

Számel Bence Domonkos<sup>1</sup> – Szabó Géza<sup>2</sup>

## LÉGTÉRKAPACITÁS SZÁMÍTÁS ELMÉLETI MODELLEK ALAPJÁN<sup>3</sup>

*A légiközlekedés biztonsága részben az alkalmazott műszaki rendszerek biztonságán, részben az alkalmazott szabályrendszer megfelelőségén és alkalmazhatóságán, de jelentős részben a légiközlekedés szervezésében, lebonyolításában részt vevő szakemberek helyes viselkedésén (szakértelem, szakképzettség, adott szituációban való cselekvőképesség stb.) múlik. A humán tényező szerepe, az emberi hibák modellezése és kiküszöbölési lehetőségeinek feltárása fontos kutatási irány. Cikkünkben a légiforgalmi irányítás (ATC) optimális munkaterhelésén alapuló légtérkapacitás-számításra mutatunk be két módszert, a neurális hálón alapuló megközelítést és a geometriai megközelítést. Módszereink korábban már bevezetett módszerek adaptálásai a magyar légtérben való alkalmazás céljára. Bemutatjuk a számunkra optimális paraméterkészlet meghatározási módját és ennek validálását is, valamint elemezzük az általános alkalmazhatóság kérdését.*

### AIRSPACE CAPACITY ESTIMATION BASED ON THEORETICAL MODELS

*The safety of air traffic is based on the safety of technological systems used as well as the adequacy and applicability of regulations, but it also depends strongly on the appropriate behaviour (expertise, qualification, situational ability to act etc.) of human experts involved in the management and operation of air traffic. The role of human factors, the modelling of human error and the exploration of methods to eliminate it are important areas of research. In this paper we present two methods to estimate airspace capacity based on optimal workload in Air Traffic Control (ATC). The first one is based on neural networks, while the other uses a geometric approach. The presented methods are adaptations of already existing methods and our aim is applying them to the airspace of Hungary. We describe the way of defining the optimal set of parameters and its validation and analyse the possibility of general application.*

## 1. A LÉGTÉRKAPACITÁS-SZÁMÍTÁS SZEREPE A LÉGI KÖZLEKEDÉS BIZTONSÁGÁBAN

A légi közlekedés biztonsága (vagy repülésbiztonság) az [1]-ben megadott definíció szerint a levegőben történő mozgás során, a komplex emberi és műszaki tevékenység eredményeként létrejött, az adott körülmények között optimális működőképesség, illetve e működőképesség megtartásának valószínűsége. A légi közlekedés biztonságát egyaránt meghatározzák az abban részt vevő műszaki rendszerek, emberek és az ezek működését befolyásoló környezeti tényezők. A műszaki rendszerekhez a repülőgépek és a hozzájuk tartozó fedélzeti hardver és szoftver mellett hozzátartoznak többek között a légiforgalmi irányítás (vagy tágabb értelemben légiforgalom szervezés) eszközei is. A műszaki rendszerek biztonságra gyakorolt hatását befolyásolja az eszközök minősége, ami a tervezés és gyártás során alakul ki, és megbízhatósága, amit részben a tervezés és kivitelezés, részben az ellenőrzés és karbantartás minősége, illetve az ezekre vonatkozó előírások határoznak meg.

<sup>1</sup> okl. közlekedésmérnök, PhD hallgató, Budapesti Műszaki és Gazdaságtudományi Egyetem, Közlekedés- és Járműirányítási Tanszék, szamel.bence@mail.bme.hu

<sup>2</sup> okl. villamosmérnök, PhD, egyetemi docens, Budapesti Műszaki és Gazdaságtudományi Egyetem, Közlekedés- és Járműirányítási Tanszék, szabo.geza@mail.bme.hu

<sup>3</sup> Lektorálta: Dr. Palik Mátyás alezredes, tanszékvezető egyetemi docens, Nemzeti Közszolgálati Egyetem Hadtudományi és Honvédtisztképző Kar Katonai Repülő Tanszék, palik.matyas@uni-nke.hu

A légi közlekedés szervezésében és lebonyolításában részt vevő emberek szintén hatással vannak a rendszer biztonságára, amely hatás részben a képzés és tapasztalat útján szerzett szakértelmüktől függ, részben pedig attól, mennyire alkalmasak feladatuk ellátására az adott szituációban. Természetesen a humán biztonság is kézben tartható, menedzselhető, bár módszerei talán kevésbé egzaktak, mint a műszaki biztonság eszközei. A humán biztonság kezelésének legfontosabb eszközei a biztonságmenedzsment rendszerek (Safety Management Systems [2][3][4])

A személyzet egy adott szituációban értelmezett feladat-végrehajtásra való alkalmasságát a környezetből származó tényezők határozzák meg, amelyek közül légiforgalmi irányítók esetében az egyik legfontosabb a munkaterhelés. A munkaterhelés biztonságos szinten tartása érdekében vezették be évtizedekkel ezelőtt a légterek szektorokra osztását, ezzel lehetővé téve, hogy ugyanazt a forgalmat több irányító kezelje. A szektorok nyitásával és zárásával kapcsolatos előírások ugyanakkor még napjainkban is tapasztalati úton meghatározott légijárműszámokon alapulnak, miközben a munkaterhelést – ahogyan látni fogjuk – más tényezők is befolyásolják.

A szolgálatban lévő irányítók munkaterhelésének optimális vagy ahhoz közeli szinten tartása érdekében indokolt a légiforgalmi szektorkapacitás nagy pontosságú meghatározása és előrebecslése. Az irányító munkaterhelése alatt azt az időtartamot kell érteni, melyet egy adott intervallumon (pl. 1 óra) belül az irányítással kapcsolatos tevékenységekre (ide értve az információszerezést, a helyzetértékelést valamint a tervek készítését és végrehajtását [5]) fordít [11]. A munkaterhelés számszerű leírására általában nem ezen időtartam abszolút hosszát, hanem a teljes intervallumhoz viszonyított százalékos arányát használják. Ha például egy irányító egy órából 30 percet tölt az irányításhoz közvetlenül kapcsolódó tevékenységgel, akkor 50%-os munkaterhelésről beszélhetünk. A munkaterhelés lehetséges szintjeit és a hozzájuk tartozó százalékos és (1 órára vonatkozóan) percben mért értékeket mutatja be az 1. táblázat.

| Tartomány   | Értelmezés               | 1 órára eső munkával töltött idő |
|-------------|--------------------------|----------------------------------|
| $\geq 70\%$ | Túlterhelés              | $\geq 42$ perc                   |
| 54–69%      | Magas terhelés           | 32–41 perc                       |
| 30–53%      | Közepes terhelés         | 18–31 perc                       |
| 18–29%      | Alacsony terhelés        | 11–17 perc                       |
| 0–17%       | Nagyon alacsony terhelés | 0–10 perc                        |

