

Fricke Cathy, Kardos Péter

NEURÁLIS HÁLÓZATOK ALKALMAZÁSA A LÁTÁSTÁVOLSÁG ULTRARÖVIDTÁVÚ ELŐREJELZÉSÉBEN

A látástávolság, mint repülésmeteorológiai szempontból kiemelkedő fontossággal bíró időjárási paraméter előrejelzése máig kihívást jelent az előrejelzők számára. A feladat megoldásához a tapasztalatok szerint a statisztikai alapú modellek nyújtanak leginkább segítséget. A neurális hálózatok (Neural Nets) is egy ilyen nemlineáris statisztikai modell, amely a látástávolságot befolyásoló meteorológiai paraméterek és a látástávolság között egy múltbeli (tanuló) adatsor alapján feltárja a legalapvetőbb összefüggéseket és ez alapján becsüli a látástávolság várható értékét. Vizsgálatink során különböző szerkezetű és formában eltérő adatokon tanuló hálózatokat teszteltünk, amelynek eredményeként egyes hálózatok előrejelzései meghaladták az ultrarövid távon kifejezetten jól teljesítő perzisztencia prognózist, így többletinformációval szolgált a látástávolság előrejelzése során.

Kulcsszavak: neurális hálózatok, ultrarövid távú előrejelzés, látástávolság, repülésmeteorológia

LÁTÁSTÁVOLSÁG ELŐREJELZÉSE

Az elmúlt évtizedekben több ezer köddel kapcsolatos publikáció született, amely azt mutatja, hogy fontos kutatási terület, és sok munkát fektettek a jelenség megismerésére. Ennek ellenére a látástávolság ultrarövid távú előrejelzésének (nowcasting) pontosítása máig további kutatásokra szorul, mivel e repülésmeteorológia szempontjából releváns időjárási paramétert olyan térben és időben változó folyamatok kölcsönhatásai határozzák meg, amelyekre hatással van a mikrofizika, a sugárzás, a turbulencia és a felszíni sajátosságok, és ezek explicit ismerete hiányos [1].

A látástávolság azon időjárási változók közé tartozik, amely nem áll elő numerikus előrejelzési modellek output-jaiként. Más nedvességhez kapcsolódó paraméterhez hasonlóan a nagyskálájú numerikus modellek a felszínközeli magas páratartalom kialakulásának komplexebb folyamatait nem képesek elegendően nagy pontossággal rekonstruálni. Finomabb felbontású 3D-s modellek segítségével javítható az előrejelzés, de ezek operatív gyakorlatban történő alkalmazása nem terjedt el a magas számítási költség miatt. Az 1D-s modellek költségkímélőbbek, de alkalmazhatóságuk korlátozott az összetett felszínborítottságú területeken.

A repülésmeteorológiai gyakorlatban a látástávolság ultrarövidtávú előrejelzése a következő két órára terjedő időszakokra történik, amelyre numerikus előrejelzést a nagy számítási igény és a fenti okok miatt sem szoktak a gyakorlatban készíteni. A látástávolság rövidtávú előrejelzésében ezért a statisztikai módszerek terjedtek el és több hazai eredmény is bizonyítja, hogy alkalmasak a gyakorlatba történő adaptálásra [2]. Az analógiás módszerrel történő előrejelzés is ilyen statisztikai alapon működő modell, amely során fuzzy logikán alapuló hasonlósági metrika segítségével megkeresik a jelen időjárási állapotot jellemző paraméterekhez leginkább hasonlót a rendelkezésre álló adatbázisban [3]. A meteorológiai helyzet szempontjából kiemelkedően fontos paraméterek nagyobb súlyokat kapnak, aminek következtében növelhető a látástávolság előrejelzésének pontossága. Mivel a prognózis múltbeli adatok alapján készül, ezért minél nagyobb a különbség a paraméterek között, annál nagyobb az előrejelzés bizonytalansága. Wantuch [4] a látástávolság és az időjárási változók

