. A **4.3.4. fejezetben** leírtak szerint a neurális hálózatok szerkezetének több, lehetséges konfigurációjával is vizsgálatokat végeztünk abból a célból, hogy megtaláljuk a legkedvezőbb látásértékeket reprezentáló hálózatot. Az **5. táblázatban** eltérő számú prediktor és rejtett rétegbeli neuron különböző kombinációi során előálló, mért és számított *MOR* értékek közötti legjobb korrelációs együtthatókat és *RMSE* értékeket tüntettük fel. A táblázatban az egyes esetekre vonatkozó, rejtett rétegbeli neuronoknál alkalmazott két különböző transzferfüggvény során nyert eredményeket is

közöltük. További vizsgálatok során számszerűsítettük és az **5. táblázatban** feltüntettük azt is, hogy a tanuló és validációs adatsorok esetén előálló hálózati súlyokat alkalmazva a rendelkezésre álló minták [70% (*Adatsor 1*)] – [30% (*Adatsor 2*)] arányú véletlenszerű (nem évek szerinti) csoportosítása során mennyire megbízható eredményekhez juthatunk. A rejtett rétegbeli neuronok maximális számát a túltanulás elkerülése végett a prediktorok és a tanuló minták számának ismeretében a (31) egyenlet segítségével határoztuk meg. A táblázatban a rejtett rétegbeli neuronok maximális számával, valamint kevesebb rejtett rétegbeli neuronnal végzett kísérleti eredmények kerültek feltüntetésre.

5. táblázat: A neurális hálózatok *PP* megközelítése során különböző konfigurációk esetén a mért és becsült látásértékek között megfigyelhető korrelációs együtthatók és *RMSE* értékek.


Prediktorok száma	Rejtett neuronok száma	Transzfer-függvény	Rendezett adatsor (évek szerinti)		Véletlenszerűen válogatott adatok	
			<i>r</i> , (<i>RMSE</i>) (2006–2010)	<i>r</i> , (<i>RMSE</i>) (2011–2012)	<i>r</i> , (<i>RMSE</i>) (<i>Adatsor 1</i>)	<i>r</i> , (<i>RMSE</i>) (<i>Adatsor 2</i>)
17	9	<i>szigmoid</i>	0,756 (2139)	0,761 (2268)	0,759 (2159)	0,756 (2223)
	9	<i>tangens hip.</i>	0,762 (2104)	0,773 (2221)	0,761 (2148)	0,778 (2110)
	5	<i>szigmoid</i>	0,742 (2192)	0,743 (2327)	0,743 (2201)	0,741 (2305)
	5	<i>tangens hip.</i>	0,750 (2110)	0,762 (2271)	0,744 (2171)	0,777 (2134)
15	10	<i>szigmoid</i>	0,773 (2095)	0,778 (2212)	0,774 (2120)	0,778 (2155)
	10	<i>tangens hip.</i>	0,767 (2103)	0,782 (2177)	0,766 (2135)	0,783 (2102)
	5	<i>szigmoid</i>	0,742 (2146)	0,774 (2230)	0,751 (2186)	0,755 (2206)
	5	<i>tangens hip.</i>	0,753 (2113)	0,740 (2352)	0,751 (2160)	0,748 (2252)
12	12	<i>szigmoid</i>	0,765 (2122)	0,787 (2170)	0,775 (2098)	0,769 (2224)
	12	<i>tangens hip.</i>	0,754 (2143)	0,765 (2244)	0,752 (2180)	0,771 (2158)
	6	<i>szigmoid</i>	0,749 (2147)	0,755 (2345)	0,750 (2213)	0,755 (2258)
	6	<i>tangens hip.</i>	0,751 (2147)	0,742 (2353)	0,750 (2175)	0,748 (2291)

A fenti táblázatban megfigyelhetjük, hogy kevesebb prediktor bevonásával is hasonló megbízhatóságú eredményeket érhetünk el. A redundancia elkerülése végett az egymástól függő meteorológiai elemeket kivontuk a bemeneti rétegből, a neurális hálózattal a tanulási folyamat során ekkor is közel ugyanazokat az eredményeket nyertük – a lehető legkevesebb – egymástól független prediktor használata esetén. Arról is megbizonyosodhatunk, hogy a véletlenszerűen válogatott adatokkal mind a korrelációs együttható, mind pedig az *RMSE* értékek tekintetében hasonló eredményekhez juthatunk, mint a rendelkezésre álló minták évek szerinti kategorizálása során.


Általánosságban még elmondható, hogy több rejtett neuron alkalmazásával az esetek többségében megbízhatóbb eredmények nyerhetők. Rögzített elemszám esetén pedig a rejtett neuronok számának növelése a prediktorok számának csökkentésével érhető el, következésképpen a 12 prediktor választása optimálisnak tekinthető.

A legnagyobb, erős korrelációs együtthatókat, valamint megbízható *RMSE* értékeket mind a tanuló, mind pedig a validációs adatsorra vonatkozóan akkor kaptuk, amikor a szabadsági fokok maximális számát kihasználva a prediktorok számával megegyező, 12 szigmoid transzferfüggvénnyel rendelkező rejtett rétegbeli neuront alkalmaztunk. Ezért a további vizsgálatainkat ezekkel a beállításokkal végeztük. Ekkor a tanuló adatsorra 0,765, míg a validációs adatsorra 0,787 korrelációs együtthatót nyertünk. A két adatsorra vonatkozó eredményeket a **11. a, b ábrán** tüntettük fel, amelyek esetén megfigyelhető, hogy a neurális hálózat súlytanulási folyamata után kapott látásértékek mindkét adatsor tekintetében jól visszaadják a látástávolság éves változékonyságából eredő változásokat.

(a)




(b)



11. ábra: A neurális hálózat *PP* megközelítése során 12 rejtett neuronnal, szigmoid transzferfüggvény alkalmazásával kapott látásértékek (a) a tanuló adatsor (2006–2010), valamint (b) a validációs adatsor (2011–2012) esetén.

A modell a minimális látásértékek esetén kissé felülbecsli, míg a maximális látásértékek esetén valamelyest alulbecsli a tényleges értékeket. Ennek oka, hogy a szigmoid transzferfüggvény tulajdonságainál fogva kimeneti értéként 0 és 1 közötti számot ad eredményül, amely számot lineárisan feleltetünk meg a transzmisszió mérő által mért minimális, 0 körüli és a maximális 10000 méter közötti látástávolság logaritmikus értékének. Következésképpen a végső látásértékek esetén negatív, valamint 10000 méter feletti kimenetet egyetlen esetben sem kapunk eredményül.

A hálózat tanítása során az *RMSE* hibafüggvény minimalizálása a célunk, ezért azt várjuk, hogy a legkisebb abszolút hibával terhelt esetek relatív gyakorisága a legnagyobb. Mivel a tanulási folyamat során a látástávolság logaritmikus értékeit közelítettük, ezért azt is feltételezhetjük, hogy kis látásértékek esetén, kisebb hibaintervallumban is teljesül az előbbi feltétel. A látástávolság-előrejelző algoritmusnál korábban már ismertetett három látástávolság-kategóriára vonatkozó, az abszolút hibák relatív gyakoriságát reprezentáló hisztogramokat a **12.a, b, c ábrán** tüntettük fel. 1000 méternél kisebb látásértékek esetén 200 méter **(a)**, 1000 és 5000 méter között 500 méter **(b)**, míg 5000 méter felett 1000 méteres felbontással **(c)** adtuk meg azokat az abszolút hibaintervallumokat, amelyek relatív gyakorisági értékeit ábrázoltuk.