1. táblázat Munkaterhelési tartományok

A munkaterhelés mértéke összefüggésben áll az irányítói hibák számával és ezáltal a repülésbiztonsági szempontból nem megengedhető események (elkülönítési minimumok sérülése) számával is, ezt az összefüggést azonban ezidáig nem sikerült egyértelműen, számszerűen leírni. Elsőre kézenfekvőnek tűnhet azt gondolni, hogy a nagyobb munkaterhelés több hibához vezet és egyes korábbi kutatásokban sikerült is ilyen jellegű összefüggést kimutatni (ilyen például M. Grossberg 1989-es tanulmánya, melyben Chicago távolkörzeti légtérét vizsgálta és statisztikailag szignifikáns kapcsolatot talált az akkori definíció szerint értelmezett komplexitás és a hibák száma között [6]). Más tanulmányokból (például P. Stager és D. Hameluck 1990-ben megjelent, a légiforgalmi irányítás ergonómiájával foglalkozó publikációjából [7]) ugyanakkor az derül ki, hogy a legtöbb hiba közepes komplexitású (és ezáltal közepes munkaterhelést jelentő) szekto-

rokban figyelhető meg. Ebből azonban nem következtethetünk egyértelműen arra, hogy a magasabb munkaterhelés nem vezet több hibához, mivel elképzelhető, hogy a kutatás azért szolgáltatott ilyen eredményeket, mert lényegesen több adat áll rendelkezésre alacsony vagy közepes komplexitású és munkaterhelésű szektorokról, mivel a szektorok az idő nagy részében közepes vagy alacsony komplexitással üzemelnek. Emiatt lehetséges, hogy bár időegység alatt a közepes terhelésű szektorokban kevesebbet hibáznak az irányítók, mint a magas munkaterhelésűekben, összességében több lesz a közepes terhelésű szektorokhoz tartozó hibaszám annak köszönhetően, hogy az irányítók hosszabb ideig dolgoznak közepes terhelésű szektorokban. Ehhez hasonló következtetésre jut M. D. Rodgers, R. H. Mogford és L. S. Mogford 1998-as cikkében, melyben a szektorok tulajdonságai és az irányítói hibák közötti kapcsolatot próbálják feltárni és azt állítják, hogy a magas munkaterhelés és a gyakoribb hibázás között logikai kapcsolat van, mivel a nagyobb mértékben terhelt irányító könnyebben hibázik [8].

A fenti szerzők feltevése valóban logikus, de irányítói hibák és ezekből fakadó események megfigyelhetőek határozottan alacsony munkaterhelést jelentő szektorokban is, amire szintén létezik észszerű magyarázat. Valószínűleg részben itt is a nagyobb adatmennyiség torzító hatása érvényesül, mivel egy átlagos és jól szervezett légtérben az alacsony komplexitású szektorok hasonló gyakorisággal fordulnak elő, mint a közepes komplexitásúak és csak a magas komplexitás ritka. Emellett azonban az is lehetséges, hogy az irányítói hibák bekövetkezésének valószínűsége nagyobb, ha a munkaterhelés mértéke nem ér el egy bizonyos minimális szintet. Ennek oka részben az lehet, hogy túlzottan alacsony munkaterhelés esetén az irányítók kevésbé érzik fontosnak, hogy minden feladatukat a forgalom figyelésére (valamint az ehhez kapcsolódó döntések kidolgozására és végrehajtására) fordítsák, így könnyebben elvonhatják figyelmüket a feladatról különböző környezeti vagy belső eredetű zavaró hatások. További problémát jelenthet az alacsony munkaterheléshez kapcsolódóan az, hogy bizonyos légiforgalmi irányítói körzetekben (például Budapest APP<sup>4</sup> körzetében) az érvényben lévő eljárásrendben az előírt szabványos repülési (indulási és érkezési) útvonalak csak ajánlás szintjén szerepelnek, vagyis az irányítók nem kötelesek minden helyzetben ezeknek megfelelően mozgatni a légi járműveket. Ez gyakran arra ösztönzi az irányítókat, hogy a hatékonyság érdekében kisebb forgalmú szituációkban repülőgépeket térítsenek át a szabványos útvonalokról rövidebb útvonalakra. A szabványos útvonalat elhagyó repülőgép azonban az elhagyást követően folyamatos figyelmet és vektorálást igényel az irányító részéről, ami munkaterhelés többletet jelent az egyébként alacsony komplexitású szituációban.

A fentiek alapján tehát látható, hogy a légiközlekedés biztonsága érdekében mind a túlzottan magas, mind a túlzottan alacsony munkaterheléssel járó szituációkat kerülni kell, azaz fontos, hogy megfelelő pontossággal előre lehessen becsülni, mikor lesz egy szektor komplexitása túl magas vagy túl alacsony és ennek megfelelően előbbi esetben több részre kell osztani, utóbbiban pedig valamely szomszédos szektorral össze kell vonni a szóban forgó szektort. Minél pontosabb a komplexitás előrebecslésére szolgáló módszer, annál rövidebb időközönként lehetséges a szektorkonfiguráció változtatása, ami által rövidebbek lesznek az optimálistól eltérő munkaterheléssel járó időszakok. Ugyanakkor fontos megjegyezni, hogy a konfigurációváltások kö-

<sup>4</sup> Approach Control, Bevezető Irányítás

zött eltelő idő nem csökkenthető minden határon túl, mivel az új szektor nyitása vagy a szektorok összevonása önmagában is terhelésnövekedést jelent, ugyanis mindkét esetben van olyan irányító, akinek rövid idő alatt teljesen új forgalmi helyzetet kell értelmeznie.

## 2. LÉGTÉRKAPACITÁS-SZÁMÍTÁSI MODELLEK

A magyar légtérre két különböző modelltípus szektorkapacitás-számításban történő használhatóságát vizsgáltuk, melyek jellegzetességeit az alábbiakban foglaljuk össze.

Az egyik lehetőség a komplexitás és az irányítói munkaterhelés kapcsolatának leírására a neurális hálós modellezés. Ezzel foglalkozik többek között D. Gianazza és K. Guittet a komplexitás becsülésének lehetőségeiről szóló tanulmányában [10]. A kutatásban a lehetséges komplexitási tényezők közül azokat vették figyelembe, melyeket korábban Kopardekar és Magyarits [12]-ben lényeges tényezőként azonosított. A kutatást 5 francia ATC központra végezték el, melyek radaradataiból és környezeti adataiból egy nap minden egész percében mintát vettek. Az adott napon 103 elemi szektort vagy szektorkombinációt alkalmaztak, melyek mindegyikére minden percben kiszámították a komplexitást és feljegyezték a szektor állapotát (egyesítve, önálló, osztva). Az adatok 60%-át a neurális háló tanítására használták, a többi 40%-ot pedig a háló tesztelésére. A komplexitási tényezők számának csökkentésére főkomponens elemzést használtak, melynek eredményeként 6 főkomponens adódott a következő mérhető értékekhez kapcsolódóan: repülőgépek száma, sebesség vagy magasságváltozások, bejövő áramlatok, összetartó áramlatok és konfliktusok előrejelezhetősége, széttartó áramlatok, függőleges elkülönítési minimum közeli állapotok. A modellezéshez háromrétegű előrecsatolt neurális hálót használtak. A háló bemeneti rétegében a neuronok számát a figyelembe vett komplexitási tényezőknek megfelelően változtatták, a rejtett réteg 15, a kimeneti réteg pedig 3 neuront tartalmazott, melyek mindegyike egy-egy szektorállapotnak felelt meg. A háló egyenlete a következő volt:

$$y_k = \Psi \left( \sum_{j=1}^q w_{jk} \Phi \left( \sum_{i=1}^p w_{ij} x_i + w_{0j} \right) + w_{0k} \right) \quad (1)$$

ahol  $\Phi$  az aktiváló függvényt (mely jelen esetben a logisztikai függvény):

$$\Phi(z) = \frac{1}{1 + e^{-z}} \quad (2)$$

,  $\Psi$  az átviteli függvényt (ebben az esetben):

$$\Psi(z_k) = \frac{e^{z_k}}{\sum_{m=1}^C e^{z_m}} \quad (3)$$

$x_i$  a komplexitási tényezők értékeit,  $w_{ij}$  és  $w_{jk}$  a hozzájuk tartozó súlys számokat,  $w_{0j}$  és  $w_{0k}$  pedig a hibát jelöli. A súlys számok és a hibák értéke a tanítás során határozható meg. Miután elvégezték a háló tanítását és tesztelését különböző számú komplexitási tényezővel, arra jutottak, hogy

a háló az első négy főkomponens használata esetén már az esetek több mint 80 %-ában a valószínűségnek megfelelő eredményt szolgáltat, az érték pedig nem növelhető számottevően további tényezők figyelembe vételével.