közötti kapcsolat feltárására a Perfekt Prognosztikán (PP) alapuló döntési fa módszerét alkalmazta, amelyet a látástávolság operatív előrejelzési gyakorlatába is adaptált. A döntési fát egy elemzések eredményeként kapott indexen (FOGSI) alkalmazta, amely a látástávolság és modell kimeneti paraméterek között teremt fizikai kapcsolatot. A FOGSI és a látástávolság között lineáris regressziós kapcsolat létesíthető, amelyet két éves adatbázis alapján határoztak meg. Az indexet Nagy Roland [5] diplomamunkája során tovább finomította (módosított FOGSI), ennek eredményeként a látástávolsággal szorosabb lineáris kapcsolat volt kimutatható. Nagy Roland emellett a látástávolság neurális hálózatokkal történő előrejelzésével is foglalkozott és megmutatta, hogy a neurális hálózatok által készített ultrarövidtávú előrejelzésekre vonatkozóan a perzisztencia prognózisnál kedvezőbb eredmények születtek. Hazánkban emellett még jelenleg is folyik neurális hálózatokkal kapcsolatos kutatás, amely a repülésmeteorológiában hatékony eljárások kidolgozását célozza meg [6].

NEURÁLIS HÁLÓZATOK (NN)

A neurális hálózatok (Artificial Neural Network) egy olyan komplexebb összefüggések feltárására tervezett nemlineáris statisztikai modell, amelynek alkalmazása széles körben elterjedt a természettudományokban, így az időjárási paraméterek előrejelzésében is jól alkalmazható. Az NN reprezentatív szituációk sorozatán keresztül képes kapcsolatot létesíteni a független változók (időjárási paraméterek) és a függő változók (látástávolság) között. Információ a prediktorok (függő változók) és a prediktandusok (független változó) közötti kapcsolatáról az egymással kölcsönható neuronok hálójában lelhető fel. A neurális hálózatoknak többféle típusa létezik, a meteorológiában a leggyakrabban alkalmazott típus az előrecsatolt többrétegű perceptron, ezért mi is ezzel dolgoztunk. A többrétegű perceptron neuronokból felépített bemeneti és kimeneti rétegekből áll, amelyek között egy vagy több ún. rejtett réteg helyezkedik el. A hálózatot alkotó neuronok súlyokon és transzferfüggvényeken keresztül kapcsolódnak egymáshoz. A súlyok egy időszakra vonatkozó adatbázis tanulása során folyamatosan illeszkednek annak érdekében, hogy a hálózat minél jobb kapcsolatot teremtsen a bemeneti és az kimeneti adatok között. A neurális hálózatokat az teszi izgalmassá, hogy múltbeli helyzetekből tanul meg alapvető összefüggéseket és nem előre meghatározott szabályok alapján hajtja végre a műveletet, mint például egy numerikus modell.

A tanulás folyamata az elérni kívánt érték és a becsült érték közötti négyzetes hibaminimum-kereső algoritmuson alapul, amely arra törekszik, hogy az iterációs lépések során megtalálja a súlyok azon kombinációját, amelyekhez a legkisebb négyzetes hibaérték tartozik.

A hálózat topológiájának tervezése során figyelembe kell venni, hogy a nem megfelelően konstruált hálózat hajlamos a túlilleszkedésre (over-fit), ami alatt azt értjük, hogy az NN a tanuló adatbázisra kellően illeszkedik, viszont korábban nem látott adatokkal téves eredményeket generál. Az over-fit többnyire akkor következhet be, ha a hálózatot a tanuló adatsor méretéhez képest túl sok neuron alkotja, illetve ha a tanuló adatsor túl rövid. A neurális hálózat eredményei akkor tekinthetőek megbízhatónak, ha új adatokon végezve a számítást jól tud általánosítani. Kevés neuronból álló hálózat esetén túl kevés a struktúra szabadsági foka ahhoz, hogy felismerje az alapvető összefüggéseket, ennek következtében előfordulhat, hogy nem csökken le a négyzetes hiba értéke. Az NN topológiájának szempontjából fontos tényező még a rejtett rétegek száma: minél összetettebb egy folyamat, annál több rejtett réteg beillesztése szükséges [7]. A rejtett ré-

tegbeli neuronok számáról több álláspont van jelen a szakirodalomban. Kaastra és Boyd egy háromrétegű neurális hálózat esetén a bemeneti és a kimeneti neuronszámok szorzatának gyökét ajánlja a rejtett réteg neuronszámának megválasztására [8]. Katz állítása szerint a rejtett rétegbeli neuronok száma a bemeneti neuronok számának a fele és háromnegyede között változtatható [8]. A neurális hálózatokkal kapcsolatos kutatásokban a rejtett rétegek neuronszáma nem haladta meg a bemeneti adatok kétszeresét, így vizsgálataink során mi sem alkalmaztunk ennél többet.