12. ábra: A neurális hálózat *PP* megközelítése során 12 rejtett neuronnal, szigmoid transzferfüggvény alkalmazásával kapott látásértékekre vonatkozó hibaintervallumok relatív gyakorisága a tanuló adatsorra vonatkozóan **(a)** $MOR \leq 1000$ méter, **(b)** $1000 \text{ méter} < MOR \leq 5000$ méter, valamint

(c) $5000 \text{ méter} < MOR$ esetén.

(Azokat a szimmetrikus intervallumokat tüntettük fel, amelyekbe az esetek minimum 90%-a beletartozik.)

Megfigyelhető, hogy várakozásainknak megfelelően mindhárom látástávolság-kategóriánál a legkisebb abszolút hibával terhelt esetek relatív gyakorisága a legnagyobb. A hisztogramok alátámasztják azt a korábbi állításunkat is, miszerint kisebb látásértékek esetén **(12.a ábra)** többnyire felülbecslés, míg nagyobb látásértékekénél **(12.c ábra)** alulbecslés figyelhető meg. Nagy látásértékekénél a $[-1000;0)$ hibaintervallumhoz tartozó kiugró relatív gyakorisági érték pedig annak tudható be, hogy a neurális hálózat megbízható becsléseket ad azokra az időjárási helyzetekre, amikor kiváló látási viszonyok ($MOR=10000$ méter) uralkodnak.

A neurális hálózatok további tesztelése céljából a tanuló és validációs adatsorokon kívül egy harmadik adatsorral, az előző kettőtől független, 2013-as évre vonatkozó teszt adatsorral is vizsgálatokat végeztünk. Ez utóbbi adatsor esetén $r = 0,723$ korrelációs együtthatót, valamint $RMSE = 2349$ hibaértéket kaptunk, amely értékek nem különböznek szignifikánsan az **5. táblázatban** megfigyelhető mérőszámoktól. Következésképpen megbizonyosodhatunk a hálózat megfelelő általánosító képességéről.

Legvégül számszerűsítésre kerültek azok a diszkrét verifikációs mérőszámok, amelyek a látástávolság-becslésekről kategóriába sorolásuk helyességét illetően adnak tájékoztatást. Ezáltal a módszer kategorikus prognosztikai képességéről is információhoz jutottunk. Ugyanazokat a mérőszámokat alkalmaztuk, amelyeket a **3.2. fejezetben** korábban ismertettünk. Eredményeinket a **6. táblázatban** foglaltuk össze. Ha összehasonlító elemzéseket végzünk a látástávolság-előrejelző algoritmus **3. táblázatban** feltüntetett diszkrét verifikációs mérőszámaival, akkor látható, hogy ködös helyzetekben a POD értéke kisebbnek adódott. Ez részben annak köszönhető, hogy a köd előrejelzések száma kisebb a megfigyelések számához képest. Ennek ellenére a hamis riasztások aránya (FAR) minden látástávolság-kategória tekintetében kedvezőbb lett. A kategóriák többségére ez a CSI indexnél is teljesül. A reprezentatív információt nyújtó HSS index mindhárom adatsorra és kategóriára vonatkozóan nagyobb értéket mutatott. Hasonlóképpen, a többi index tekintetében túlnyomó többségében kedvezőbb értékekhez jutottunk.

Nem szabad azonban megfeledkeznünk arról, hogy a neurális hálózatok módszerének alkalmazásával a mért és számított látásértékek közötti $RMSE$ hibát minimalizáltuk, nem a kategorizálás helyességét tekintettük elsődlegesnek. Következésképpen többször előfordul, hogy a hálózati kimenet az egyes látástávolság-kategóriák küszöbszámaihoz közeli értéket eredményez, azonban a besorolás a szomszédos

kategóriába történik. Ennek köszönhető többek között a ködös helyzetek esetén előálló kisebb *POD* érték is. Ellenben a **12.a ábrán** megfigyelhetjük, hogy a ködre vonatkozó abszolút hiba az esetek többségében 1000 méter alatti, így kijelenthetjük, hogy a módszer megbízható segítséget nyújthat az előrejelzők számára a kisebb látásértékek rövid, illetve középtávú prognózisához. A látástávolság-előrejelző algoritmussal további összehasonlító vizsgálatokat végezve elmondható, hogy a neurális hálózatokkal a teljes adatsorra nézve több, mint 0,2-del nagyobb korrelációs együtthatót nyertünk a mért és számított látásértékek között, következésképpen a neurális hálózatokkal azok összetettségüknek és nemlineáris tulajdonságaiknak köszönhetően szorosabb kapcsolat létesíthető a meteorológiai elemek és a horizontális látástávolság között.


6. táblázat: A neurális hálózatok *PP* megközelítése során az egyes látástávolság-kategóriákra vonatkozó diszkrét verifikációs mérőszámok.

MOR kategóriák	Index neve	Tanuló adatsor (2006–2010)	Validációs adatsor (2011–2012)	Teszt adatsor (2013)
<i>MOR</i> ≤ 1000 m	<i>PC</i>	0,936	0,930	0,961
	<i>POD</i>	0,473	0,357	0,307
	<i>CSI</i>	0,375	0,263	0,210
	<i>FAR</i>	0,357	0,500	0,600
	<i>BIAS</i>	0,736	0,714	0,769
	<i>HSS</i>	0,511	0,380	0,328
1000 m < <i>MOR</i> ≤ 5000 m	<i>PC</i>	0,728	0,743	0,820
	<i>POD</i>	0,766	0,710	0,615
	<i>CSI</i>	0,542	0,544	0,366
	<i>FAR</i>	0,350	0,301	0,523
	<i>BIAS</i>	1,180	1,017	1,292
	<i>HSS</i>	0,456	0,478	0,428
5000 m < <i>MOR</i>	<i>PC</i>	0,785	0,808	0,849
	<i>POD</i>	0,731	0,820	0,879
	<i>CSI</i>	0,630	0,681	0,823
	<i>FAR</i>	0,179	0,199	0,072
	<i>BIAS</i>	0,891	1,024	0,947
	<i>HSS</i>	0,571	0,616	0,566

5.2.1.1. Érzékenységi vizsgálat

A *PP* megközelítésű neurális hálózat kimenete a 12 prediktor függvényében előálló látástávolság-érték. A látástávolságot előállító neurális hálózat súlyait egy hiba-minimalizálási módszeren alapuló, összetett matematikai algoritmus alkalmazása során kaptuk. Matematikai szempontból tehát lehetőségünk nyílt a meteorológiai elemek és a látástávolság közötti lehető legszorosabb kapcsolat kialakítására, azonban a módszer

hitelességének bizonyításaként izgalmas kérdésként merül fel, hogy a tényleges fizikai kapcsolatok reálisan képződtek-e a neurális hálózatok tanulási folyamata során. Példaként három olyan – különböző hőmérsékleti rétegződésű – helyzetet választottunk, amikor a felszín közelében telített, 100% relatív nedvességtartalmú levegő és gyenge, 3 ms^{-1} -nál kisebb légmozgás volt megfigyelhető. Arra kerestük a választ, hogy az egyes helyzetekben a hálózat miként reagál a relatív nedvesség csökkentésére, illetve a szélesebbesség növelésére akkor, ha a többi prediktor értékét változatlanul hagyjuk. Az eredmények a **13. ábrán** kerültek feltüntetésre.



