



Hadobács Katalin¹ – Bottyán Zsolt²

NEURÁLIS HÁLÓZATOK ÉS ALKALMAZÁSUK A REPÜLÉSMETEOROLÓGIÁBAN³

Hihetetlen módon gyorsuló világunkban a repülés területén is megnövekedett a fejlődés irama. Ahogy civil vonatkozásban, úgy katonai szempontból is megfigyelhető, hogy a szárazföldi feladatok egyre inkább áthelyeződnek a levegőbe. Ehhez nagyban hozzájárultak az utóbbi évtizedekben robbanásszerűen elterjedő pilóta nélküli repülőgépek is. Az egyes légi műveletek sikeressége, hatékonysága nagymértékben függ az időjárástól, így a hajózó személyzet felől egyre több és speciálisabb igény érkezik a meteorológus szakemberek felé. Jelenleg azonban a prognózisok elkészítéséhez kizárólag a numerikus előrejelző modellek eredményeit van lehetőség felhasználni, amelyek adott időtartományon kívül nem állnak rendelkezésre, valamint e modellek a kis skálájú folyamatokat is gyakran sikertelenül jelzik előre. Ezért elengedhetetlenné vált az időjárás előrejelzés területén új eljárások, eszközök kidolgozása illetve adaptálása. Munkánkban egy hazánk repülésmeteorológiai gyakorlatában még nem elterjedt módszert, a neurális hálókat valamint azok alkalmazhatóságának lehetőségeit mutatjuk be, a vonatkozó hazai és nemzetközi szakirodalom felhasználásával.

ARTIFICIAL NEURAL NETWORKS AND THEIR APPLICATION IN AVIATION METEOROLOGY

In our unbelievably accelerating world, the pace of development has also intensified in the field of aviation. It can be observed from both a civilian and military viewpoint that land activities are increasingly moved into the air. The unmanned aerial vehicle that have spread at an explosive rate in recent decades have considerably contributed to this. The success and efficiency of certain aerial manoeuvres is significantly dependent on weather conditions, thus increasingly many and growingly special demands are received by meteorology experts from aviators. However, currently only the results of numerical forecasting models can be applied in the preparation of prognosis, which are not available outside of a specific time domain, furthermore the models are frequently unsuccessful in forecasting even small scale processes. Therefore, it has become indispensable to develop and adapt new methods, instruments in the field of weather forecasting. In our paper we introduce a method that is not widespread in Hungarian aviation meteorology practice yet, neural networks, and the possibilities of their application, based on related Hungarian and international professional literature.

BEVEZETÉS

Az időjárás pillanatnyi illetve jövőbeni alakulásának ismerete az egyes katonai feladatok tervezésénél és végrehajtásánál napjainkban egyre nagyobb szerepet kap. Kiemelten igaz ez a repülőeszközökkel végrehajtandó műveletek esetében. A döntéshozó parancsnok illetve a hajózó személyzet az aktuális meteorológiai adatok illetve a meteorológus által elkészített prognózisok felhasználásával tud számot vetni az időjárás kedvező vagy kedvezőtlen hatásairól az egyes műveletek során. A megbízható időjárás előrejelzések készítése elképzelhetetlen numerikus és statisztikus előrejelző

¹ meteorológus, MH Geoinformációs Szolgálat, katalin.hadobacs@gmail.com

² egyetemi docens, NKE Katonai Repülő Tanszék, bottyan.zsolt@uni-nke.hu

³ Lektorálta: Bíró Dr. Kircsi Andrea, egyetemi adjunktus, Debreceni Egyetem Meteorológiai Tanszék, kircsi.andrea@science.unideb.hu

modellek futtatása nélkül. Egy olyan nem-lineáris rendszer esetében, mint a légkör csak modellezés révén tehetünk becsléseket a jövőbeli fejlődésre [1].

Jelenleg a szakemberek által biztosított meteorológiai információk csak korlátozottan tudják kiszolgálni a felhasználók igényeit. Ennek egyik fő oka, hogy napjainkban, hazánkban a meteorológiai támogatás kizárólag numerikus modellekre alapuló produktumokkal tud jelen lenni, melyek az előrejelzési időtartományon kívül nem állnak rendelkezésre, így például ultrarövid távon (0–3 óra).

Ismert azonban – elsősorban kis skálájú időjárási jelenségek esetében – hogy a numerikus modellek megbízhatósága az átlagosnál lényegesen kisebb. Igaz ez különösen a repülésre veszélyes időjárási helyzetekre, mint pl. a jegesedés, turbulencia, zivatar stb. vonatkozásában. Számos kutatási program foglalkozik e jelenségek fizikájának, előrejelezhetőségének problémakörével.