Kezdetben a neurális hálózatok tanulási folyamatához Multiple Back-Propagation (with CUDA) version 2.2.4) szoftvert használtuk fel. A kutatás során Fast Artificial Neural Network (FANN) – PHP programkönyvtár használatára tértünk át, mivel az számos előnnyel bírt a neurális hálózatok tanítása szempontjából. A FANN olyan C programnyelven írt függvénykönyvtár, amely a C, C++, Python, PHP, Delphi nyelvekkel is egyaránt használható. A FANN függvénykönyvtárban belül öt-féle tanulási algoritmus és tizennyolcféle aktivációs függvény közül választhatunk, ezek közül az alapvetőbbeket (Gauss, szigmoid) alkalmaztuk a tanítás során. Továbbá ötféle tanulási algoritmus-sal tanulhat a hálózat a FANN keretein belül: soros (incremental), kötegelt (batch), RPOP, Quick-RPOP és a SARPOP. A soros és a kötegelt algoritmus közötti különbség, hogy a súlyok frissítése különböző szakaszon történik. Ennek megértéséhez először definiálnunk kell az epoch jelentését: a tanító halmaz egyszeri végigfutása a hálózaton. A soros algoritmussal történő tanítás során a súlyok módosítása minden egyes tanító pont után megtörténik, míg a kötegelt tanulás során ez csak egy-egy teljes epoch után történik meg. Az RPOP, QuickRPOP és SARPOP továbbfejlesztett algoritmusok, amelyekhez további tanulás javítását szolgáló paraméterek is tartoznak.

A FANN további előnye, hogy programnyelv felépítése lévén egy időben különböző felépítésű, hálózatok eltérő struktúrájú adatokkal történő tanítására is alkalmas, így lehetőség van a kiterjedtebb és hatékonyabb elemzésre is.

CÉLKITŰZÉS ÉS FELHASZNÁLT ADATOK

A kutatás során az volt a célkitűzésünk, hogy a neurális hálózatokat felhasználva készítsünk olyan ultrarövid távú, két órás látástávolság-előrejelzési módszereket, amelyek az operatív előrejelzői gyakorlatba is könnyen integrálhatók lesznek. Vizsgálataink során a Liszt Ferenc Nemzetközi Repülőtéren telepített ALMOS mérőrendszer 13R, 31L, 13L és 31R pályaküszöbkhöz tartozó transzmisszió méréseit használtuk fel. A műszerek az egyes pályák melletti a futópályamenti látótávolságot jól jellemző mért optikai mélységet (MOR) mérik. A mérési adatok 2005. januártól 2016 decemberéig terjedő időszakokra álltak rendelkezésre, ebből jelöltük ki a tanuló, teszt, illetve referencia adatsort. Annak érdekében, hogy az NN reprezentatív adatokkal végezze a tanulást, a tanuló adatsor leválasztása során a feltétel az volt, hogy a 13R vagy a 31R és a 31L mérési ponton mért MOR egyike 3000 m alatt legyen. Tehát a futópályák egyik pontjában 3000 méter feletti MOR is előfordulhatott, ezáltal nem csak az alacsony látástávolsággal jellemezhető ködös napok kerültek az adatbázisba.