D. Delahaye és S. Puechmorel olyan lehetséges megközelítéseket mutat be a légitforgalom komplexitásának meghatározására, melyek figyelembe veszik a forgalom belső rendezetlenségét (entrópiáját) [9]. A repülőgépek sebességének rendezetlenségének számítására általános esetben kézenfekvő lenne a statisztikai alapú entrópiaszámítás, a nagy rendezetlenségű helyek azonosítására pedig a wavelet transzformáció, ezek a módszerek azonban csak elegendően nagy minta (esetünkben repülőgépszám) esetén szolgáltatnak kielégítő eredményt. Ugyanakkor a vizsgált szektorokban egyszerre megtalálható, legfeljebb 30–40 repülőgép esetén is valószínű eredményt szolgáltat a geometriai alapú és a Kolmogorov-entrópián alapuló megközelítés. A geometriai megközelítés alapja a repülőgépek egymáshoz viszonyított helyzete és sebessége az egyes időpillanatokban. A módszer alkalmazásának végeredménye egy 3 dimenziós koordináta-rendszer, melyben pontsorozatok jelképezik az egyes forgalmi helyzetek komplexitását. A koordináta-rendszer egyik tengelyén a sűrűség jelenik meg, ami a modellben exponenciálisan függ a többi repülőgép adott repülőgéptől mért távolságától adott pillanatban. A sűrűség fogalma alatt jelen esetben nem a forgalomsűrűséget kell érteni (ami a járatszámmal hasonló jelentéstartalommal bíró fogalom), hanem egy olyan tényezőt, ami a járatok adott szektoron belüli térbeni elrendeződéséről hordoz információt, vagyis a forgalom egyenletes vagy sűrűsödési helyekre tömörülő jellegére lehet belőle következtetni. A sűrűség kiszámítása az alábbi képlet segítségével történik:

$$Dens(i) = 1 + \sum_{\substack{j=1 \\ j \neq i}}^N e^{-\alpha \frac{\|\bar{d}_{ij}\|}{R}} \quad (4)$$

ahol  $N$  az összes repülőgép száma a vizsgált szektorban,  $\|\bar{d}_{ij}\|$  az  $i$ . és  $j$ . repülőgép távolságvektorának nagyságát kifejező norma,  $\alpha$  súlyozó tényező,  $R$  pedig a járat vizsgált környezetének sugara.

A második tengely az egymáshoz viszonyított sebességet ábrázolja, más szóval a forgalom divergenciáját (pozitív oldal) és konvergenciáját (negatív oldal). A divergencia és a konvergencia kiszámítására az alábbi két képlet szolgál (az  $i$ . és  $j$ . repülőgép vonatkozásában):

$$Div(i) = \sum_{\substack{j=1 \\ j \neq i}}^N \left| \frac{d\|\bar{d}_{ij}\|}{dt} \right| \cdot \mathbf{1}_{R^+} \left\{ \frac{d\|\bar{d}_{ij}\|}{dt} \right\} e^{-\alpha \frac{\|\bar{d}_{ij}\|}{R}} \quad (5)$$

$$Conv(i) = \sum_{\substack{j=1 \\ j \neq i}}^N \left| \frac{d\|\bar{d}_{ij}\|}{dt} \right| \cdot \mathbf{1}_{R^-} \left\{ \frac{d\|\bar{d}_{ij}\|}{dt} \right\} e^{-\alpha \frac{\|\bar{d}_{ij}\|}{R}} \quad (6)$$

Az (5) és (6) képletben szereplő  $\mathbf{1}_{R^+}$  és  $\mathbf{1}_{R^-}$  a valós számok pozitív és negatív részhalmazára vonatkozó karakterisztikus függvény, melynek értéke 1, ha az argumentumban szereplő szám eleme a részhalmaznak és 0, ha nem.

A harmadik tengely azt reprezentálja, hogy a távolságváltozás mennyire érzéketlen a sebesség és a haladási irány változására (ami a gyakorlatban azt fejezi ki, mennyire tudja a légiforgalmi irányítás befolyásolni a forgalom komplexitását). Az érzéketlenség az érzékenység reciprokaként áll elő, az érzékenység kiszámítása pedig a következő két képlettel történhet:

$$St_+(i) = \sum_{\substack{j=1 \\ j \neq i}}^N \|\nabla t_c\| \cdot \mathbf{1}_{R^+} \left\{ \frac{d\|\overline{d}_{ij}\|}{dt} \right\} e^{-\alpha \frac{\|\overline{d}_{ij}\|}{R}} \quad (7)$$

$$St_-(i) = \sum_{\substack{j=1 \\ j \neq i}}^N \|\nabla t_c\| \cdot \mathbf{1}_{R^-} \left\{ \frac{d\|\overline{d}_{ij}\|}{dt} \right\} e^{-\alpha \frac{\|\overline{d}_{ij}\|}{R}} \quad (8)$$

ahol:

$$\|\nabla t_c\| = \left\| \begin{pmatrix} \|\overline{d}_{ij}\| \cdot \frac{\Delta v_x \sin(\theta_j) + \Delta v_y \cos(\theta_j)}{(\|\overline{v}_{ij}\|)^3} \\ \|\overline{d}_{ij}\| \cdot \frac{-\Delta v_x \sin(\theta_i) + \Delta v_y \cos(\theta_i)}{(\|\overline{v}_{ij}\|)^3} \\ \|\overline{d}_{ij}\| \cdot \frac{-\Delta v_x \cos(\theta_j) + \Delta v_y \sin(\theta_j)}{(\|\overline{v}_{ij}\|)^3} \\ \|\overline{d}_{ij}\| \cdot \frac{\Delta v_x \cos(\theta_i) - \Delta v_y \sin(\theta_i)}{(\|\overline{v}_{ij}\|)^3} \end{pmatrix} \right\| \quad (9)$$

$v_x$  és  $v_y$  az adott irányban vett sebességkülönbség,  $\theta$  pedig a földrajzi északi iránnyal bezárt szög.

A geometriai modell problémája, hogy csak időpillanatokra alkalmazható, így a forgalom dinamikáját csak korlátozottan veszi figyelembe. A másik módszer a forgalom múltbeli alakulását egy dinamikus rendszer állapotváltozásaként értelmezi és a rendszer topológiai entrópiáját használja a komplexitás kifejezésére. Mivel ezt a módszert jelen kutatás során nem használtuk, ezért részletekbe menő ismertetésétől eltekintünk.