Az egyre pontosabbá, bonyolultabbá és szerteágazóbbá váló ismeretanyag feldolgozásához nagy szükség van egyéb matematikai módszerek alkalmazására. Különösen érvényes ez a közvetlenül nem mérhető jellemzőkkel rendelkező, bizonytalansággal is terhelt komplex problémák megoldása esetén. Azért, hogy ezt minél hatékonyabban tudjuk végrehajtani, az új eszközökön túl új gondolkodásmódra és az eszközök újfajta használatára is szükség van. Ezért elengedhetetlenné vált a hazánk katonai meteorológiai gyakorlatában még operatíván nem alkalmazott, de külföldön már széles körben, sikeresen használt mérési adatbázison nyugvó, statisztikai megközelítéseken, eljárásokon alapuló elemző és előrejelző módszerek kidolgozására.

Az egyszerű lineáris regressziós modellek mellett a számítógépek és az informatika gyors fejlődése lehetővé tesz olyan módszerek implementálását, melyek reálisabb, bonyolultabb folyamatokat is tudnak kezelni. Egy ilyen hatékony eszközként szolgálnak a többváltozós, nemlineáris regresszió alapuló neurális hálózatok. Mivel a neurális hálók módszere hazánk meteorológiai gyakorlatában még operatíván nincs alkalmazva és kutatások is csak az utóbbi években indultak meg ezen a területen, így maga a módszer illetve a benne rejlő lehetőségek is csak a meteorológusok egy szűk köre előtt ismertek. Ezért e cikk fő célja a neurális hálók elméleti hátterének ismertetése, valamint a meteorológiai alkalmazhatóságának bemutatása nemzetközi és a már rendelkezésre álló néhány hazai szakirodalom alapján.

REGRESSZIÓ-SZÁMÍTÁS – LINEÁRIS REGRESSZIÓ

Mint minden elemző tudomány területén, a meteorológiában is alapvető az összefüggések matematikai vizsgálata. Gyakran előfordul, hogy két változó mennyiség közötti kapcsolatot vizsgáljuk. A kapcsolat szorosságát célszerű egy mérőszámmal jellemezni. Nagyon sok ilyen mérőszám létezik, ezek közül a legelterjedtebb az ún. korrelációs együttható (r) (1) [2]:

$$r = \frac{\sum(x-M_x) \cdot (y-M_y)}{\sqrt{\sum(x-M_x)^2 \cdot \sum(y-M_y)^2}}, \quad (1)$$

ahol: M_x és M_y az x és y változó számtani közepe.

A korrelációs együttható értéke +1 és -1 között változhat. Ha pozitív értékeket vesz fel, akkor a két változó között egyértelmű kapcsolat van. Ha $r=0$, akkor a két változó között nincs összefüggés.

Amennyiben függvényszerű kapcsolatot keresünk egy vagy több független változó (x_1, x_2, \dots, x_n) és egy függő változó (y) között, akkor alkalmazzuk a regresszió számítását. Azaz:

$$x \rightarrow y \text{ vagy } y = f(x) \quad (2)$$

Az, hogy melyik változó legyen a független és melyik a függő mindig attól kell, hogy függjön, hogy milyen irányú oksági kapcsolatot tételezünk fel a változók között. Nem szabad azt figyelembe venni, hogy melyik változót szeretnénk a másik alapján előrejelezni [3].

A függő változó mindig valószínűségi változó, a magyarázó változó azonban nem biztos. Többnyire az y két független, additív komponensre bontható. Az egyik x -ektől függ, a másik az x -ektől független véletlen faktor.

$$y = f(x) + \varepsilon, \quad (3)$$

ahol: ε a hiba komponens.

Ha a közelítés módja lineáris, akkor lineáris regresszióról beszélünk. Ha csak egy független változónk van, akkor egyváltozós regresszióról van szó. Abban az esetben, ha az előbbi feltételek közül mindkettő fennáll, akkor egyváltozós lineáris regresszióval van dolgunk.

Az általános modell egyenlete (3) lineáris függvénnyel felírva (4):

$$y = ax + b + \varepsilon, \quad (4)$$

ahol: a és b együtthatók;
 x és y független és függő változók;
 ε a hiba komponens.

A legjobb közelítés akkor érhető el, ha:

- a hiba szórása minimális, és
- a hiba átlaga nulla.

A feladat tehát az, hogy megtaláljuk azt az a és b együtthatót, mellyel az $ax+b$ a legjobb közelítése y -nak, azaz a pontokra illeszkedő legjobb egyenest kell megtalálni. Az $y=ax+b$ olyan (x,y) pontokból álló egyenes, melynek meredeksége a , és a függőleges tengelyt b magasságban metszi [4].

A korrelációs együttható (1) és a kapcsolatba hozott változók számtani közepének és szórásának ismeretében tudjuk meghatározni a regressziós egyenes egyenletében szereplő együtthatók értékét, melyek a következő formában írhatók fel [2]:

$$a = r \frac{\sigma_y}{\sigma_x}, \quad (5)$$

$$b = \bar{y} - \bar{x} \cdot a, \quad (6)$$

ahol:

σ_y illetve σ_x függő és független változók szórása,
 \bar{y} és \bar{x} a függő illetve független változó mintaátlaga.