A korábban említett analógiás módszer példáján hipotézisünk az volt, hogy a hálózat tanulását segítheti, ha az egyes időjárási paraméter aktuális időpontra vonatkozó értéke mellett a korábbi mérések is a tanuló adatbázis részét képezik. A múltbeli időlépéseket az előrejelzési időlépcsőknek megfelelően határoztuk meg, azaz a 30, 60, 90 és 120 perccel korábbi mérések is a

bemeneti adatok elemei. A neurális hálózatok bemeneti adataiként a látástávolság alakulását erősen befolyásoló paramétereket választottuk ki, amelyek a következők: év napja, óra, hőmérséklet, harmatpont, szélereősség, szélirány és MOR.

EREDMÉNYEK

Neurális hálózatok olyan variációit készítettük el, amelyekhez különböző tanulási algoritmusok, aktivációs függvények tartoznak és az egyes hálózatok rejtett rétegeinek számai és a rejtett rétegbeli neuronok számai is elérőek. Emellett minden hálózatnak elkészítettük azt a változatát, amely nem csak a sorban következő rétegbeli neuronokhoz kapcsolódik, hanem azt kihagyva a következő rétegbeli neuronnal is kapcsolatot létesít. A továbbiakban látni fogjuk, hogy ugyanazon tanuló adatsor több formájával is tanultak a hálózatok, amelyek szintén jelentősen befolyásolták a neurális hálózat teljesítményét, működését.

Vizsgálataink során a tanuló adatsorban az outputot többféle módon adtuk meg az NN számára, így tesztelni tudtuk, hogyan teljesít a hálózat ugyanazon adatok módosított változataival. Meg kell említenünk, hogy a tanuló adatsorok változtatása során a bemeneti adatok formája nem változott. Elsőként maga a látástávolság négy időlépcsőben mért méterben kifejezett értékeiből álló outputok-kal tanultak a különböző hálózatok, amelyek várt kimeneteit is a látástávolság konkrét, méterben kifejezett számértékei adják. Ezen hálózatokat (továbbiakban decimális hálók) prognosztikai minőségét úgy ellenőriztük, hogy a teljes 2016-os év referencia adatbázisával hajtottuk meg. Ehhez a látástávolság verifikációja során széles körben alkalmazott Heidke Skill Score (HSS) verifikációs indexet használtuk fel. Az index kiszámításához (1) az alábbi 2×2-es kontingencia táblázatot kell felhasználnunk.


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

1. táblázat Az előrejelzés verifikálásához szükséges 2×2-es kontingencia táblázat

$$HSS = \frac{2(ad-bc)}{(a+c)(c+d)+(a+b)(b+d)} \quad (1)$$

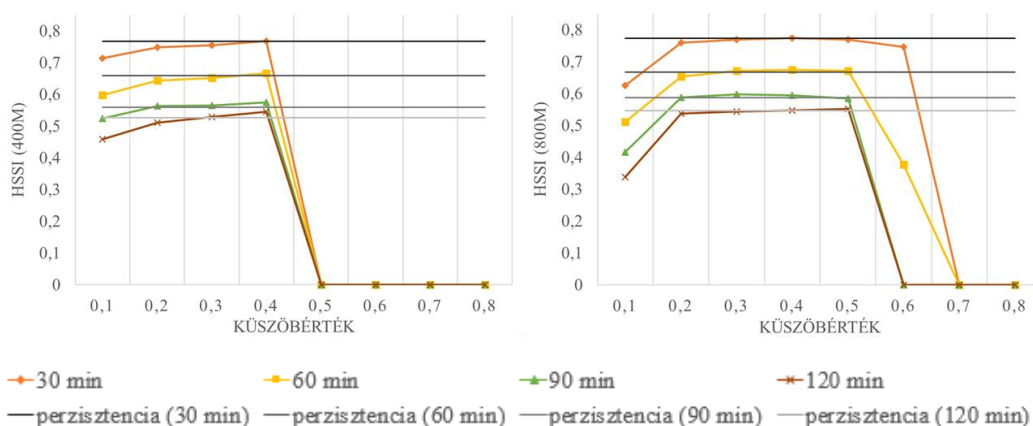
A decimális hálózatok verifikációja során a táblázat kitöltéséhez az előrejelzett és a mért MOR értékeit hat különböző intervallumra osztottuk (0–400 m, 400–600 m, 600–1000 m, 1000–1500 m, 1500–10 000 m) és a HSSI értékét az egyes csoportokra számítottuk ki. A HSSI értéke mínusz végtelentől egyig terjed és az előrejelzés akkor ideális, ha az index értéke 1. Az ultrarövid távú előrejelzésnek akkor van információ értéke, ha jobb prognózist képes adni a perzisztencia prognózisnál, amely ilyen időtávon kifejezetten jól teljesít. A repülésmeteorológia szempontjából viszont fontos tudni, hogy mikor várható változás a látástávolságot illetően, a neurális hálózatokkal éppen ezen változások előrejelzésére törekszünk. A decimális hálózatok verifikációját a teljes 2016-os év adatbázisával végeztük el. A hálózatok becsléseire számított HSS indexek a 1500 m feletti kategóriában haladták meg a perzisztencia prognózis HSS indexeit, azaz a decimális hálózatok képesek volt arra, hogy az esetek nagy részében előrejelezze, hogy a MOR 1500 m alatt vagy felett alakul a következő két óra egyes időlépcsőiben.