### 3. A MODELLEK PARAMÉTEREZÉSE A MAGYAR LÉGTÉRRE

A modellek bemenő adatokkal történő ellátásához és validálásához szükséges adatok három csoportra oszthatóak, melyek a következők:

- a légtér szerkezetére vonatkozó statikus adatok (szektorhatárok, légterek, útvonalszerkezet);
- a forgalomra vonatkozó radaradatok;
- az irányítóktól származó szubjektív adatok a forgalmi szituációk komplexitásával és a komplexitási tényezők fontosságával kapcsolatban.

A szektorhatárokat és az útvonalszerkezetet leíró adatokhoz a Közlekedés- és Járműirányítási Tanszék jóvoltából juthattunk hozzá. A tanszék az adatokat egy korábbi kutatás során a HungaroControlltól szerezte. Radaradatként két korábbi forgalmasnak számító nap (2012. július

29. és 2011. július 30.) adatait használhattuk kiegészítve néhány órányi forgalommal 2012. október 25-éről. Utóbbira azért volt szükség, mert a másik két nappal ellentétben ezekben az órákban nyitva volt néhány TRA<sup>5</sup>, így lehetőségünk volt ezeket is bevonni a modellbe.

A fogalmi szituációk komplexitását leíró tényezők kiválasztása a HungaroControl Zrt-nél operatív területen dolgozó szakemberek, valamint gyakorló irányítók és supervisorok megkérdezésével történt személyes interjúk, illetve az egyes tényezők munkaterhelésnövelő hatásának felmérésére szolgáló kérdőívek formájában. A kérdőívben az irányítóknak különböző tényezőket kellett értékelniük (1-től 5-ig terjedő skálán) aszerint, hogy mennyire játszik szerepet az adott tényező a munkaterhelésben, illetve mennyire gyakran változik jelentősen a tényező értéke. A felmérés alapján a 2. táblázatban felsorolt komplexitási tényezőket vettük figyelembe a neurális háló bemenő paramétereiként.

| Jelölés    | Jelentés                                                                                                                     |
|------------|------------------------------------------------------------------------------------------------------------------------------|
| AcCnt      | A szektorban tartózkodó járatok száma                                                                                        |
| AcCntCl    | A szektorban tartózkodó emelkedő járatok száma                                                                               |
| AcCntDesc  | A szektorban tartózkodó süllyedő járatok száma                                                                               |
| AcCntCl%   | A szektorban tartózkodó emelkedő járatok aránya a szektor összes járatához viszonyítva ( $\text{AcCntCl} / \text{AcCnt}$ )   |
| AcCntDesc% | A szektorban tartózkodó süllyedő járatok aránya a szektor összes járatához viszonyítva ( $\text{AcCntDesc} / \text{AcCnt}$ ) |
| Dens       | A szektorban tartózkodó járatokhoz tartozó átlagos sűrűség                                                                   |
| SpdDev     | A szektorban tartózkodó járatok sebességeinek szórása                                                                        |
| Div        | A szektorban tartózkodó járatok átlagos divergenciája                                                                        |
| Conv       | A szektorban tartózkodó járatok átlagos konvergenciája                                                                       |
| InsPos     | A szektorban tartózkodó járatok konvergenciájára vonatkozó érzéketlenség                                                     |
| InsNeg     | A szektorban tartózkodó járatok divergenciájára vonatkozó érzéketlenség                                                      |
| ConfNo     | A szektorban tartózkodó járatok között fennálló konfliktuslehetőségek összege                                                |
| IntsctNo   | A szektort keresztező szabványos útvonalak keresztezési pontjainak száma                                                     |
| Vol        | A szektor "térfogata" (szabványos magassági szintek száma X alapterület)                                                     |
| FreeFLNo   | A szektoron belüli szabad szabványos magassági szintek száma                                                                 |
| TRANo      | A szektoron belül (vagy szomszédos szektorban) nyitva lévő korlátozott légterek száma                                        |
| TMAcl      | A TMA ban tartózkodó emelkedő járatok száma                                                                                  |

2. táblázat A modellekben használt komplexitási tényezők

Ahhoz, hogy a komplexitási tényezőket felhasználhassuk valamilyen matematikai modellben, szükség van azok jelentésének egzakt megfogalmazására (pl. mit értünk pontosan konfliktus alatt történeti forgalmi adatok esetén) és azok számszerű kifejezésére.

A légijárművek radaradataiból (a szükséges atalakítások elvégzését követően) a következő információk nyerhetők ki: a járat földrajzi pozíciója (szélességi és hosszúsági koordináta), repülési magassága-, iránya-, sebessége. Az, hogy az egyes repülőgépek az adott pillanatban mely szektorban helyezkednek el, a földrajzi pozíciójukra és a szektorhatárok földrajzi elhelyezkedésére vonatkozó adatok alapján „point-in-polygon” algoritmus használatával határozható meg.

<sup>5</sup> Temporary Restricted Airspace, Időszakosan Korlátozott Légtér

Ezen adatokból (kiegészítve a szektorhatárok és szabványos útvonalak adataival) különféle számítások elvégzésével előállítható bármely, a 2. táblázatban bemutatott komplexitási tényező értéke. Az alábbiakban röviden bemutatjuk azon komplexitási tényező értékek meghatározását, melyek esetében nem triviális a tényező jelentése vagy a kiszámítás menete.

A forgalom geometriáját leíró komplexitási tényezők (Dens, Div, Conv, InsPos és InsNeg) kiszámítása a Delahaye és Puechmorel modelljében használt módon történt a 2. fejezetben ismertett képletek alapján. A tényezők teljes szektorra vonatkozó értékeit az egyes légi járművekre számított értékek összegeként kaptuk.

Ha a szektorkapacitás számítási modellt historikus adatokra alapozzuk – ahogyan azt jelen esetben is tesszük – akkor a forgalom konfliktusos jellegének számszerű leírása az egyik legnehezebb feladat. A probléma abból adódik, hogy a lehetséges konfliktusok döntő többségét az irányítók elhárítják még a tényleges konfliktus létrejötte előtt, így utólag nehéz eldönteni, hogy azért nem jött-e létre konfliktus, mert a forgalmi helyzet nem is hordozta magában annak lehetőségét vagy azért, mert az irányító időben észlelte és elhárította azt. Ezzel együtt lehetséges olyan számításokat végezni, melyekkel becslést adhatunk a forgalom konfliktusos jellegére. Az egyik ilyen lehetőség az, ha meghatározzuk egy adott forgalmi mintán belül azon járatpárok számát, melyek egymást keresztező útvonalon repülnek, útvonalaik metszéspontját pedig meghatározott rövid időn belül (pl. 15 perc), egymáshoz képest kis időkülönbséggel (pl. 5 perc) érik el (feltételezve, hogy sebességük, haladási irányuk és magasságuk addig nem változik). A neurális hálós modell paraméterezésekor erre az értékre a konfliktusok számaként hivatkozunk, valójában azonban nem a konfliktusok tényleges számát, hanem a forgalom konfliktusos jellegének mértékét mutatja.

A TRA-k számának meghatározásánál nem csak azokat érdemes figyelembe venni, amelyek a vizsgált szektor egyes részeit teszik korlátozottá, hanem azokat is, melyek a szomszédos szektorokat érintik, mivel ezek is hatással lehetnek az irányítók munkaterhelésére. A neurális hálós modell paraméterezése során a szomszédos szektorokat érintő különleges légterek száma 0,5-es szorzóval került be a TRANo tényezőbe.