13. ábra: A neurális hálózat **(a)** a relatív nedvesség csökkenésére, valamint **(b)** a szélesebbesség növekedésére adott válasza különböző hőmérsékleti rétegződésű helyzetekben.

A fenti ábrákon a kisugárzási inverziós és hideg légpárnás időjárási helyzeteket úgy különítettük el, mint korábban a látástávolság-előrejelző algoritmus döntési fája esetén. Előbbi esetben az inverziós hőmérsékleti rétegződés a felszín közelétől a 925 hPa főizobárszintig megfigyelhető, azonban a 925 hPa és 850 hPa szintek között már nem. Ezzel szemben hideg légpárnás helyzetekben hőmérsékleti inverzió ez utóbbi főizobárszintek között is észlelhető. Várakozásainknak megfelelően mindhárom kiválasztott helyzetben a relatív nedvesség csökkenésére és a felszínközeli szélesebbesség növekedésére egyaránt nagyobb látástávolság-értékkel válaszolt a hálózat, azonban látható, hogy a növekedés mértékében a légkör vertikális hőmérsékleti rétegződése is jelentős szerephez jut. A **13.a ábrán** megfigyelhető, hogy hőmérsékleti inverzió jelenlétekor a kezdetben csak kismértékű, majd a relatív nedvesség további csökkentése során már jelentősebb látásjavulás figyelhető meg. Hasonló következtetésre juthatunk a kiválasztott normál hőmérsékleti rétegződésű időjárási helyzet esetében is, ellenben az előzőekhez képest a kis kezdeti látásérték változásának tendenciája már a relatív nedvesség 100%-ról 90%-ra való csökkentése során nagyobb mértékű javulást mutat, köszönhetően a vastagabb légrétegre kiterjedő hőmérsékleti inverzió hiányának, ezáltal a nagyobb légköri átkeveredési lehetőségnek. A **13.b ábra** arról nyújt információt, hogy a felszínközeli

szélsébség növekedése az említett átkeveredési folyamatok intenzitásának növekedésén keresztül miként befolyásolja a látástávolság értékét konstansnak feltételezett, 100% relatív nedvesség esetén. Itt is megfigyelhető, hogy normál hőmérsékleti rétegződés esetén az intenzívebb turbulens átkeveredés nagyobb mértékű látásjavulást eredményez a hőmérsékleti inverziós helyzetekhez képest, amelyeknél a szélsébség növelésére a hálózat csak kismértékű változásokkal válaszolt.

A bemutatott példákon keresztül elsősorban arra voltunk kíváncsiak, hogy a neurális hálózat miként reagál a látástávolságot meghatározó két fontos prediktor, a felszínközeli relatív nedvesség és szélsébség változásaira. E prediktorok értékeinek megváltoztatásával tulajdonképpen olyan fiktív időjárási helyzeteket állítottunk elő, amelyeket a hálózat korábban nem látott. Például ilyen idealizált időjárási helyzetnek tekinthető a hideg légréteg és élénk szélsébség egyidejű jelenléte. Természetesen ez előbbi eset a valóságban nem, vagy csak ritkán és rövid ideig állhat fenn. Összességében a három különböző hőmérsékleti rétegződésű időjárási helyzettel végzett vizsgálataink igazolják, hogy a hálózat nemcsak a korábban látott bemenetekre nézve ad kielégítő becslést a látástávolság várható értékére, hanem képes az említett fizikai kapcsolatokra reális leképezésére is.

Előző kísérleteink során kizárólag egy-egy prediktor értékét változtattuk csak meg, azonban a hálózat általánosító képességének további feltérképezése céljából olyan vizsgálatot is végeztünk, amely során minden meteorológiai állapothatározó kezdeti értékében kismértékű változtatásokat alkalmaztunk. Ehhez példaként az előző, normál hőmérsékleti rétegződésű időjárási helyzetet választottuk, ugyanis amint azt az előzőekben megfigyelhettük, a hálózat ekkor a szélsébség és relatív nedvesség változásaira a többi helyzethez képesti legnagyobb látástávolság-változással reagált. Arra kerestük a választ, hogy ez a változékonyság miként befolyásolja a kimeneti látástávolságot akkor, ha csak kismértékű, de minden meteorológiai elem kezdeti értékére kiterjedő változtatásokat végzünk, alul-és felülbecsléseket egyaránt alkalmazva. Az eredeti és perturbált prediktorokat, valamint a neurális hálózat kimeneteként előálló látástávolság-értékeket a **7. táblázatban** jelenítettük meg. A táblázatban feltüntetésre kerültek azok a számszerű látástávolság-kimenetek is, amelyek a relatív nedvesség 10%-os csökkentése (**13.a ábra**), valamint a felszínközeli szélsébség 2 ms^{-1} növelése (**13.b ábra**) során előálltak.

A táblázat alapján arra következtethetünk, hogy a meteorológiai állapothatározók kezdeti értékeiben kismértékű változtatásokat eszközölve nem kapunk lényegesen eltérő látástávolság-értéket. Mivel a 12 prediktor adott együttállása közvetett módon egy-egy

időjárási helyzetet határoz meg, ezért elmondható, hogy a hálózat hasonló időjárási helyzetekhez (tehát a meteorológiai elemek hasonló együttállásához) szignifikánsan nem eltérő látástávolság-értékeket párosít. Ezzel szemben kizárólag egy meteorológiai állapothatározó értékében megfigyelhető nagyobb változás már más időjárási helyzetként fogható fel, amelyhez tehát lényegesen eltérő látástávolság tartozik.

7. táblázat: A meteorológiai állapothatározók eltérő kezdeti értékei és a hozzájuk kapcsolódó látástávolság kimenetek **A:** az eredeti kezdeti értékek; **B:** minden meteorológiai elem kezdeti értékén végzett kis változtatások; **C:** a 2 méteres relatív nedvesség értékének 10%-kal való csökkentése; **D:** a 10 méteres szélesség 2 ms⁻¹-mal történő növelése esetén.

	sin (év napja)	cos (év napja)	T_{2m} [°C]	RH_{2m} [%]	T_{925} [°C]	RH_{925} [%]	T_{850} [°C]	RH_{850} [%]	$W_{irány}$ [°]	W_{10m} [ms ⁻¹]	W_{850} [ms ⁻¹]	QNH [hPa]	MOR [m]
A	-0,940	0,342	3,7	100	2,4	81	-1,9	79	118	1,7	6,17	1015,9	1220
B	-0,940	0,342	4,7	97	3,4	84	-0,9	82	138	0,7	8,17	1012,9	1056
C	-0,940	0,342	3,7	90	2,4	81	-1,9	79	118	1,7	6,17	1015,9	3075
D	-0,940	0,342	3,7	100	2,4	81	-1,9	79	118	3,7	6,17	1015,9	2661

Arra a fontos következtetésre jutottunk, hogy a neurális hálózat egy-egy időjárási helyzetre nézve jól tud általánosítani, a korábban nem látott bemenetekre nézve pedig jól visszaadja a valóságban uralkodó, ténylegesen megfigyelhető fizikai kapcsolatokat. Jelen kutatásunk során a hálózat tanítására közel ezer minta állt rendelkezésünkre, azonban a látástávolság várható értékének minél pontosabb becslése céljából jövőbeli mérésekkel érdemes minél több mintát, így minél több időjárási helyzetet bevonni a tanulási folyamatba.