Az 1. ábrán példának egy olyan decimális hálózat előrejelzése látható egy kiválasztott napra (2016. 01. 28.) alkalmazva, amelyben két darab tizennégy neuronból álló rejtett réteg található a bemeneti és a kimeneti réteg között. A hálózat Gauss aktivációs függvényt alkalmazott a rétegek között és RPOP algoritmussal tanult. Az ábrán az egyes időpontokban mért MOR értékek és az időponthoz tartozó NN által négy időlépcsőre előrejelzett értékei vannak bemutatva. Az ábra alapján megállapítható, hogy a neurális hálózat az esetek jelentős részében képes volt a MOR változás irányáról információt szolgáltatni.



1. ábra A mért látástávolság (piros) és a kiválasztott decimális hálózat 30, 60, 90 és 120 percre előrejelzett értékei 2016. 01. 28-ára vonatkozóan

A további vizsgálataink során ugyanezen tanuló adatsoron egy átalakítást végeztünk el: az egyes időlépcsőkben mért látástávolságokhoz kategóriaváltozókat rendeltünk, annak megfelelően, hogy 400 m, illetve 800 m fölött vagy alatt alakult a látástávolság értéke. A hozzárendelés a következő módon történt: ha 400 m vagy 800 m alatti a MOR értéke, akkor 1-et rendeltünk hozzá, ellenkező esetben 0-t. Ebben az esetben a kimeneti neuronok száma nyolc darab volt, mivel mind a négy időlépcsőhöz tartozó MOR értéket a két feltétel szerint egyenként vizsgálta.

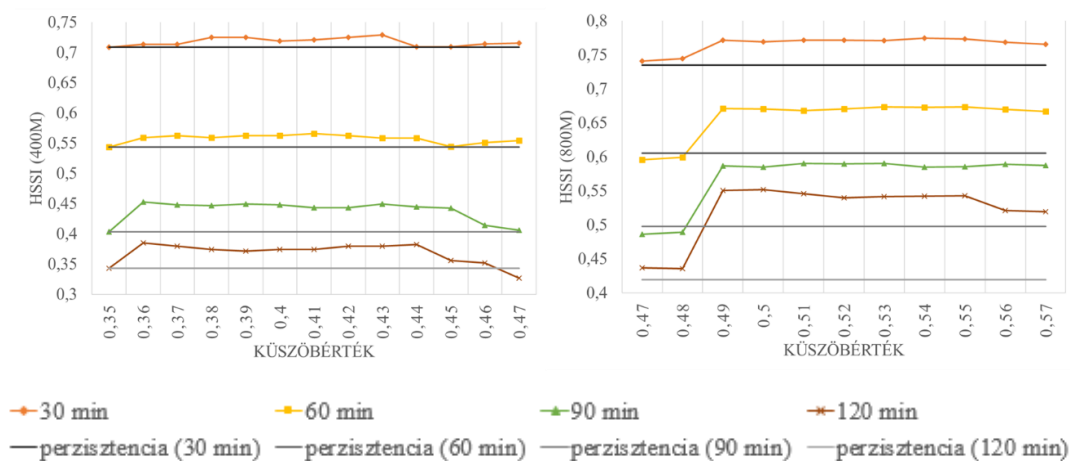


2. ábra A kiválasztott kategóriás hálózat 400 és 800 m-re vonatkozó HSS indexei a 30, 60, 90 és 120 perces időlépcsőre vonatkozóan