Az előzőekben bemutatott számításokat a gyakorlatban egy .NET C# környezetben létrehozott program használatával hajtottuk végre. A számításokat minden forgalmi minta esetében elvégeztük a teljes légtérre, annak tíz elemi szektorára (WL, WM, WU, WH, WT, EL, EM, EU, EH, ET), valamint húsz, több elemi szektorból álló, de a teljes légtérre nem lefedő légtérblokkokra (W, WLM, WLMU, WLMUH, WMU, WMUH, WMUHT, WUH, WUHT, WHT, E, ELM, ELMU, ELMUH, EMU, EMUH, EMUHT, EUH, EUHT, EHT). A neurális hálós modellben külön háló segítségével vizsgáltuk a teljes légtérre, az elemi szektorokra és a légtérblokkokra vonatkozó adatokat, mivel előbbi kettő csak kétféle állapotot vehet fel (a légtérre nem lehet más szektorral összevonni, az elemi szektorokat pedig nem lehet osztani), míg utóbbiaknak három lehetséges állapotuk van.

Annak érdekében, hogy a modellben ne feltétlenül kelljen a vizsgált komplexitási tényezők számának megfelelő neuront létrehozni a hálók bemeneti rétegén, a neurális hálós számítások elvégzése előtt érdemes főkomponens elemzést végezni az adathalmazon és a komplexitási tényezők helyett főkomponenseket használni bemeneti változóként. A főkomponens számítást R programnyelv használatával végeztük.

## 4. A NEURÁLIS HÁLÓS MODELL EREDMÉNYEI

A neurális hálós modellhez a háló tervezése tanítása és validálása a Neural Planner Software által fejlesztett EasyNN-plus nevű szoftver 16.0a verziójának használatával történt a 3. főfejezetben bemutatott módon meghatározott adatok felhasználásával. A modellezés során alapvetően a Gianazza és Guittet által használt elveket követtük [10], de mivel más légtérre készítettük a modellt, mások voltak a figyelembe vett komplexitási tényezők. További különbség volt, hogy a hálók kimeneti változóinak meghatározásánál nem a valóságban használt, hanem a megkérdezett supervisorok által optimálisnak talált szektorállapotokat vettük figyelembe. A háló bemenetét a szektorokhoz tartozó komplexitási tényezők értékei alkották, a kimenetet pedig a szektorok állapota, ami lehet osztott („split”), önállóan használt („armed”) vagy más szektorral összevont („merged”). A háló tanítása és a tanulás közbeni validálás során a kimenetek értéke 1 volt, ha az adott szektor az adott időpontban (forgalmi szituációban) az adott állapotban volt és 0, ha valamely más állapotban. A kimenetek közül tehát mindig pontosan egynek az értéke volt 1, a többié pedig 0. Tekintve, hogy a kimeneteken a tanításhoz használt adatok esetében csak kétféle érték szerepelt, lehetséges lett volna a kimeneti változók típusát valós szám helyett logikai típusúra választani, ez azonban a háló tesztelésekor hátrányt jelentett volna. Ez a hátrány abban nyilvánul meg, hogy míg a logikai változó csak igaz vagy hamis értéket vehetne fel, addig a valós változó a logikai igaznak megfelelő 1 és a hamisnak megfelelő 0 közötti értékeket is felveheti, aminek köszönhetően részletesebb információval szolgálhat arról, mit érdemes csinálni az adott szektorral az adott szituációban, mivel nem csak az derül ki belőle, hogy mi lenne a szektor optimális állapota, hanem az is, hogy mekkora valószínűséggel lesz ez az optimális állapot. Ha például egy több elemi szektorból álló (de a teljes légtérrel nem lefedő) légtérblokkot vizsgálunk, ami mindhárom fenti állapotot felveheti, a háló kimenetén pedig a „split” értékre 0,9, az „armed”-ra 0,09, a „merged”-re pedig 0,01 adódik, akkor a légtérblokkot szinte biztosan szét kell osztani. Ha azonban az értékek rendre 0,45, 0,43, 0,12-re adódnak, akkor már nem biztos, hogy a szektorbontás a legjobb megoldás (mivel figyelembe kell venni az új szektor nyitásából származó munkaterhelés növekedést, a vizsgált időpontot követő időszakban várható forgalmat, a szomszédos szektorok állapotát stb.). A logikai típusú kimeneteken ugyanakkor mindkét esetben egy igaz („split”) és két hamis („armed” és „merged”) érték jelenne meg, ezért érdemesebb valós értékeket használni, még akkor is, ha ez a háló lassabb tanulásával jár.

Mind a hálók tanításához, mind a helyes működésük ellenőrzéséhez elengedhetetlen az egyes forgalmi szituációkhoz tartozó optimális (a munkaterhelést befolyásoló tényezők alapján meghatározott) szektorkonfiguráció ismerete. Ennek meghatározásában a HungaroControl két supervisoroként dolgozó munkatársa volt segítségünkre, akik irányítói tapasztalattal is rendelkeztek. A velük töltött idő alatt megmutattuk nekik a vizsgált forgalmi szituációk radarképeit, ők pedig elmondták, szerintük hány irányító tudná az egyes szituációkat biztonságosan és hatékonyan kezelni. Válaszaik többségét részletesen indokolták, ami az előzetes felmérésen és a kérdőíven (ld. 3. fejezet) felül további információt nyújtott a komplexitási tényezők irányítói megítélésével kapcsolatban. Így kerülhetett be a számításba vett tényezők közé a TMA-ban tartózkodó emelkedő járatok száma. A beszélgetés során fontos volt tudatni a supervisorokkal, hogy bár a vizsgált szituációk a valóságban 30 perces eltérésekkel követték egymást, a kutatás szempontjából egymástól teljesen független helyzetekként tekintünk rájuk. Ez azért volt lényeges, mert a

gyakorlatban sokszor előfordul, hogy a forgalmi helyzet szektorok összevonását indokolná, a supervisor azonban nem ad erre irányuló utasítást, mivel a jövőbeni forgalom becsült alakulása alapján az összevont szektort rövid időn (10–20 perc) belül újra szét kellene osztani.

## Teljes légtér

Mivel a főkomponens elemzés alapján a teljes légtér esetében négy főkomponens sajátértéke volt 1 felett, ezért az első hálónak négy bemenő változója volt, mivel pedig a teljes légtér nem vonható össze semmilyen más légtérrel, csak két kimenő változóra volt szükség (Split és Armed). Mivel a teljes légtér forgalma minden, a forgalomból vett mintában pontosan egyszer szerepel, ezért összesen 107 adatsor állt rendelkezésre, ami ezt írta le. A 107 forgalmi szituációból 65 adatait a háló tanításához, 21-et a tanulás közbeni validáláshoz, a maradék 21-et pedig a tanulás utáni teszteléshez (lekérdezéshez) használtuk fel. A három csoport mindegyikében hasonló arányban voltak megtalálhatóak a „Split” és „Armed” állapotú szektorok (tanítási adatok: 65-ből 8 „Armed” (12,3%), validálási adatok: 21-ből 3 „Armed” (14,3%), lekérdezési adatok: 21-ből 3 „Armed” (14,3%).