Miután meghatároztuk az együtthatókat, meg kell vizsgálni a modell jóságát. Ehhez a lépéshez tartozik:

1. az illeszkedés globális vizsgálata, melyet F-próba segítségével lehet elvégezni,
2. az egyes paraméterek egyenkénti vizsgálata, melyet t-próbával lehet ellenőrizni, valamint
3. a kapcsolatok szorosságának és a függő változó meghatározottságának vizsgálata, melyet a függő változó és az $ax+b$ korrelációjának a négyzete ad meg (R^2).

Ha nem tudjuk eldönteni, melyik változót tekintjük független és melyiket függő változónak, vagy ha tudjuk, hogy a független változó a függő változóval azonos nagyságrendű véletlen hibával terhelt, akkor a regresszió számítás nem alkalmazható [5][6].


A statisztikai modellek elsősorban az egyes meteorológiai elemek között a matematikai statisztika eszközeivel igyekeznek minél szorosabb kapcsolatot létesíteni. Az egyik legelterjedtebb módszer a fent részletesebben bemutatott lineáris regressziós egyenessel való közelítés alkalmazására a Modell Kimenet Statisztika (MOS megközelítés). Ennél az eljárásnál a keresendő paraméter becslése a modell outputokra illesztett lineáris regressziós egyenessel történik. Ennek a fő hibája, hogy a modell eredmények hibáit, valamint a módszerekben rejlő hibákat is továbbviszi a rendszerbe, valamint az algoritmus is csak az alkalmazott modell adott beállítás mellett működik [6]. Habár a szakterület hatékonyan alkalmazza a lineáris regresszió alapuló módszereket, a jövőben a pontosabb, korrektebb eredmények érdekében érdemes lenne a nem-lineáris regresszió alapuló módszerek fejlesztése, adaptálása. Ennek egy lehetősége a neurális hálózatok bevezetése.

NEURÁLIS HÁLÓZATOK

A neurobiológia és az informatika rohamos fejlődése és összefonódása napjaink bonyolódó információelemzési problémáinak egyike. A mesterséges neurális hálók az agyműködés legkisebb önálló egységei, a neuronok modellezése révén létrejött összetett hálózatot szimulálva látnak el feldolgozási és elemzési feladatokat [7].

A mesterséges neuronok

Egy mesterséges neurális háló egyszerű számítási egységekből, mesterséges neuronokból áll, melyek egymásnak küldött jelekkel kommunikálnak. A jelek nagyszámú súlyozott kapcsolaton áramlanak. A mesterséges neuron az agyi neuron másolata [8]. A legegyszerűbb formában a 1. ábrán látható módon lehet szemléltetni.

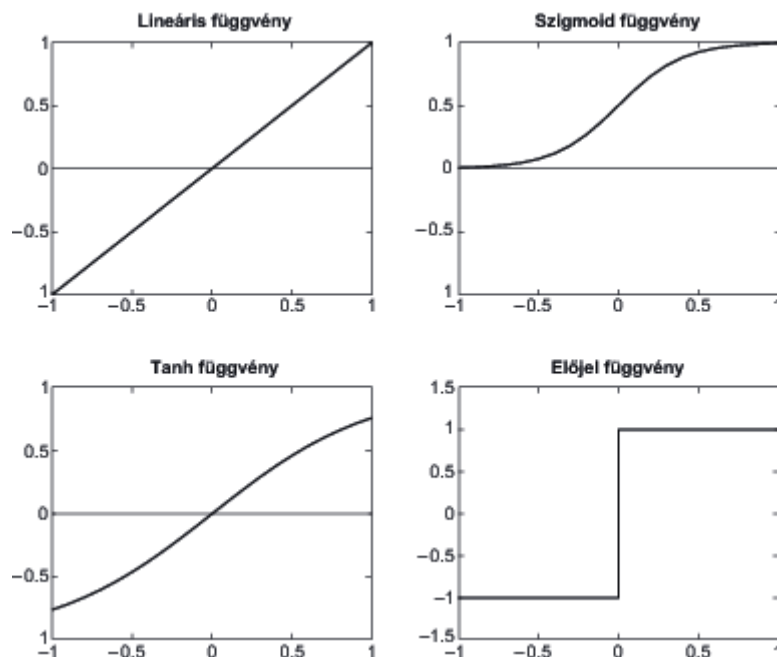


1. ábra Általános neuronmodell [9]

A beérkező jeleket részösszegként, előzetes információk, tanítás alapján súlyozva állapítja meg a kimeneti jelet. A kimenet generálása valamilyen transzferfüggvény segítségével történik, mely a gyakorlatban többnyire nem lineáris, mivel ha itt is lineáris függvényt vezetnénk be, akkor ugyanúgy lineáris regresszióhoz jutnánk. E transzferfüggvény (átviteli függvény) többféle is lehet:

- lineáris;
- lineáris küszöbfüggvény;
- lépcsős függvény;
- szigmoid függvény;
- tangens hiperbolikus;
- logisztikus;
- radiális bázis ... stb.

Az 2. ábrán néhány gyakran alkalmazott transzferfüggvény tekinthető meg [9].