Legvégül olyan érzékenységi vizsgálatot végeztünk, amellyel a tanuló adatsor egészére nézve megvizsgáltuk, hogy minden mintában az egyes prediktorokra $\pm 5\%$ -os hibaintervallumon belüli véletlenszerű zajokat illesztve mennyire kapunk eltérő látástávolság-értékeket. Ennek értelmében a hálózat a 2 méteres relatív nedvességre, valamint a 2 méteres és 925 hPa főizobárszíni hőmérséklet változására a legérzékenyebb, ellenben a 850 hPa-os hőmérsékleti- és nedvességi viszonyokra, valamint az évszakra kisebb érzékenységet mutat.

5.2.1.2. Esettanulmány – A 2013. november 16–17-i ködös helyzet elemzése

E fejezetben a tanuló- és validációs adatsortól független mintákat képező, 2013-as tesztidőszakból a november 16–17-i éjszakai időjárási helyzetet vizsgáltuk esettanulmányként, amikor az ország nagy területén, így Budapest Liszt Ferenc Nemzetközi Repülőtérén is sűrű ködtakaró alakult ki. Választásunk azért erre az időszakra

esett, mert november 16-án az esti órákban kialakult sűrű köd olyan mértékben lecsökkentette a horizontális látástávolságot, hogy hatására másnap virradóra 14 repülőgép nem tudott leszállni a korlátozott látási viszonyok miatt. A meteorológiai elemek mért adataira támaszkodva megvizsgáltuk, hogy a látástávolság-előrejelző algoritmus során, vagy a neurális hálózatok kimeneteként előálló látástávolság-értékek nyújtanak-e megbízhatóbb becslést. Természetesen *PP* megközelítéssel éltünk, így feltételeztük, hogy az egyes prediktorokat képező dinamikai modell kimenetek pontosan megfelelnek az adott időpontbeli méréseknek, ezáltal lehetővé válik a legpontosabb, modellhibától független látástávolság-becslés.


2013. november 17-én a Kárpát-medence időjárását anticiklonális hatások határozták meg. Hazánk néhány nappal korábban annak az Ibériai-félsziget térségében megfigyelhető sekély ciklonális mezőnek a keleti peremén helyezkedett el, amely retrográd mozgással nyugat felé helyeződött át, teret biztosítva az azori anticiklon benyomulásának. A 2013. november 17. 00 UTC-s reanalízis térképet a **14. ábrán** tüntettük fel.



14. ábra: 2013. 11. 17. 00 UTC-re vonatkozó NCEP reanalízis
(Forrás: <http://www.wetterzentrale.de/topkarten/fsrea2eur.html>).

A légnyomási mezőben Magyarország felett kis gradiens-értékek figyelhetők meg, így meglehetősen gyenge szélsébség, illetve szélcsend volt a meghatározó. Az elmúlt napokban a 850 hPa-os szinten melegadvekcio fokozta a stabilitási viszonyokat. A légkör

vertikális állapotáról információt nyújtó rádiószondás mérések (15. ábra) arról tanúskodnak, hogy az alsó néhány száz méteres rétegben inverziós hőmérsékleti rétegződés figyelhető meg, továbbá a felszín közelében a hőmérsékleti és harmatpont görbe együttes futása nagy relatív nedvességi viszonyokra utal. 16-án a késő délutáni órákban már 100%-hoz közeli relatív nedvességet mértek, majd a levegő további lehülése egyre korlátozottabb látási viszonyok létrejöttéhez vezetett. 00 UTC-kor mindössze 123 méteres MOR értéket észlelt a 13R pályaküszöb menti transzmisszométer.



15. ábra: A 2013. 11. 17. 00 UTC-s budapest-lőrinci rádiószondás felszállás adatai
(Forrás: <http://weather.uwyo.edu/upperair/sounding.html>).

Mivel a 850 hPa főizobárszíni hőmérséklet kisebb volt a 925 hPa-os hőmérséklethez képest, továbbá a $M. Fogsi_3$ index értéke beleesett abba a kritikus intervallumba, amelyen belül a döntési fa alkalmazása szerint történik a látástávolság-kategóriák elkülönítése, ezért a besorolás a meteorológiai állapothatározók és a belőlük származtatott további fizikai mennyiségek szerint történt. Jelen esetben a nagy relatív nedvesség és kis szélesség miatt az algoritmus 1000 méteres látástávolságot adott visszatérési értéként. Ugyanakkor a neurális hálózat kimeneteként előálló látásérték 516 méternek adódott. Amíg az algoritmus helyesen prognosztizálta a kategóriát, addig a neurális hálózat metrikus értelemben is pontosabban megközelítette a ténylegesen mért MOR értéket. Az esettanulmány kapcsán arra a következtetésre juthatunk, hogy érdemes a fenti két módszert együttesen alkalmazni, és amennyiben mindkettő egyetért a látáskategória helyességét illetően, akkor a neurális hálózat kimeneteként előálló MOR érték elfogadásával pontosabb becslést adhatunk a látástávolság kvantitatív értékére vonatkozóan.

5.2.2. Nowcasting célú előrejelzések verifikációja


A nowcasting célú előrejelzésekhez nyolc évre (2006–2013) vonatkozó, órás felbontású adat állt rendelkezésünkre. Így több prediktor, illetve rejtett rétegbeli neuron felhasználására nyílt lehetőségünk anélkül, hogy túltanítottuk volna a hálózatot. Kihasználva a szabadsági fokok maximális számát, 22 bemenetet, és kétszer annyi, azaz 44 rejtett rétegbeli neuront alkalmaztunk. A *PP* megközelítéstől eltérően a kimeneti rétegben két neuront használtunk, amelyek az egy, illetve két órával későbbi látástávolságra adnak becslést.

Az előzőekhez hasonlóan a 2006–2010 ötéves adatsort tanulásra, míg a 2011–2012 független adatsort validálásra használtuk fel. A 2013-as adatsort további tesztelések céljára alkalmaztuk. A tanulási folyamathoz rendelkezésünkre álló nagyszámú (~15 ezer minta) közel 15-szöröse a szabad paraméterek számának, így nem volt szükség a hálózat megbízhatóságának igazolása céljából a rendelkezésre álló minták véletlenszerűen 70%–30%-os felosztására, ugyanis a validációs adatsor átlagos négyzetes hibája minden kísérlet során kisebbnek adódott a tanuló adatsor hibaértékéhez képest. A hálózat tehát a nagyszámú bemenetre nézve jól tudott általánosítani. Nem szabad megfeledkeznünk azonban arról, hogy a legtöbb látástávolság-érték 10000 méter, ugyanis a transzmisszió méter az ennél nagyobb látásértékeket külön nem számszerűsíti. Amennyiben minden olyan időjárási helyzetet figyelembe veszünk, amikor a transzmisszió méter 10000 méter látástávolságot regisztrált, felmerülhet az a probléma, hogy a hálózat a nagy többséggel rendelkező magas látásértékekre megbízható eredményeket ad, míg a kisebbekre kevésbé. Ennek elkerülése érdekében a *PP* megközelítésű neurális hálózathoz hasonlóan annyi véletlenszerűen válogatott 10000 méteres látástávolsággal rendelkező mintát használtunk fel a hálózat tanítására, hogy az 5000 méter alatti és 5000 méter feletti látástávolság esetek száma egyenlő legyen. A meteorológiai elemek és látásértékek adott időpontbeli méréseinek ismeretében az egy órával későbbi időpontra vonatkozó MOR becslések mért látástávolság-adatokkal történő összehasonlítását a **16.a, b ábrán** jelenítettük meg.