A teljes légtérrel modellező első háló bemeneti rétege tehát négy neuronból állt, a kimeneti réteg két neuronból, a rejtett réteg pedig 8 neuronból, amik 32 élen keresztül kapcsolódtak a bemeneti réteghez és 16 élel a kimeneti réteghez. A hálót ezen kezdeti feltételek beállítását követően az EasyNN-plus automatikusan tervezte meg. A háló tanítása alatt a szoftver 100 tanulási ciklusonként vizsgálta, hogy a 21 validálási rekordra a kimenő értékek hány százaléka van a kívánt értékhez képest  $\pm 5\%$ -os eltérésen belül, a tanulás befejezésének feltétele pedig az volt, hogy ez 100% legyen. A feltétel 200 tanulási ciklust, azaz a második validálási ciklust követően teljesült.

A betanított hálót először a lekérdezési adatokkal teszteltük, az eredmények pedig 21 esetben (18 „Split” és 3 „Armed”), azaz az esetek 100%-ában megfeleltek az elvárt értékeknek. A tanítási adatokkal történő teszteléskor hasonlóan pontos eredmények születtek: 65 esetből (57 „Split”, 8 „Armed”) 65-re az elvárt kimeneti érték adódott (pontosan vagy kerekítve).

Mivel a 15 főkomponens közül mindössze négy felhasználásával is maximális pontosságú eredmények adódtak, nem tűnt szükségesnek a bemeneten ennél több (például a korábban tervezett 7 vagy 15) főkomponens használata. Indokolt volt ugyanakkor a háló lehetséges további egyszerűsítésének érdekében megvizsgálni a működést ennél kevesebb bemeneti neuronnal. A vizsgálatot végre lehetett volna hajtani a főkomponensek számának folyamatos csökkentésével, de egyszerűbbnek tűnt előbb igénybe venni az EasyNN-plus azon funkcióját, mely az élekhez tartozó súlyszámok alapján megmutatja, melyik bemeneti tényező milyen mértékben befolyásolja a kimenetet. Ez alapján (a várakozásoknak megfelelően) PC1 volt a domináns bemeneti változó, amihez képest a többi három jelentősége elhanyagolható volt, vagyis a következő vizsgált háló már csak egy bemeneti neuront tartalmazott. A kimeneti rétegben továbbra is két neuron volt, míg a rejtett réteg a bemenetihez hasonlóan egyszerűsödött és mindössze két neuront tartalmazott. A lekérdezési adatokkal tesztelve az új hálót az előzőhöz hasonló, 100%-osan pontos eredmények adódtak, a tanítási adatokkal történő tesztelésnél pedig 65-ből csak egy esetben volt eltérés (98,5%-os pontosság).

A teljes légtérre vonatkozó eredmények a 3. táblázatban láthatóak. A táblázatban a validáláshoz használt adatok oszlopban Q jelöli a háló számára addig ismeretlen lekérdezési adatokat, T

pedig a tanításhoz használt adatokat. Az oszlop megnevezésében szereplő validálás szó itt a tanulást követő „manuális” validálást jelenti és nem a tanulási közben a háló által automatikusan végzett validálást.

| Főkomponensek száma | Validálási adatok | Összes állapot |        |         |       |        |         |
|---------------------|-------------------|----------------|--------|---------|-------|--------|---------|
|                     |                   | Összes         | Helyes | Helyes% |       |        |         |
| 1                   | Q                 | 21             | 21     | 100     |       |        |         |
| 1                   | T                 | 65             | 64     | 98,46   |       |        |         |
| 4                   | Q                 | 21             | 21     | 100     |       |        |         |
| 4                   | T                 | 65             | 65     | 100     |       |        |         |
|                     |                   | Split          |        |         | Armed |        |         |
|                     |                   | Összes         | Helyes | Helyes% | Össz  | Helyes | Helyes% |
| 1                   | Q                 | 18             | 18     | 100     | 3     | 3      | 100     |
| 1                   | T                 | 57             | 56     | 98,25   | 8     | 8      | 100     |
| 4                   | Q                 | 18             | 18     | 100     | 3     | 3      | 100     |
| 4                   | T                 | 57             | 57     | 100     | 8     | 8      | 100     |

3. táblázat A neurális hálós modell eredményei a teljes légtérre

Ahhoz, hogy ellenőrizhessük a főkomponensek bemeneti változóként való használatának létjogosultságát (bár ez a fenti eredmények alapján aligha kérdőjelezhető meg), valamint, hogy bemutassak egy lehetséges másik megközelítést, az EasyNN-plus segítségével terveztünk a teljes légtérhez egy harmadik hálót is, ami az eredeti változókat használja a bemeneti rétegében. Ez a háló a változók számának megfelelően 15 bemeneti neuronnal (itt legfeljebb az irányítók szubjektív véleménye alapján lehet előzetes képünk a változók súlyát illetően, ezért nem hagyhatunk el változókat), 30 rejtett neuronnal és 2 kimeneti neuronnal rendelkezett. A háló eredményeinek pontossága nem volt ugyan rossz (a lekérdezési adatok használatakor 21-ből 18 (86%), a tanításhoz használt adatoknál pedig 65-ből 63 (97%) helyes eredmény született), de ezek eléréséhez nagyobb bementi rétegre (azaz bonyolultabb hálóra) volt szükség, mint a főkomponensek használatakor.

## Elemi szektorok

A magyar légtérben jelenleg összesen 10 elemi szektor értelmezhető, vagyis 107 forgalmi mintavétel esetén 1070 olyan rekord adódik, aminek az adatai egy-egy elemi szektor forgalmának komplexitását írják le. A neurális hálós modellezéshez a teljes légtérnél látottakhoz hasonlóan itt is három csoportra kellett osztani az adatokat. A tanítási adatok közé 643 (44 „Armed”, 599 „Merged”), a validálási adatok közé 198 (14 „Armed”, 184 „Merged”), a lekérdezési adatok közé pedig 229 rekord került (16 „Armed”, 213 „Merged”). Megfigyelhető, hogy az „Armed” és a „Merged” szektorok egymáshoz viszonyított száma itt is közelítőleg egyenlő az egyes csoportokban.

Bemeneti változóként kezdetben 6 főkomponenssel érdemes a hálót megtervezni. Az első háló bemeneti rétegében 6, rejtett rétegében 12, kimeneti rétegében pedig 2 neuron volt. A rejtett réteg neuronjai a bemeneti réteghez 72, a kimeneti réteghez pedig 24 élen keresztül kapcsolódtak, azaz a hálót 96 súlyozó tényezővel lehetett leírni. A tanítás során itt is a teljes légtérre tervezett hálónál látott feltételnek kellett teljesülni a tanulási folyamat befejeződéséhez, azaz a validálási adatok 100%-a esetében az elvárthoz képest  $\pm 5\%$ -on belül kellett lenni a kimeneti értékeknek. A feltétel ezúttal is 200 tanulási ciklus után teljesült.