A teljes 2016-os évre egy 27 bemeneti, 14 rejtett és 8 kimeneti neuronból álló kategóriás hálózaton végeztük el a verifikációt. E hálózat szigmoid aktivációs függvényt és batch algoritmust használt a tanulás során. A hálózat előrejelzési minősége attól függően is változott, hogy a tesztelése során milyen küszöbértékeket határoztunk meg a 0 és az 1 kimenet szétválasztásához. A 2. ábrán a perzisztencia prognózisra és a különböző küszöbindexekkel ellátott NN becsléseire

vonatkozó HSS indexek láthatók 400 m, illetve 800 m-es csoportosítás szerint. Megállapíthatjuk, hogy a küszöbérték megválasztása előteljesen befolyásolja a neurális hálózat működését, így képes javítani a becslés pontosságát.

Annak érdekében, hogy ezt a hatást jobban szemléltessük, külön ábráztuk a hálózat azon becsléseinek HSS indexeit, amelyek meghaladták a perzisztencia prognózis HSS indexeit az egyes időlépcsőkben. Látható, hogy több maximum is tartozik a küszöbértékek sorozatához és szembe-tűnő az is, hogy az NN HSS indexei minden időlépcsőben jóval meghaladták a perzisztencia HSSI értékeit. Megállapítható még, hogy hálózattól függően a 800 méterre vonatkozó HSS indexek magasabb értékei a 400 méteres HSS indexeitől eltérő tartományban jelentkezhetnek.