2. ábra Transzferfüggvények

Mindegyikben közös, hogy a leképezés korlátos, az eredménye mindenféleképpen a $[-1;1]$ intervallumba eső legyen, és a folytonosan differenciálhatóság. Utóbbi tulajdonság különösen nagy szerepet játszik a súlytanulási algoritmusnál [10].

Általánosságban elmondhatjuk, hogy a neuronmodellek mindegyike rendelkezik a következő tulajdonságokkal:

- n darab, időtől függő bemenet $x_i(t)$, $i=1, \dots, n$;
- egyetlen időtől függő kimenet $y(t)$;
- a bemenetek súlyozásra kerülnek a kimenetre gyakorolt hatásuk alapján. w_i ($w_i < 0$ esetén gátló, $w_i > 0$ esetén serkentő);
- $y(t)$ valamilyen függvénykapcsolatban van a bemenetekkel, figyelembe véve a súlyokat $y=f(x_1, x_2, \dots, x_n, w_1, w_2, \dots, w_n)$.

A kimenet számítási módjától illetve a be- és kimenetek értékeitől függően különböztetünk meg neuronmodelleket, mint például lineáris neuronmodell, McCulloch-Pitts neuronmodell, leaky integrator modell, integrate and fire neuronmodell [9].


Neurális hálózatok

A neuronmodelleket összekapcsolva neurális hálózatokat kapunk. Az összekapcsolás azt jelenti, hogy az egyik neuron kimenetét összekötjük egy másik neuron egyik bemenetével. Többnyire egy irányított gráffal reprezentálhatjuk őket (3. és 4. ábra), ahol a csúcsok képezik a neuronokat, az élek az összeköttetéseket, míg az irányok a kimenetből a bemenet felé mutatnak. A neuronok ugyanolyan vagy hasonló típusú műveleteket végeznek. Egy hálózatban ezeket a műveleteket a többiekétől függetlenül, lokálisan végzik. Az azonos típusú műveleti elemek alkotnak egy réteget (layer). Az egyes rétegekhez tartozó neuronok az előző réteg kimenetével illetve a következő réteg bemenetével vannak összekötve [11].

A részfeladatok megoldására alkalmas hálózati kapcsolatok felépítéséhez elengedhetetlen egy bemeneti réteg, ahol azon neuronok helyezkednek el, melyek a bemeneti jel továbbítását végzik a hálózat felé. Emellett kell egy vagy több számítást végző rejtett réteg, ahol tulajdonképpen a feldolgozást végző neuronok találhatóak. Valamint létezik egy kimeneti réteg, ahol a neuronok azon csoportja van, melyek a külvilág felé továbbítják az információkat.


A rejtett réteg(ek) neuronjai kapcsolódnak mind a bemeneti, mind a kimeneti réteghez, a kapcsolatok struktúrája alapján a neurális hálóknak két fő csoportja különböztethető meg:

1. előreccsától (hurokmentes) (3. ábra):



3. ábra Előrecsatolt neurális hálózat sematikus ábrája [12]

2. visszacsatolt hálózat (4. ábra):



4. ábra Visszacsatolt neurális hálózat sematikus ábrája [12]

Mivel többnyire a meteorológiai célú alkalmazások során előrecsatolt neurális hálókat használnak, így a továbbiakban e cikkben is ezekkel foglalkozom.

Előrecsatolt neurális hálók

A hálózat egy adott rétegben található neuronjai csak az őt közvetlenül megelőző réteg neuronjaitól kap jelet. A háló struktúrájának felállításánál nincsenek szigorú szabályok, azonban a rétegek számának meghatározásánál a megoldandó feladat bonyolultságától, összetettségétől függően egy vagy két rejtett réteget érdemes kijelölni. Ennél több réteg meghatározása már hatékonyság szempontjából nem célszerű, ugyanis a modell futási ideje drasztikusan megnő, illetve instabillá válik a hibagradiens is [13]. Meteorológiai alkalmazás során a szakirodalom szerint jellemzően egy rejtett réteget szoktak alkalmazni, mivel az adott feladatok megoldásánál így is megfelelően pontos információkhoz jutunk.

A struktúra kialakításának egy másik fontos mozzanata az egyes rétegek neuron-számának meghatározása. Erre a kutatások alapján nincs egzakt, elfogadott szabály, azonban néhány már korábban jól alkalmazott összefüggés fellelhető a szakirodalomban.

Egyik ilyen például, amikor a rejtett neuronok száma (j) a bemeneti (a) és a kimeneti neuronok (b) számából a következő egyszerű összefüggéssel állapítható meg (7) [14]:



$$j = \sqrt{a \cdot b}, \quad (7)$$

Vagy egy másik ajánlás, amikor a rejtett neuronok száma a bemeneti neuronok számának 75%-val egyezik meg. A leggyakrabban alkalmazott lehetőség azonban, amikor a bemeneti neuronok számának maximálisan kétszerese a rejtett neuronok száma [15].

A nagyméretű hálózatok előnyeként meg kell említeni, hogy szinte bármilyen feladat megoldásában pontos eredményt adnak vissza, amennyiben a keletkező redundancia ki van küszöbölve. Azonban a kisebb hálózatok folyamatos bővítésével a betanítás és a számítások ideje meghosszabbodik, de az erőforrásigénye jóval kisebb [16].