Amikor a tesztelés lekérdezési adatok segítségével történt, a 229 esetből 217 alkalommal (az esetek 94,8%-ában) volt egyezés az elvárt és a modell által szolgáltatott kimeneti értékek között. Az „Armed” állapotúra várt szektorokra 16-ból 11 esetben (68,8%), míg a „Merged” állapotúakra 213-ból 206-szor (96,7%) adódott helyes eredmény. Ennél érthető módon kis mértékben jobbák voltak az eredmények akkor, amikor a tesztelést a tanításhoz is használt adatokkal végeztük el. Ekkor az összes esetet tekintve 95,8%-ban, az „Armed” szektorok esetében 79,5%-ban, a „Merged” szektorok esetében pedig 97%-ban adódott a várakozásoknak megfelelő eredmény. Az összes esetet tekintve tehát mindkét tesztelés során 90% felett volt a pontosság, vagyis a modell ez alapján pontosnak tekinthető már 6 főkomponens használata mellett is, a teljes pontosságot azonban a jóval nagyobb elemszám miatt elsősorban a „Merged” szektorokra vonatkozó pontosság határozza meg és kicsi benne a szerepe az „Armed” szektoroknak. Utóbbiakra láthatóan pontatlanabb eredmények adódtak ez azonban valószínűleg nem a modell hibája, hanem a modell validálásához használt adatoké. Gyakran előfordul ugyanis, hogy egy elemi szektorhoz a szektor forgalma alapján nem lenne indokolt külön irányítókat rendelni, a szomszédos elemi szektorok, illetve légtérblokkok forgalma miatt azonban nem lehet az adott szektort egy másikkal sem összevonni. Vannak tehát olyan esetek, amikor egy elméletileg „Merged” állapotú szektor a valóságban „Armed” állapotú, mivel pedig a modell validálásához valóságos szektorállapotokat használtunk, az ilyenek rontják a modell pontosságát.

Bár a pontosság 6 főkomponens esetében is kielégítő, érdemes megvizsgálni, milyen mértékben lehet javítani további főkomponensek bevonásával. Legyen a következő háló bemeneti rétegében 10 neuron, amik az első 10 főkomponensnek felelnek meg. A rejtett réteget az eddigi logikát követve alkossa kétszer ennyi, azaz 20 neuron, a kimeneti réteg pedig álljon változatlanul 2 neuronból. A neuronok között ilyenkor összesen 240 súlyozott kapcsolat áll fenn. Az így létrehozott háló tanulásának kilépési feltétele továbbra sem változott az előzőekhez képest és ismét elég volt 200 ciklus a teljesüléséhez.

A háló tesztelése során mind a lekérdezési, mind a tanítási adatok használatakor kismértékű javulás mutatkozott a pontosságban. Előbbiekre az összes esetből 219-ben adódott jó eredmény (95,6%), amik közül 9 (56,25%) az „Armed” szektorokra, 210 (98,6%) pedig a „Merged” szektorokra vonatkozott. Utóbbiaknál az „Armed” szektorokra 36 (81,8%), a „Merged” szektorokra pedig 588 (98,2%) helyes eredmény adódott, vagyis az összes esetet tekintve 624-szer (97%-ban) felelt meg az eredmény a várakozásoknak. A tanítási adatoknál az értékek külön-külön is mind javultak, a lekérdezési adatoknál azonban az „Armed” szektoroknál pontatlanabbnak tűnik a modell, mint a korábbi, ami 6 főkomponenst használt. A csökkenés egyik lehetséges oka az „Armed” szektorokra vonatkozó fentebb ismertetett probléma, ami gyakrabban vezethet pontatlansághoz, ha a modell részletesebb számításokat végez, mivel ilyenkor könnyebben észlelheti az elméletileg nem megfelelő állapotú szektorokat. A másik lehetséges ok a modellben rejlő hiba, ami ugyan az EasyNN-plus elemzése szerint csak 1% körül van, de ez 229 elemre átlagosan 2–3 esetben vezet eltéréshez, amik közül ha 2 egy-egy „Armed” szektor esetében jut érvényre, akkor bekövetkezhet a fenti csökkenés (ahogyan az is lehetséges, hogy a korábbi jobb eredmény volt hibának köszönhető).

További enyhe javulás mutatkozott a pontosságban a harmadik neurális háló esetében, aminek a bemeneti rétegében mind a 17 főkomponensnek megfelelt egy-egy neuron. A háló belső rétege 34 neuronból állt, a neuronok közti kapcsolatok száma pedig 646 volt. A tanítás a korábbi

feltétel mellett a korábbi ciklusszámmal ment végbe. A lekérdezési adatok közül mindössze nyolcnál adódott a várakozással ellentétes kimeneti érték (vagyis az esetek 96,5%-ában helyes volt az eredmény). Ezek közül 7 az „Armed”, 1 pedig a „Merged” szektoroknál volt megfigyelhető, azaz előbbiekre a pontosság nem javult a korábbihoz képest, utóbbiakra azonban meghaladta a 99%-ot. A tanításhoz használt adatokkal való teszteléskor is hasonló volt a helyzet: az „Armed” szektorokra továbbra is 36 helyes érték adódott (81,8%), míg a „Merged” szektorokra javult a pontosság (593 helyes érték, azaz 99%), aminek következtében az összes esetre vonatkozóan is pontosabbak lettek az eredmények (629 pontos eredmény, 97,8%). Az elemi szektorokra adódó eredményeket a 4. táblázat szemlélteti.

4. táblázat A neurális hálós modell eredményei elemi szektorokra

## Légtérblokkok

A légtérblokkok vizsgálata a teljes légtérhez és az elemi szektorokhoz képest nagyobb volumenű feladat volt részben, mert az ott látottaknál több volt a bemenő adat, részben pedig mert a kimeneti réteget alkotó három neuron miatt a neurális hálók felépítése bonyolultabbá, tanulásuk pedig lassúbbá vált. A komplexitási tényezők kiszámítása után minden forgalmi szituációhoz 20 olyan rekord tartozott, ami egy-egy légtérblokknak felelt meg, mivel a W és az E szektorban is 10-10 légtérblokk hozható létre különféle magassági szektorbontások által, melyek a következők: W, WLM, WLMU, WLMUH, WMU, WMUH, WMUHT, WUH, WUHT, WHT, E, ELM, ELMU, ELMUH, EMU, EMUH, EMUHT, EUH, EUHT, EHT. A 107 forgalmi szituációnak köszönhetően tehát 2140 légtérblokkra vonatkozó rekord állt rendelkezésre, amelyek közül 1323-at a hálók tanításához, 406-ot a tanulás közbeni validáláshoz, 411-et pedig a betanított háló teszteléséhez használtunk.

A légtérblokkokhoz kapcsolódó első hálóban hat főkomponenst vettünk figyelembe (mivel ennyinek a sajátértéke volt 1-nél nagyobb), ezért a bemeneti réteg hat neuronból állt. A rejtett réteg neuronszámának megválasztásakor továbbra is a korábban látott elvet követtük, azaz a bemeneti réteg neuronszámának kétszeresét (12) használtuk. A kimeneti réteget három neuron alkotta, mivel a légtérblokkokat egyaránt lehetséges szétszítani és összevonni más szektorokkal, vagyis lehetnek „Split”, „Armed” és „Merged” állapotúak is. A háló tanításakor a befejezés feltétele változatlanul a validáláshoz használt adatokra adódó eredmények várakozáshoz képest  $\pm 5\%$ -on belül kerülése volt. A feltétel nem teljesült azon a 16 200 s-os (4,5 órás) időintervallumon belül, ami a tanulás maximális időtartamaként meg volt adva. A tanulás befejezésekor az EasyNN-plus statisztikai adatai szerint a validálási értékek 57,11%-a volt a megadott határon belül, ami rossz aránynak mondható. Az ez alapján valószínűsíthető megbízhatatlan működés ellenére elvégeztük a háló tesztelését lekérdezési adatokkal és a tanításhoz használt adatokkal is.