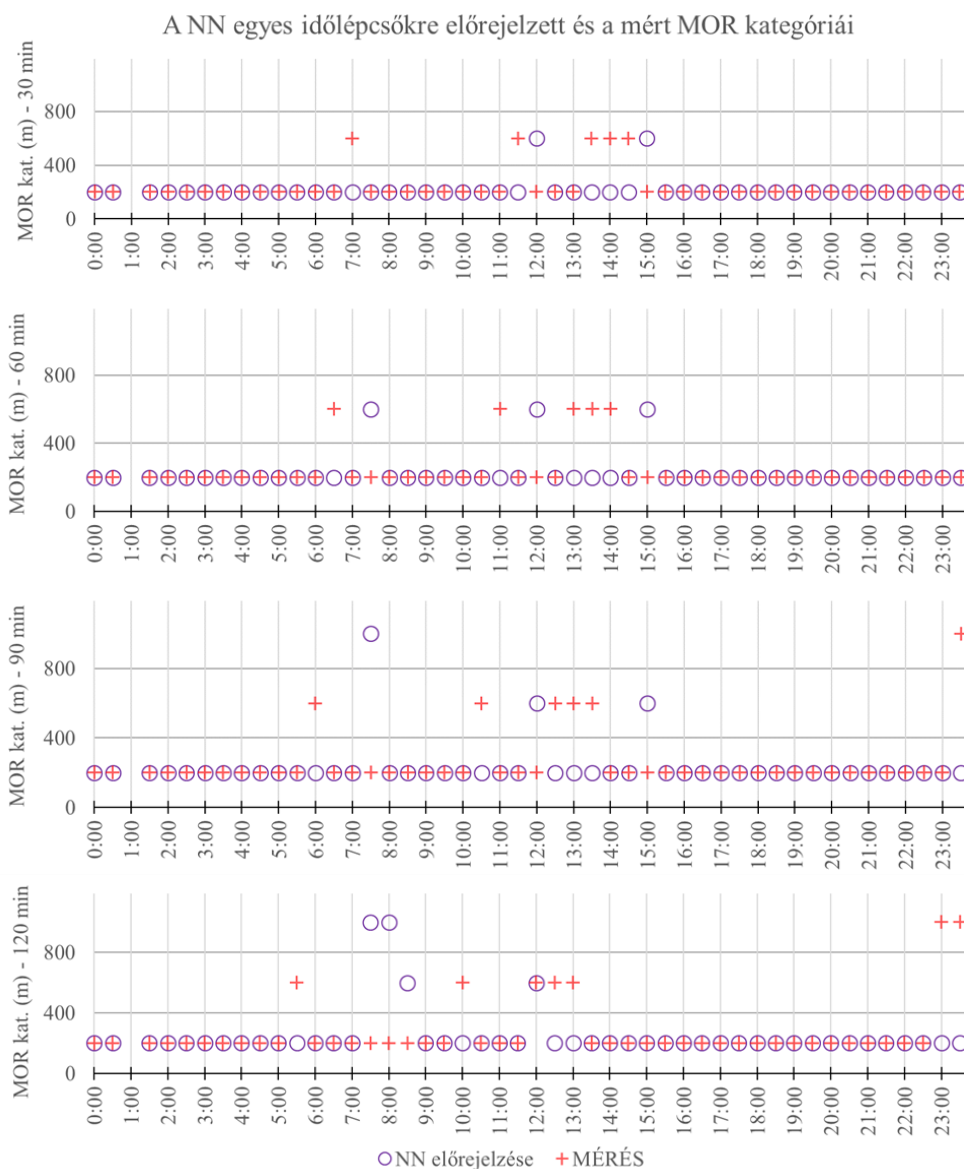


3. ábra A kiválasztott kategóriás hálózat 400 és 800 m-re vonatkozó HSS indexei a perzisztencia prognózist meghaladó tartományban a 30, 60, 90 és 120 perces időlépcsőre vonatkozóan

A továbbiakban bemutatunk egy jól teljesítő kategóriás hálózatot egy kiválasztott téli, ködös napon (2016. 01. 27) alkalmazva. A hálózatban a bemeneti és a kimeneti rétegeket két – egy 28 és egy 14 neuronból álló – rejtett réteg köti össze. A tanulás során RPOP algoritmust és Gauss aktivációs függvényt használt. A 400 méterhez tartozó küszöbindexet 0.34-nek, a 800 méterhez tartozó küszöbindexet 0.41-nek választottuk meg, mivel a hálózat a teljes 2016-os évre vonatkozóan ezekre az értékekre produkált jó eredményeket. Ez azt mutatja, hogy minden hálózat másképpen függ a küszöbindexek értékétől. Míg a 2-es, 3-as ábrán bemutatott hálózat maximális 400 méterre, illetve 800 méterre vonatkozó HSS értékei rendre 0,43 és 0,49 küszöbértékek körül alakultak, e hálózat más küszöbértékeknél teljesít jól. A 4. ábra az NN által az egyes időlépcsőkre előrejelzett és a mért MOR kategóriáit mutatja be 2016. 01. 27-ére vonatkozóan. A MOR előrejelzése egy ilyen változóan ködös napon kihívást jelent az előrejelzők számára. Az ábra alapján láthatjuk, hogy az NN több esetben és képes volt MOR változásának előrejelzésére, így információ-többlettel szolgál a perzisztencia prognózissal összehasonlítva. A 30 perces időlépcsőt tekintve a 47-ből 40-szer, a 60 perces időlépcsőt tekintve 39-szer, a 90 perces és 120 perces időlépcsőt tekintve pedig 38 esetben volt sikeres a hálózat becslése, így ebben az esetben nőtt a bizonytalanság mértéke az időlépcső növekedésével.

Az eredmények alapján levonhatjuk azt a következtetést, hogy az NN számára sokkal tanulhatóbb formának bizonyult a kategóriás besorolást tartalmazó adatbázis és mivel előrejelzései több esetben információ-többletet hordoznak a perzisztencia prognózishoz képest, érdemes ebben az irányban tovább vizsgálni. Ha sikerül tovább pontosítani a becsléseket, akkor akár a

repülésmeteorológiában – ahol a MOR jövőbeli változásának iránya is fontos információ – operatív gyakorlatban is alkalmazhatóvá válik.