A neurális hálózatok alkalmazását egy adott probléma megoldására mindig egy tanulási folyamat kell, hogy megelőzze, ugyanis pont ez lesz az előnye az operatíván alkalmazott módszerekkel szemben, hogy a múltbeli folyamatok ismeretében kerülnek módosításra a kezdetben véletlenszerűen kijelölt hálózati súlyok. Tehát magát a tanulást úgy lehet definiálni, mint a hálózat memóriájának, azaz a súlyoknak (súlymátrix) a változását. Két fő tanulási kategóriát lehet megkülönböztetni:

1. felügyelt tanulás
2. felügyelet nélküli tanulás

Meteorológiai vizsgálatok során, adatbázisokon alapuló futtatásokat végzünk, ezért a két tanulási folyamat közül számunkra az ellenőrzött tanulás alkalmazása a célszerű, mivel rendelkezésre állnak be és kimeneti adatpárok. Tehát egy adott bemenet esetén tudjuk, hogy mit várunk kimeneti értéként. Így a hálózat választát össze lehet hasonlítani a várt eredménnyel. A tanulási folyamat során az a cél, hogy az ismert kimeneti minták értékeit kapjuk vissza. Tehát a keletkező hiba, a két válasz különbsége lesz felhasználva a hálózat tanítására. Ezt a különbséget kell minimalizálni. Ehhez a hiba-visszaterjesztési tanulási alapelv nyújt segítséget, ahol a minimalizálását iteratív módon hajtjuk végre. A hálózat a tanulási folyamat során a hiba csökkenésének mértéke szerint változtatja a súlyokat, amíg egy adott feltételnek meg nem felel az eredmény. A súlyfrissítésnek két féle módja van:

1. a teljes minta adatsor egyszeri végigfutása után történik meg a súlyfrissítés
2. minden tanuló minta után frissít a rendszer.

A mintaadatsor kijelölése során érdemes arra figyelni, hogy a mintaadatok száma legalább ötszöröse legyen a hálózati súlyok számának [17].

Ahogy a statisztikai modellek nagy része a neurális hálóknál is felmerülhet a túltanulás eset, vagyis a túlilleszkedés. Ez a gyakorlatban azt jelenti, hogy hiába memorizálja a rendszer a példákat, nem tudja általánosítani az új bemenetekre [18].

Tehát úgy kell megválasztani a tanulásra alkalmazott adatsort, hogy ne legyen átfedés a validációs résszel. Korábbi kutatások tapasztalatai szerint a rendelkezésre álló adatsor nagyobb részét (~70%) szükséges tanulásra fordítani, így a maradék rész (~30%) segítségével a hálózat általánosító képességét lehet fejleszteni. Utolsó simításként a végső beállítások meghatározásához gyakran a korai leállítás módszerét alkalmazzák, mely során azelőtt állítják le a tanulási folyamatot, mielőtt a validációs adatsorra vonatkozó hiba szignifikánsan nőni kezdene. Ennél az eljárásnál a hibafüggvényt a két adatsorra vonatkozóan együtt vizsgáljuk [10]. A tanulási és



validálási folyamat befejezését követően az előállított neurális háló alkalmazhatóvá válik a feladatok megoldására.

A mai neurális hálók még messze állnak a teljes céltól, azaz az emberi aggyal összemérhető szintű működéstől, azonban az egyéb modellekhez illetve eljárásokhoz képest már most jelentős előnyökkel rendelkeznek.

Mindenekelőtt ki kell emelni, hogy fejlesztésük bizonyos mérvű egyszerűséggel végezhető, így nem szükséges hozzá átfogó programozási ismeret, mivel a rendszer a feladathoz alkalmazkodik, azaz „önállóan” tanul. Habár ebből az is következhet, hogy a kapott eredmények nehezen értelmezhetőek a felhasználó számára, mivel a hálózat egy ún. fekete dobozként működik, amibe nem látunk bele, így az eredmények jóságát különböző statisztikai módszerekkel kell mérni. Struktúrájukból fakadóan a memória szétosztott, azaz párhuzamos feldolgozásokat végez, így nagyobb sebességgel végezhetőek el a futtatások.