A két adatsor között a *PP* megközelítésű hálózathoz képest szorosabb illeszkedést figyelhetünk meg, köszönhetően a több rendelkezésre álló prediktornak, valamint a nagyszámú minta eredményeként a szabad paraméterek maximális számával történő vizsgálati lehetőségnek. Az egy és két órával későbbi időpontokra a neurális hálózattal nyert látástávolság-kimenetek jóságát a perzisztencia prognózissal (t időpontban mért

MOR érték) hasonlítottuk össze. Ennek oka, hogy a perzisztencia prognózis ultrarövidtávú előrejelzésekhez nagy megbízhatósággal alkalmazható. A neurális hálózatokkal pedig a nowcasting célú látástávolság prognózisok megbízhatóságának további növelését tűztük ki célul.

(a)



(b)




16. ábra: A neurális hálózat nowcasting célú felhasználása során 44 rejtett neuronnal, szigmoid transzferfüggvény alkalmazásával kapott látásértékek a $t + 1$ időpontra (a) a tanuló adatsor (2006–2010), valamint (b) a validációs adatsor (2011–2012) esetén.

A **8. táblázatban** az előbbi két ultrarövidtávú előrejelzési módszer során előálló, és a mért látásértékek közötti korrelációs együtthatókat, valamint *RMSE* hibaértékeket jelenítettük meg négy látástávolság-kategóriára vonatkozóan, a tanuló, a validációs és a teszt adatsor esetében is. A mérőszámok a perzisztencia prognózissal szemben többségében kedvezőbbnek adódtak, az r értéke egyedül a $t + 1$ időpontra a teszt adatsor esetén mutatott kisebb, ugyanakkor elhanyagolhatóan különböző értéket. Ennek ellenére ez utóbbi esetben az *RMSE* lényegesen kedvezőbbnek adódott.

8. táblázat: A nowcasting célú látástávolság-előrejelzésekre vonatkozóan a perzisztencia prognózis, valamint a neurális hálózatok kimeneteként előálló látásértékek mért MOR értékekkel való összehasonlító vizsgálata a $t + 1$ és $t + 2$ időpontokra, a tanuló, a validációs és a teszt adatsor esetén.

		$t + 1$		$t + 2$	
		Perzisztencia	Neurális hálózat	Perzisztencia	Neurális hálózat
Tanuló adatsor (2006–2010)	r	0,869	0,894	0,789	0,858
	$RMSE$	1707	1507	2209	1768
Validációs adatsor (2011–2012)	r	0,918	0,925	0,856	0,889
	$RMSE$	1396	1317	1396	1317
Teszt adatsor (2013)	r	0,896	0,893	0,822	0,838
	$RMSE$	1279	1128	1680	1540

A *PP* megközelítésű neurális hálózathoz hasonlóan elsőként az abszolút hibák relatív gyakoriságait vizsgáltuk hisztogramok segítségével. Elemzéseink során a tanuló adatsor esetén a $t + 1$ időpontra, négy látáskategóriára vonatkozó hibaintervallumok relatív gyakoriságát a **17.a–d ábrán** jelenítettük meg. A *PP* megközelítésű neurális hálózathoz hasonlóan mindegyik kimutatás rávilágít arra, hogy a legkisebb abszolút hibával terhelt esetek relatív gyakorisága a legnagyobb. A hisztogramok itt is tükrözik a neurális hálózat alkalmazásából adódó sajátosságokat, többek között a kódös helyzetek során a felülbecslések dominanciáját, valamint a jó látási viszonyok megbízható elkülönítéséről információt nyújtó, **17. d ábrán** megfigyelhető kiugró relatív gyakorisági értéket is.




17. ábra: A neurális hálózatok nowcasting célú felhasználása során 44 rejtett neuronnal, szigmoid transzferfüggvény alkalmazásával nyert látásértékekre kapott hibaintervallumok relatív gyakorisága a tanuló adatsorra vonatkozóan **(a)** $MOR \leq 1000$ m, **(b)** $1000 \text{ m} < MOR \leq 3000$ m, **(c)** $3000 \text{ m} < MOR \leq 5000$ m, **(d)** $5000 \text{ m} < MOR$ esetén.


(Azokat a szimmetrikus intervallumokat tüntettük fel, amelyekbe az esetek minimum 90%-a beletartozik.)

További vizsgálataink során számszerűsítettük, hogy a t időpontban megfigyelt MOR értékeket az előző ábrán megfigyelhető négy látástávolság-kategóriába sorolva mennyire megbízható becslések nyerhetők az egyes kategóriák esetén, a korrelációs együttható és *RMSE* tekintetében. A $t + 1$ időpontra vonatkozó, perzisztencia prognózissal való összehasonlítás eredményei a **18.a, b ábrán** kerültek feltüntetésre.

(a)



(b)




18. ábra: A $t + 1$ időpontra vonatkozó *nowcasting* célú látástávolság-előrejelzések esetén a perzisztencia prognózis, valamint a neurális hálózatok tanuló adatsorának kimeneteként előálló látásértékek és mért MOR értékek közötti (a) korrelációs együtthatók, illetve (b) *RMSE* értékek, a t időpontban megfigyelt látástávolság-kategóriák szerinti csoportosításban.

Figyelemre méltó, hogy mindkét mérőszám tekintetében a legkisebb látásértékekre adódtak a legkedvezőbb eredmények. Amikor a t időpontban 1000 méternél kisebb látástávolság volt megfigyelhető, akkor a $t + 1$ időpontra a mért és számított látásértékek közötti


korrelációs együttható értéke a perzisztencia prognózishoz képest szignifikánsan nagyobbak, 0,172 helyett 0,732-nek adódott.

A ködös helyzetek ultrarövid távú előrejelzésének egyik kiemelt operatív jelentőséggel bíró típusa, amikor a köd megszűnését kell előrejelezni, ezért megvizsgáltuk, hogy a módszer hogyan kezeli a köd disszipációját. A **19.a, b** ábrán a tanuló és validációs adatsor esetén egyaránt megfigyelhető, hogy nemcsak a kis látásértékekre, hanem a köd disszipációjának becslésére is megbízható becslések nyerhetők.

(a)



(b)



19. ábra: A nowcasting célú neurális hálózat felhasználása során a $t + 1$ időpontra nyert látásértékek mért adatokkal történő összehasonlítása **(a)** a tanuló adatsor (2006–2010), valamint **(b)** a validációs adatsor (2011–2012) esetén, amikor $MOR(t) \leq 1000$ m.


A 2006–2010 ötéves adatsor tekintetében, amennyiben a t időpontban 1000 méter alatti látástávolság volt megfigyelhető, akkor a korlátozott látási viszonyok az esetek 70%-ban

egy órával, míg az esetek 58%-ban két órával később is fennmaradtak, így ezekben a helyzetekben a perzisztencia prognózis alkalmazása akár helytállónak is tekinthető. Mindazonáltal, hogy a perzisztencia prognózissal a köd fennmaradása előrejelezhető, a módszer kevésbé alkalmazható a kis látásértékek tendenciájának, valamint a köd egy, vagy két órával későbbi lehetséges disszipálódásának becslésére. Az ábrákon pedig megfigyelhető, hogy egy órával későbbi időpontban a látástávolság akár a maximális, 10000 métert is elérheti. Ezeknek a helyzeteknek a többségét tehát sikerült megfogni, ezt a független mintákat tartalmazó validációs adatsor egyes esetei is alátámasztják. Összességében kijelenthetjük, hogy az összetett fizikai-statisztikai kapcsolatokat sikeresen feltérképező neurális hálózatok ultrarövidtávú döntéstámogató célprognózisok készítéséhez megbízható segítséget nyújtanak.