4. ábra A kiválasztott kategóriás hálózat egyes időlépcsőkre előrejelzett értékei és a mért látástávolság (m) 2016. 01. 27-én

FELHASZNÁLT IRODALOM

- [1] I. Gulpepe, R. Tardif, S. C. Michaelides, J. Cermak, A. Bott, J. Bendix, M. D. Müller, M. Pagowski, B. Hansen, G. Ellrod, W. Jacobs, G. Toth, S. G. Cober, 2007: Fog Research: A Review of Past Achievements and Future Perspectives. Pure and Applied Geophysics, 164/6, pp. 1121–1159.
- [2] Bottyán Zs., Deák B., Wantuch F., 2010.: A látástávolság és a köd rövid távú előrejelzésének lehetőségei. Repüléstudományi Konferencia 2010 Szolnok, 2010. április 16. Repüléstudományi közlemények 2010/2 különszám, Szolnok, 2010 április 16.
- [3] Tuba Z., Bottyán Zs., 2015.: Analógiás elven alapuló repülésmeteorológiai előrejelzések és a makroszinoptikus időjárás-situációk kapcsolatának vizsgálata. Repüléstudományi Közlemények, Szolnok, 2015/2, pp. 162–168.
- [4] Wantuch F., 2001: Visibility and fog forecasting based on decision tree method. Időjárás 105, 29-38.
- [5] Nagy R., 2014: Új módszerek vizsgálata a légitforgalmi irányításban használatos, látástávolságra vonatkozó döntéstámogató célprognózisok készítésében Budapest Liszt Ferenc Nemzetközi Repülőtér. Diplomamunka. Eötvös Loránd Tudományegyetem, Budapest (témavezető: Kardos Péter). 69 p.

- [6] Hadobács K., Bottyán Zs., 2015: Neurális hálózatok és alkalmazásuk a repülésmeteorológiában. Repüléstudományi Közlemények, Szolnok, 2015/2, pp. 36–48.
- [7] Jain A. K., Mao J., Mohiuddin K. M., 1996: Artificial neural networks – a tutorial. Computer, 31–44.
- [8] Kaastra I., Boyd M., 1996: Designing a neural network for forecasting financial and economic time series. Neurocomputing 10, 215–236.
- [9] Katz J. O., 1992: Developing neural network forecasters for trading. Technical Analysis of Stocks and Commodities 8, 58–70.

APPLYING NEURAL NETWORKS IN ULTRA-SHORT TERM FORECASTING OF VISIBILITY

Visibility is a relevant meteorological variable in aviation meteorology and until nowadays forecasting of this parameter has been a complicated task. Statistical models are the most applied methods for forecasters to solve this problem. Neural networks are also nonlinear statistical models, which can produce connections between the determined meteorological variables and the visibility by learning data of measures of a previous term. After the learning process neural nets are able to estimate the visibility in the short term future. In this research numerous neural networks were tested with various topology and different form of learning data base. As a result some of these forecasts of neurals networks produced better estimates, than persistent prognosis, which are known for their relatively good evaluation in ultra-short term.

Keywords: neural nets, ultra-short term forecasting, visibility, aviation meteorology

Fricke Cathy (MSc) hallgató Eötvös Loránd Tudományegyetem Természettudományi Kar Meteorológiai Tanszék frcsaat@gmail.com orcid.org/0000-0001-5737-4618	Fricke Cathy (MSc) Student Eötvös Lorand University Faculty of Science Department of Meteorology frcsaat@gmail.com orcid.org/0000-0001-5737-4618
Kardos Péter részlegvezető Hungarocontrol Magyar Légiforgalmi Szolgálat Zrt. Repülőtéri Meteorológiai Részleg Peter.Kardos@hungarocontrol.hu orcid.org/0000-0001-8857-4102	Kardos Péter head of unit Hungarocontrol Hungarian Air Navigation Services Ltd. Aerodrome Meteorological Unit Peter.Kardos@hungarocontrol.hu orcid.org/0000-0001-8857-4102

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

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



http://www.repulestudomany.hu/folyoirat/2017_2/2017-2-09-0392-Fricke_Cathy-Kardos_Peter.pdf