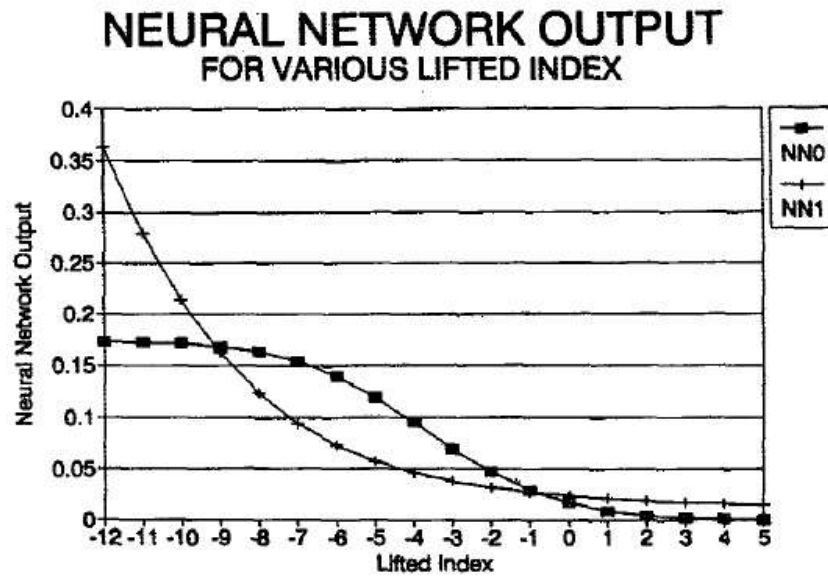
A meteorológiai vizsgálatok során kiemelkedő jelentőséggel bír az egyéb statisztikai eljárásokkal szemben, hogy a lineáris számítási elemek mellett megjelennek a nemlineáris, numerikus számítási folyamatok, valamint zajos és hiányos adatokat is képes bemeneti adatként elfogadni, és abból értékelhető eredményt előállítani.

NEURÁLIS HÁLÓZATOK METEOROLÓGIAI CÉLÚ FELHASZNÁLÁSA

Egy neurális hálózat sokféleképpen épülhet fel, sokféle tanítási eljárással tanítható, és e tulajdonságok biztosítják, hogy többféle tudományterületen válik elengedhetlenné az alkalmazása. A meteorológia területén is egyre nagyobb teret hódítanak a neurális hálók. Az utóbbi évtizedben különösen nagy figyelem irányul a környezet szennyezésre, így egyértelmű, hogy számos kutatás irányul ennek meteorológiai aspektusaira. A meteorológia és a légszennyezés szoros, bonyolult kapcsolatban állnak, ezért a neurális rendszer természetéből adódik, hogy alkalmazható levegőkémiai vizsgálatokra. Yi és Prybutok (1996) valamint Boznar et al. (1993) ipari területekre készített ózon illetve kén-dioxid koncentráció változására vonatkozóan előrejelzéseket [19][20]. Mindkét kutatás során kimutatható volt, hogy a regresszió számítás eredményei elmaradtak az új technika mellett. Ugyanezt támasztotta alá Comrie (1997) összehasonlító tanulmányában is [21].


A légkört vizsgáló tudományban sok olyan feladat merül fel, ahol bizonyos jelenségeket, folyamatokat különböző osztályokba kell sorolni, vagy azonosítani kell. Számos publikáció bizonyítja, hogy e téren is van létjogosultsága az új eljárásnak. Peak és Tag (1992) felhőosztályozást végzett el műholdképek felhasználásával, Verdecchia et al. (1996) a blocking helyzeteket azonosított, Hagelberg és Helland (1995) pedig radarképek felhasználásával határozta meg a konvergencia vonalakat [22][23]. Kutatásaikkal hozzájárultak ahhoz, hogy a meteorológus szakembereknek az időjárás pillanatnyi, aktuális állapotát könnyebb legyen felmérni. Illetve munkájukat is egyszerűbbé teszi, ha a műhold illetve radarképek mellett azok értékelése, analizálása is a rendelkezésükre áll, melyek kizárólag objektív alapokon állnak.

A meteorológia szakterületének Achilles-pontja a repülésmeteorológia, annak is a repülésre veszélyes jelenségekkel foglalkozó területe. A szakemberek legnagyobb kihívása e folyamatok előrejelzése mind térben mind időben. Ilyen téren az első értékelhető eredmények McCann-nek (1992) köszönhetőek, aki a zivatarok előfordulásának előrejelzésére vonatkozóan készített algoritmust [24]. Kísérletet tett a zivatar kialakulásáért felelős paraméterek (stabilitás, emelő hatás) kapcsolatának vizsgálatára (5. ábra), azonban arra a következtetésre jutott, hogy lehetetlen megérteni a neurális hálók „fekete dobozát”. Így munkássága akkoriban nem aratott osztatlan sikert a kollégái között.



5. ábra A neurális hálózat kimenete (output) különböző lifted indexek (emelési index) mellett. Az outputok dimenzió nélküli számok 0 (nem mérvadó zivatar előrejelzése) és 1 (mérvadó zivatar előrejelzése) között. (NN0 és NN1: a kutatás során alkalmazott két futtatás). [24]

A neurális hálókkal történő vizsgálatait azonban nem hagyta abba, így egy másik repülést veszélyeztető jelenség, a repülőgép felületi jegesedésének előrejelzésére is készített algoritmust [25], melynek eredményeinek térképes megjelenítése a 6. ábrán látható.