5.2.2.1. Esettanulmány – A 2013. november 1–2-i ködös helyzet elemzése


Az ultrarövidtávú előrejelzésekhez fejlesztett neurális hálózat esettanulmányaként a 2013-as tesztidőszakra vonatkozóan egy olyan időjárási helyzetet elemeztünk, amikor az éjszaka folyamán kialakult köd a reggeli órákban disszipálódott. Mivel a hálózat prediktorait képező mérések és megfigyelések órás felbontásban álltak rendelkezésünkre, ezért a látástávolság mért és prognosztizált értékeit is órás felbontásban hasonlítottuk össze, így a köd képződésének, valamint megszűnésének folyamatát is figyelemmel kísérhetjük.

2013. november 1–2-án hazánk egy ciklon előoldali áramlási rendszerében helyezkedett el (**20. ábra**), amelynek hatására délies áramlással enyhe, nedves légtömegek érkeztek térségünk fölé. 1-jén a nap folyamán többnyire erősen felhős, illetve borult volt az égbolt, alacsony felhőalappal rendelkező réteges felhőzet volt megfigyelhető. 2-án az éjszakai órákban a réteges felhőzet fokozatosan leereszkedett, mígnem 3 UTC-kor már a felszín közelébe érve 1000 méter körüli látástávolságot eredményezett. Hajnalban a hőmérséklet kismértékű csökkenésének hatására a relatív nedvesség elérte a 100%-os telítettségi értéket, ennek következtében a 13R pályaküszöbnél a látástávolság minimális értéke reggel 6 UTC-kor 812 méternek adódott. A nappali felmelegedésnek, de főként a szélsebesség növekedésének köszönhetően egy órával később már 2500 méter feletti látástávolság volt észlelhető, a délelőtt folyamán a látási viszonyok tovább javultak.



20. ábra: 2013. 11. 02. 00 UTC-re vonatkozó NCEP reanalízis
(Forrás: <http://www.wetterzentrale.de/topkarten/fsrea2eur.html>).

A 21. ábrán a meteorológiai elemek adott időpontbeli, valamint egy órával korábbi mért értékeinek ismeretében az egy órával későbbi időpontra nyert látástávolság-becsléseket jelenítettük meg. Az ábrán a neurális hálózat előrejelzései mellett feltüntetésre kerültek a mért MOR értékek, valamint a perzisztencia prognózis menete is.



21. ábra: A 2013. 11. 1–2-án a mért, valamint a neurális hálózattal és perzisztencia prognózissal előrejelzett látástávolság-értékek a $t+1$ időpontra vonatkozóan.

Az ábrán megfigyelhető, hogy mindhárom görbe hasonló menettel rendelkezik. Mind a neurális hálózat, mind pedig a perzisztencia prognózis kezdetben leköveti a látáscsökkenést, azonban az 1 és 3 UTC közötti nagymértékű látásromlást mindkét előrejelzés késleltetve adja. Ez a perzisztencia prognózis esetén érthető, hiszen alkalmazásával feltételezzük, hogy a következő egy órában a látástávolság nem változik az aktuális értékéhez képest. Ekkor azonban hátrányt jelent, hogy a látásértékek egy órán belül bekövetkező nagyobb változásai esetén nem jutunk pontos becsléshez. Jóllehet, a neurális hálózat és a perzisztencia prognózis kezdetben hasonló menetet mutatnak, a neurális hálózat kimenetei mégis a perzisztenciánál pontosabb, a mért MOR értékekhez közelebb eső becsléseket nyújtanak a 3 és 5 UTC közötti időszakra. Annak ellenére, hogy a hálózat a látási viszonyok hirtelen csökkenését némi késéssel prognosztizálta, a hajnalban kialakult köd 6 és 7 UTC között bekövetkező disszipálódását, így a látástávolság javulását megbízhatóan előrejelezte.

Az eredmények ismeretében elmondható, hogy a neurális hálózat a rendelkezésre álló ötéves tanuló adatsorból helyesen megtanulta a köd disszipálódásának lehetőségére utaló helyzeteket. Ezzel szemben kevésbé jól fogta meg azokat az eseteket, amikor a jó látási viszonyok hirtelen csökkenése következett be. Ennek oka, hogy a hálózat által a tanulási folyamat során látott minták túlnyomó többségében a jó látási viszonyok egy órával később is fennmaradtak. A fentiek alapján arra a következtetésre juthatunk, hogy a hálózat megbízhatóságának növelése érdekében célszerű olyan további mintákat bevonni a hálózat tanulási folyamatába, amelyek háttérében a látási viszonyok hirtelen csökkenése figyelhető meg. Nem szabad megfeledkeznünk azonban arról, hogy a módszer kizárólag mért adatokra támaszkodva, statisztikai alapon nyújt becslést a látástávolság ultrarövid távú időskálán várható jövőbeli értékére.

Összességében kijelenthetjük, hogy a módszerrel a látástávolság változásának tendenciájáról, valamint a köd disszipálódásának lehetőségéről megbízható információhoz jutottunk, azonban pontosabb becslésekhez elengedhetetlen a nowcasting és a *PP* megközelítésű neurális hálózat kimeneteinek együttes vizsgálata.

6. Összefoglalás

Munkánk során Budapest Liszt Ferenc Nemzetközi Repülőtérre a légiforgalmi irányításban használatos ultrarövidtávú, rövidtávú és középtávú, látástávolságra vonatkozó célprognózisok készítését elősegítő, döntéstámogató módszereket fejlesztettünk és teszteltünk. Elsőként egy olyan indexet adaptáltunk és alakítottunk át, amely lineáris kapcsolatban áll a látástávolsággal, s amely esetén az egyes látásértékek kategorizálása további fizikai elkülönítést jelentő döntési fa alkalmazásán alapszik (*látástávolság-előrejelző algoritmus*). Másrészt a hazai meteorológiai gyakorlatban kevésbé elterjedt módszert, a neurális hálózatokat alkalmaztuk a látástávolság becslésére. Ez utóbbi esetben lehetőségünk nyílt a meteorológiai elemek és a látástávolság közötti összetettebb, nemlineáris kapcsolatok feltérképezésére, figyelembe véve a látásértékek éven, illetve napon belüli változékonyságát is. Az első módszert *PP* megközelítésű, míg a másodikat *PP* megközelítésű, valamint *nowcasting* célú előrejelzésekhez egyaránt alkalmaztuk. Munkánk során a következő következtetésekre jutottunk:

- 1) A látástávolság-előrejelző algoritmusok esetén a Módosított *FOGSI* (*M.FOGSI*) indexek *szorosabb lineáris kapcsolatban* állnak a látástávolsággal, mint a *FOGSI* index.
- 2) *PP* megközelítésnél a *M.FOGSI* indexek és a kapcsolódó döntési fa felhasználásával az általunk tanulmányozott referencia- és tesztidőszakra a kategória előrejelzések verifikációja során alkalmazott mérőszámok tekintetében az eredeti módszerhez képest *többnyire kedvezőbb* értékek nyerhetők.
- 3) *PP* megközelítésnél a neurális hálózatokat alkalmazva *nagyobb korrelációs együttható* figyelhető meg a mért és becsült látásértékek között, valamint a diszkrét verifikációs mérőszámok többsége is *kedvezőbb értékeket* eredményez a látástávolság-előrejelző algoritmusokhoz képest. Ezáltal a módszer többnyire *megbízhatóbb* kategória elkülönítést tesz lehetővé.
- 4) A neurális hálózatokkal ultrarövidtávú előrejelzések esetén a *perzisztencia prognózisnál kedvezőbb* eredmények érhetők el, továbbá *megbízható becslések adhatók* a repülőtéri operatív előrejelzési gyakorlatban kiemelt fontosságú kis látásértékek, valamint a kód disszipációja esetén is.

Összességében elmondható, hogy neurális hálózatokkal a lineáris regressziós modellekhez képest szorosabb kapcsolat hozható létre a meteorológiai elemek és a látástávolság között, köszönhetően azok összetettségének és nemlineáris tulajdonságainak.

7. Jövőbeli tervek

Kutatásaink rávilágítottak arra, hogy a neurális hálózatok megbízhatóan alkalmazhatók a horizontális látástávolság becslésére. Ennek következtében felmerült az igény a módszer operatív gyakorlatba való lehetséges beépítésére, valamint néhány továbbfejlesztési lehetőség elvégzésére. Jövőbeli terveink között a következő kutatási irányok szerepelnek:

1. **Univerzalitás vizsgálat** – Mivel munkánk során Budapest Liszt Ferenc Nemzetközi Repülőtér meteorológiai méréseire és megfigyelésire támaszkodtunk, ezért a hálózattal a korlátozott látási viszonyokért felelős helyi időjárási sajátosságokat is megtanítottuk. Több repülőtérre vonatkozó mérések bevonásával, a földrajzi szélesség és hosszúság prediktorként való alkalmazásával azonban lehetővé válik, hogy nemcsak egy pontra vonatkozóan, hanem térben is megbízható látástávolság-becsléseket nyerjünk.
2. **Kategória előrejelzések pontosítása** – A hálózattal bináris kimeneteket is megtaníttathatunk aszerint, hogy adott időjárási helyzetben előfordult-e köd, vagy nem. Ehhez azonban a jelenleginél több ködös helyzet tanulási folyamatba történő bevonására van szükségünk. Célunk, hogy a hálózat jó általánosító képességének megalapozása érdekében reprezentatív mennyiségű, lehetőleg több ezer minta álljon rendelkezésünkre mindkét látástávolság-kategória (köd/nem köd) esetén egyaránt.
3. **Modell kimenet statisztika alkalmazása** – Kutatásaink során *PP* megközelítéssel éltünk, azaz egy dinamikai modell kimeneteiről feltételeztük, hogy azok tökéletesek. Nem szabad megfedkezünk arról, hogy a meteorológiai modellek hibával terheltek, tehát nem az általunk feltérképezett fizikai kapcsolatoknak megfelelő megbízhatóságú látástávolság kimenetet adják eredményül. Így felmerülhet az igény egy olyan hálózat elkészítésére, amely a modell kimeneteket, mint prediktorokat tanulja meg. Ekkor a hálózat képes általánosítani az adott modell szisztematikus hibáira nézve, azonban eltérő parametrizációk, modellbeállítások alkalmazása új tanulási folyamatot igényel.
4. **Keresztvalidációs módszerek alkalmazása** – A k -szoros keresztvalidáció azt jelenti, hogy a rendelkezésre álló adatsort k részre osztjuk fel, és az egyes részek közül felváltva mindig más $(k - 1)$ minta vesz részt a tanulásban, míg egy a validálási folyamatban. N darab tanítás és validálás után ezek átlagos eredményével jellemezzük a módszert.

8. Köszönetnyilvánítás

Ezúton szeretnék köszönetet mondani témavezetőmnek, *Kardos Péternek*, hogy szaktudásával, hasznos tanácsaival, lelkiismeretes munkájával segítette dolgozatom létrejöttét. Köszönettel tartozom azért is, hogy nyári gyakorlat keretein belül lehetőséget biztosított arra, hogy betekintést nyerhessek a repülőtéri operatív meteorológiai munkába.

Köszönetemet fejezem ki *dr. Wantuch Ferencnek*, hogy személyesen ismertette látástávolság-előrejelző algoritmusát, valamint *dr. Havasi Ágnesnek*, hogy segítséget nyújtott a neurális hálózatok elméleti hátterének áttekintésében.

Köszönetet mondok tanszéki konzulensemnek, *Soós dr. Dezső Zsuzsannának*, hogy szakított rám időt, és segített dolgozatom formai követelményeinek elsajátításában és véglegesítésében.

Köszönet illeti a *HungaroControl Zrt. Repülésmeteorológiai részlegének dolgozóit*, hogy hozzájárultak szakmai fejlődésemhez.

Végül, de nem utolsó sorban köszönetemet fejezem ki *Családom számára*, hogy támogatásukkal, biztatásukkal végigkísérték egyetemi tanulmányaimat.

9. Irodalomjegyzék

- Ali, A. F., Johari, D., Nik Ismail, N. F., Musirin, I., Hashim, N., 2011: Thunderstorm forecasting by using artificial neural network. *Power Engineering and Optimization Conference (PEOCO), 2011 5th International*.
- Baily, D., Thompson, D. M., 1990: Developing neural network applications. *AI Expert* 12, 33–41.
- Bottyán, Zs., 2008: Kísérlet egy repülőgép-katasztrófa meteorológiai viszonyainak rekonstrukciójára – a Malév HA-MOH repülőgépének balesete. *Repüléstudományi Közlemények* 20, 3. szám.
- Bremnes, J. B., Michaelides, S., 2005: Probabilistic forecasts of rare visibility events using neural networks. Short range forecasting methods of fog, visibility and low clouds. *Workshop Proceedings, Larnaca, Cyprus*.
- Chi, T-H., Wang, Y-M., 2011: Using Multiple Regression and Artificial Neural Network Approach for Modeling Airport Visibility. *2011 International Conference on Agricultural and Biosystems Engineering, Advances in Biomedical Engineering* 1–2, 428–431.
- Costa, S. B., Carvalho, F. O., Amorim, R. F. C., Campos, A. M. V., Ribeiro, J. C., Carvalho, V. N., dos Santos, D. M. B., 2006: Fog forecast for the international airport of Maceio, Brazil, using artificial neural networks. *Proc. Eighth Int. Conf. on Southern Hemisphere Meteorology and Oceanography, Foz do Iguçu, Brazil, INPE*, 1741–1750.
- Cséki, G., 2010: Inverziós helyzetek kialakulása a Kárpát-medencében. Diplomamunka. *Eötvös Loránd Tudományegyetem, Budapest* (témavezető: Dr. Bonta Imre). 92 p.
- Dean, A. R., Fiedler, B. H., 2001: Forecasting Warm-Season Burnoff of Low Clouds at the San Francisco International Airport Using Linear Regression and a Neural Network. *Journal of Applied Meteorology* 41, 629–639.
- Deák, B., 2010: A látástávolság és a köd rövidtávú előrejelzésének lehetőségei. Diplomamunka. *Eötvös Loránd Tudományegyetem, Budapest* (témavezetők: Dr. Wantuch Ferenc és Dr. Bottyán Zsolt). 69 p.
- Fabbian, D., De Dear, R., Lellyett, S., 2007: Application of Artificial Neural Network Forecasts to Predict Fog at Canberra International Airport. *Weather and Forecasting* 22, 372–381.
- Fodor, Z., 2006: Hosszantartó rendkívül hideg időszakok szinoptikus klimatológiai vizsgálata a Kárpát-medencében. Diplomamunka. *Eötvös Loránd Tudományegyetem, Budapest* (témavezető: Dr. Bonta Imre). 78 p.
- Hall, T., Brooks, H. E., Doswell, C. A. III., 1999: Precipitation Forecasting Using a Neural Network. *Weather and Forecasting* 14, 338–345.
- ICAO, Annex 3, 2013: International Civil Aviation Organization (ICAO). Meteorological Service for International Air Navigation. *Eighteenth Edition, July 2013*.
- Kaastra, I., Boyd, M., 1996: Designing a neural network for forecasting financial and economic time series. *Neurocomputing* 10, 215–236.
- Kandya, A., Nagendra, S. S. M., Tiwari, V. K., 2012: Forecasting the Tropospheric Ozone using Artificial Neural Network Modelling Approach: A Case Study of Megacity Madras, India. *Journal of Civil and Environmental Engineering* 11, 2012.
- Katz, J. O., 1992: Developing neural network forecasters for trading. *Technical Analysis of Stocks and Commodities* 8, 58–70.
- Khalili, N., Khodashenas, S. R., Davary, K., 2011: Monthly precipitation prediction by artificial neural networks (case study: Mashhad synoptic station). GRAIE, Lyon, France.