6. ábra Neurális háló outputjának térképes megjelenítése a 825-850 mb nyomási szint között tapasztalható jegesedésre vonatkozóan 2003. február 1-jén 16 UTC időpontra (15 UTC-től számított 1 órás előrejelzés) [25]

Egy-egy repülési feladatot azonban nem csak a veszélyes jelenségek tudnak megghiúsítani, hanem a csapadék, a felhőzet alapjának illetve a látástávolságnak a csökkenése is. Így egyértelmű, hogy e területen is releváns a neurális hálók alkalmazása [26][27][28]. Mint ahogy a statisztikai modellek nagy részénél, a neurális hálók alkalmazásával elkészített produktumok is elsősorban ultrarövid távon (3-6 óra) mutatnak jó eredményt. Ezt bizonyítja Fabbian és társai által kidolgozott rendszer kísérleti alkalmazása a Canberrai Nemzetközi repülőtéren, mely a látástávolságok előrejelzésére kategóriákat vezet be, így eredményként megkapjuk egyértelműen, hogy adott időben a látástávolság melyik intervallumba esik. Kiemelten fontos az egyértelmű eredmény kód esetén [29].

Jelenleg a vizsgálatok nagy része a látástávolsággal kapcsolatosak, mivel e paraméter előrejelzésére vonatkozóan a numerikus modellek nem szolgáltatnak információt, így nagy kihívást jelent az előrejelzőknek.

KUTATÁSI CÉLKITŰZÉSEK

A hazai (katonai) repülésmeteorológiai gyakorlatban szinte teljesen hiányoznak a repülésre veszélyes időjárási jelenségekre vonatkozó előrejelzési produktumok. Mivel e folyamatok méretük-nél fogva egyébként is numerikus modellekkel nehezen vagy egyáltalán nem előrejelezhetőek, így legfőbb célom olyan statisztikai eljárások kidolgozása, vagy már külföldön bevált módszerek Kárpát-medencére való adaptálása, melyek kimondottan e problémára jelenthetnek megoldást. Mindezt a neurális-hálók alkalmazásával tervezem elkészíteni. Így elsőként a legfontosabb feladat a meteorológia tudományágának megfelelő neurális háló típust, illetve annak beállításait ki-



alakítani. Ehhez a MATLAB szoftvert alkalmazom. A MATLAB programban kétféle módon tudunk létrehozni neurális hálózatokat. Az első és egyben nehezebb megvalósítási koncepció, hogy a program Command Window paneljét használva parancsnyelven hozzuk létre azt a hálózati struktúrát, amire éppen szükségünk van. Másik lehetőség, melyet kutatásim során használni kívánok, egy egyszerűbb mód, a Neural Netwok Toolbox. Ez a MATLAB-ban elérhető grafikus eszköz a neurális hálózatok kezelése céljából [30].

Ezt követően a kidolgozott módszerek független statisztikai adatbázis és kísérleti mérési adatok felhasználásával tesztelésre kerülnek, majd különböző verifikációs eljárások segítségével ellenőrzöm eredményeimet. Az új eljárás hatékonyságát, illetve operatív használatba való állítás szükségességét objektív értékeléseken alapuló esettanulmányok segítségével szeretném alátámasztani.

ÖSSZEZÉS

A repülésmeteorológusok irányába támasztott egyre nagyobb és széleskörűbb igények a felhasználók felől megkövetelik a folyamatos kutatásokat, annak érdekében, hogy új, hatékonyabb költségtakarékosabb módszerek kerüljenek kidolgozásra az időjárás minél pontosabb előrejelezhetőségének érdekében. Ehhez azonban elengedhetetlen az egyéb, kapcsolódó tudományterületeken (matematika, számítástechnika) az újabb és újabb egyre fejlettebb módszerek, eszközök kialakítása. Egyik ilyen, az utóbbi évtizedek leginkább figyelemmel kísért számítástechnikai és egyben matematikai fejlesztése a neurális hálózatok, melyeket még most is vegyes fogadtatás kísér a szakemberek körében is.

Habár elmondható, hogy napjainkra a neurális hálók túlnőttek a velük szemben támasztott követelményeken, és ahogy a cikkben is bemutattam számos meteorológiai kutatás során is alkalmazzák már őket. A számítástechnika e területre irányuló fejlesztései még messze nem érték el a lehetséges célt, így a folyamatos fejlesztések révén a meteorológusok is újabb és újabb eszközöket kapnak, amik segítségével a légkörben zajló összetett, bonyolult folyamatokat egyre pontosabban tudják modellezni majd előrejelezni.

További kutatásaim célja olyan hatékony értékelő és előrejelzési módszerek, eljárások kidolgozása és fejlesztés, melyek jelenleg a hazai repülésmeteorológiai gyakorlatban teljesen hiányoznak. Mindezt a cikkben bemutatott, e területen még újnak számító neurális-hálók alkalmazásával tervezem elkészíteni.