- Klimasauskas, C. C., 1993: Applying Neural Networks, in R. R. Trippi and E. Turban, editors, *Neural Networks in Finance and Investing: Using Artificial Intelligence to Improve Real World Performance*, (Probus, Chicago, 1993), 64–65.
- Kröse, B., van der Smagt, P., 1996: An introduction to neural network. *University of Amsterdam*. Eighth edition. 135 p.
- Makainé, Cs. M., 1962: Zsugorodási inverziók erősödő anticiklonban. *Időjárás* 66, 97–100.
- Makainé, Cs. M., Tóth, P., 1978: Szinoptikus meteorológia II.: *Tankönyvkiadó*, Budapest, 431 p.
- Marzban, C., Stumpf, G. J., 1996: A neural network for tornado prediction based on Doppler radar-derived attributes. *Journal of Applied Meteorology* 35, 617–626.
- McCann, D. W., 2005: NNICE – A neural network aircraft icing algorithm. *Environmental Modelling & Software* 20, 1335–1342.
- Messer, K., Kittler, J., 1998: Choosing an Optimal Neural Network Size to Aid a Search through a Large Image Database. *Proceedings of the 9th British machine vision conference (BMVC98)*, University of Southampton, UK, 235–244.
- Mészáros, E., 2005: Hogyan fedezték föl a levegőt? Adalékok a légkör kutatásának történetéhez. *Magyar Tudomány, Új Évfolyam* 50, 426–437.
- Naik, A. R., Pathan, S. K., 2013: Indian Monsoon Rainfall Classification And Prediction Using Robust Back Propagation Artificial Neural Network. *International Journal of Emerging Technology and Advanced Engineering* 3, 11, 2013, 99–101.
- Niestovaara, V., Jacobs, W., 2008: Activities and co-operation. In COST Action 722-Earth System and Environmental Management – Short range forecasting methods of fog, visibility and low clouds. ISBN 978-92-898-0038-9.
- Pasini, A., Pelino, V., Potestà, S., 2001: A neural network model for visibility nowcasting from surface observations: Results and sensitivity to physical input variables. *Journal of Geophysical Research* 106, 14 951–14 959.
- Priddy, K. L., Keller, P. E., 2005: Artificial Neural Networks: An Introduction. *SPIE Press*. ISBN 0-8194-5987-9. 165 p.
- Ruangjun, S., Exell, R. H. B., 2008: Regression Models for Forecasting Fog and Poor Visibility at Donmuang Airport in Winter. *Asian Journal on Energy and Environment* 9 (3–4), 215–230.
- Sándor, V., Wantuch, F., 2005: Repülésmeteorológia. Tankönyv pilóták és leendő pilóták számára. *Folium Nyomda*. ISBN 963-7702-91-1. Második javított kiadás. 272 p.
- Svozil, D., Kvasnička, V., Pospíchal, J., 1997: Introduction to multi-layer feed-forward neural networks. *Chemometrics and Intelligent Laboratory Systems* 39, 43–62.
- Takács, P., 2010: Budapest-Ferihegy Nemzetközi repülőtér szélviszonyainak vizsgálata és szélelőrejelzési módszerek. Diplomamunka. *Eötvös Loránd Tudományegyetem, Budapest* (témavezető: Kardos Péter). 92 p.
- Varga-Haszonits, Z., Varga, Z., Lantos, Zs., Vámos, O., Schmidt, R., 2000: Magyarország éghajlati erőforrásainak agroklimatológiai elemzése. *Lóripint*, Mosonmagyaróvár. 223 p.
- Vislocky, R. L., Fritsch, J. M., 1997: An automated, observations-based system for short-term prediction of ceiling and visibility. *Weather And Forecasting* 12, 31–43.
- Wantuch, F., 2001: Visibility and fog forecasting based on decision tree method. *Időjárás* 105, 29–38.

Wantuch, F., Bottyán, Zs., Deák, B., 2010: A látótávolság és a köd rövidtávú előrejelzésének lehetőségei. Repüléstudományi Konferencia, Konferencia Kiadvány, Szolnok, 2010/2.

Wilks, D. S., 2011: Statistical Methods in the Atmospheric Sciences. Academic Press. ISBN 978-0-12-385022-5. Third Edition. 676 p.

WMO (World Meteorological Organisation), 2000: Guidelines on performance assessment of public Weather Services, WMO, WMO/TD No. 1023.

Internetes források:

[1] [Google Earth](#)

[2] <http://www.mkirste.de/series/industry-traffic/de/#id326>


[3] <http://www.wetterzentrale.de/topkarten/fsrea2eur.html>

[4] <http://weather.uwyo.edu/upperair/sounding.html>

10. Függelék

1. számú melléklet

Döntési fa a *FOGSI* index használatához




Forrás: Wantuch (2001); Deák (2010)

Megjegyzés: A módszer eltérő küszöbszámokat alkalmaz hideg légréteg, illetve normál rétegződés esetén.

2. számú melléklet

Döntési fa az *M.FOGSI* indexek használatához



* Feltéve, ha nem teljesül, hogy *M.FOGSI*₃ ≥ 20 és $W_{10m} \geq 3\text{ ms}^{-1}$

** Feltéve, ha nem teljesül, hogy *M.FOGSI*₃ < 20 és $W_{10m} < 3\text{ ms}^{-1}$

Megjegyzések: 1. a kék nyilak az utasítások igaz, míg a piros nyilak azok hamis ágát jelentik.

2. a sárga ellipszisekben a kék feliratok jelentik az adott utasításhoz tartozó igaz, a pirosak pedig a hamis elágazáshoz tartozó kategóriát.