FELHASZNÁLT IRODALOM

- [1] HORÁNYI ANDRÁS: Egységes időjárési és éghajlati előrejelző rendszer kifejlesztése az Országos Meteorológiai Szolgálatnál. 34. Meteorológiai Tudományos Napok előadásai (Szerkesztette: Weidinger T.), Budapest, OMSZ, 2009, pp. 39-52.
- [2] Dr. Péczely György: Éghajlat. Nemzeti Tankönyvkiadó, Budapest, 1998, pp.285-321.
- [3] Két mennyiség kapcsolatának vizsgálata, korreláció és lineáris regresszió. url: <http://rs1.szif.hu/~szorenyi/elm/bioselm7.htm> (2015.01.15.)
- [4] Csordásné Marton Melinda: Matematikai példatár VII., Lineáris algebra II., 2010, url: http://www.tankonyvtar.hu/hu/tartalom/tamop425/0027_MAT7/ch01s07.html (2015.01.25.)
- [5] Dr. Reiczigel Jenő: A regressziószámítás gyakorlati kérdései. url: <http://www2.univet.hu/users/jreiczig/omaa-courses-2001/regr-hun.pdf> (2015.02.25.)

- [6] Dévényi Dezső – Gulyás Ottó: Matematikai statisztika módszerek a meteorológiában. Tankönyvkiadó, Budapest, 1988.
- [7] Horváth Gábor: Neurális háló és műszaki alkalmazásai. Műszaki Egyetem, 2006.
- [8] Fazekas István: Neurális hálózatok. Debrecen, 2013. url: http://w1.inf.unideb.hu/documents/19512/90610/Neuralis_halozatok_v8.pdf/821f6e89-40f9-4ec6-8f2d-61de3e6d4bf8
- [9] Bérci Norbert: A neurális hálózatok alapjai. 2005. url: http://virt.uni-pannon.hu/index.php/component/docman/doc_download/55-neuralishalozatok
- [10] Anil K. Jain, Jianchang Mao: Artificial Neural Networks: A Tutorial. Computer, 29, 3, 1996, pp. 31-41.
- [11] Kröse B., van der Smagt P.: An introduction to neural network. University of Amsterdam, 1996
- [12] Dr. Dudás László: Mesterséges intelligencia. url: <http://ait.iit.uni-miskolc.hu/~dudas/MIEAok/MIEa1.PDF> (2015.02.23.)
- [13] Svozil D., Kvasnicka V., Pospichal J.: Introduction to multi-layer feed-forward neural networks. Chemometrics and Intelligent Laboratory Systems, 39, 1997, pp. 43-62.
- [14] Kaastra I., Boyd M.: Designing a neural network for forecasting financial and economic time series. Neurocomputing, 10, 1996.
- [15] Katz J. O.: Developing neural network forecasters for trading. Technical Analysis of Stocks and Commodities, 8, 1992, pp 58-70.
- [16] Zaletnyik Piroška: WGS-84 – EOVS koordináta transzformáció neurális hálózattal. BME, TDK dolgozat, 2003.
- [17] Klimasaukas C. C.: Applying Neural Networks, in R. R. Trippi and E. Turban, editors, Neural Network sin Finance and Investing: Using Artificial Intelligence to Improve Real World Performance, Chicago, 1993, pp. 65-65.
- [18] Jeanett Lawrence: Introduction to Neural Networks. California Scientific Software, Grass Valley, 1991, p 203.
- [19] Yi J. and Prybutok R.: A neural network model forecasting for prediction of daily maximum ozone concentration in an industrialised urban area. Environmental Pollution, 92, 3, 1996, pp. 349-357.
- [20] Boznar M., Lesjak M. and Mlakar P.: A neural network-based method for short-term predictions of ambient SO₂ concentrations in highly polluted industrial areas of complex terrain. Atmospheric Environment, 27, 2, 1993, pp. 221-230.
- [21] Comrie A. C.: Comparing neural networks and regression models for ozone forecasting. Journal of Air and Waste Management, 47, 1997, pp 653-663.
- [22] Peak J. E. and Tag P. M.: Towards automated interpretation of satellite imagery for navy shipboard applications. Bulletin of the American Meteorological Society, 73, 7, 1992, pp 955-1008.
- [23] Verdecchia M., Visconti G., D'Andrea F. and Tibaldi S.: A neural network approach for blocking recognition. Geophysical Research Letters, 23, 16, 1996, pp. 2081-2084.
- [24] McCann D. W.: A neural network short-term forecast of significant thunderstorms. Forecasting Techniques, 7, 1992, pp 525-534.
- [25] McCann D. W.: NNICE – A neural network aircraft icing algorithm. Environmental Modelling & Software, 20, 2005, pp 1335-1342.
- [26] Pasini A., Pelino V., Potesta S.: A neural network model for visibility nowcasting from surface observations: Results and sensitivity to physical input variables. Journal of Geophysical Research, 106, 2001, pp 954-959.
- [27] Dean A. R., Fiedler B. H.: 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, 2001, pp 629-639.
- [28] Brenners J. B., Michaelides S.: Probabilistic forecasts of rare visibility events using neural networks, Short range forecasting methods of fog, visibility and low clouds. Workshop Proceedings, 2005.
- [29] Fabbian D., De Dear R., Lellyett S.: Application of Artificial Neural Network Forecasts to Predict Fog at Camberra International Airport, Weather and Forecasting, 22, 2007, pp. 372-381.
- [30] Stoyan Disbert (szerk.): MATLAB, Typotex, Budapest, 2011.