A 411 lekérdezési adatból 136-nál volt az elvárt kimeneti érték „Split”, 44-nél „Armed”, 231-nél pedig „Merged”. A „Split”-re várt kimenetek közül 93-ra (68,4%) adódott helyes eredmény, a „Merged”-re vártaknál 134-re (58%), az „Armed”-ra vártaknál pedig mindössze 2-re (4,5 %). Az összes érték közül 229 (55,7 %) volt helyes. A tanítási adatokkal való teszteléskor valamivel nagyobb pontosság volt tapasztalható. Itt az összes (1323) esetből 949-re (71,7%), a „Split” esetekből 398-ra (88,2%), a „Merged” esetekből 538-ra (77%), az „Armed” esetekből pedig 13-ra (7,5%) adódott pontos eredmény.

A szemmel láthatóan alacsony megbízhatóság miatt indokoltnak láttuk a figyelembe vett főkomponensek számának növelését a maximális 17-re. A 17 főkomponenssel működő háló rejtett rétege 34 neuront tartalmazott, a tanulás befejezésének feltétele változatlan volt és akárcsak az előző esetben, itt sem teljesült a megadott maximális tanulási időn (23 400 s) belül. Az így kapott eredmények csekély mértékű javulást mutattak a 6 főkomponenst használó háló eredményeihez képest, de az „Armed” szektorokhoz tartozó eredmények pontossága továbbra is nagyon alacsony volt (lekérdezési adatokra 44-ből 2 esetben (4,5%), tanításhoz használt adatokra 174-ből 14 esetben (8%) született helyes eredmény). A légtérblokkokhoz tartozó eredmények az 5. táblázatban láthatóak.

| Főkomponensek száma | Validálási adatok | Összes állapot |        |         | Split  |        |         |
|---------------------|-------------------|----------------|--------|---------|--------|--------|---------|
|                     |                   | Összes         | Helyes | Helyes% | Összes | Helyes | Helyes% |
| 6                   | Q                 | 411            | 229    | 55,72   | 136    | 93     | 68,38   |
| 6                   | T                 | 1323           | 949    | 71,73   | 451    | 398    | 88,25   |
| 17                  | Q                 | 411            | 235    | 57,18   | 136    | 95     | 69,85   |
| 17                  | T                 | 1323           | 955    | 72,18   | 451    | 399    | 88,47   |
|                     |                   | Armed          |        |         | Merged |        |         |
|                     |                   | Összes         | Helyes | Helyes% | Összes | Helyes | Helyes% |
| 6                   | Q                 | 44             | 2      | 4,55    | 231    | 134    | 58,01   |
| 6                   | T                 | 174            | 13     | 7,47    | 698    | 538    | 77,08   |
| 17                  | Q                 | 44             | 2      | 4,55    | 231    | 138    | 59,74   |
| 17                  | T                 | 174            | 14     | 8,05    | 698    | 542    | 77,65   |

5. táblázat A neurális hálós modell eredményei légtérblokkokra

A légtérblokkokhoz tervezett hálók által szolgáltatott eredmények megbízhatatlanságának több oka is lehet. Az, hogy az „Armed” szektorokra vonatkozóan pontatlanabbak az eredmények, mint a másik két szektorállapokra önmagában nem számít rendkívüli jelenségnek. Ugyanez figyelhető meg Gianazza és Guittet kutatásában is, akik azzal indokolják a jelenséget, hogy a hálónak ilyen esetben két, állapotok közti határvonalhoz viszonyítva kellene pontosan meghatároznia a szektorállapotot, míg a másik két esetben csak egyhez [10]. Ez azonban önmagában még nem ad magyarázatot az „Armed” értékek 10% alatti pontosságára. A további lehetséges okok egyike a háló tervezéséhez használt szoftver viszonylagos fejletlensége, ami nem teszi lehetővé a háló működését meghatározó logika (aktiváló és átviteli függvény, hálóegyenlet) módosítását. Elképzelhető tehát, hogy egy magasabb funkcionalitású hálótervező szoftverrel a függvények megfelelő megválasztása által nagyobb pontosság lenne elérhető.

Problémát jelenthet az is, hogy a különböző légtérblokkok felépítése nagyban eltérhet egymástól, a legkisebbek ugyanis két szektorból állnak, míg a legnagyobbak ötből. Ennek kiküszöbölésére két lehetőség kínálkozik. Az egyik az, hogy a [10]-ben bemutatott példát követve a szektorgeometriát elsődlegesen leíró komplexitási tényezőt (jelen esetben a szektor kiterjedését) nem vesszük figyelembe a főkomponens elemzésnél, hanem megtartjuk önálló változóként és így helyezzük rá a háló bemeneti rétegére, ezáltal nagyobb súlyt adva a szektorgeometriának a modellben. A másik lehetőség a légtérblokkok halmazának felbontása kisebb, kevésbé eltérő felépítésű légtérblokkokból álló csoportokra. Utóbbi lehetőség alkalmazhatóságának vizsgálata érdekében megvizsgáltuk a modell működését úgy, hogy az összes légtérblokk helyett csak a W és E légtérblokk (azaz a teljes nyugati és keleti szektort) adatait használtuk bemeneti változóként. A módosított modellhez természetesen szükség volt egy újabb főkomponens elemzésre is, melyben csak a két vizsgált légtérblokk változói szerepeltek.

Az elemzés alapján 5 főkomponens sajátértéke volt 1 felett, így az első háló bemeneti rétegét 5 neuron alkotta, de hasonlóan a többi háléhoz, ezt is teszteltük 17 főkomponenssel is. A hálók általános paraméterei megegyeztek a korábban használtakkal és ezáltal teljesült a tanulás befejezésének feltétele is, igaz, ehhez a 17 főkomponenses háló esetében több, mint 3000 tanulási ciklusra volt szükség (az 5 főkomponenses hálóra már 400 ciklus után teljesült). A háló tanításához 132, a validálásához 40, a betanított háló teszteléséhez pedig 42 forgalmi szituáció adatait használtuk fel (továbbá ezt a hálót is teszteltük a tanításhoz használt adatokkal is). Az 5 főkomponenses hálóra a 42 lekérdezési adatból 34-nél (81%) helyes eredmény adódott. Ezek közül 22 a „Split” szektorokra (91,7%), 8 az „Armed” szektorokra (66,7%), 4 pedig a „Merged” szektorokra (66,7%) állt elő. Ennél is magasabb volt a pontosság a tanítási adatokkal való teszteléskor. Itt a 132 esetből 129-szer (97,7%) lett jó az eredmény, szektortípusonkénti bontásban pedig a „Split” és a „Merged” szektorokra 100%-os pontosság adódott, míg az „Armed” szektorokra 94,7% (38-ból 36). A várakozásoknak megfelelően tovább javult a pontosság 17 főkomponens bevonása esetén. A lekérdezési adatoknál mindössze egy „Armed” és egy „Merged” szektor esetében volt hibás az eredmény, azaz 42 esetből 40-szer (95,2%) pontos volt. A tanítási adatok esetében továbbra is 100%-os eredmény adódott a „Split” és „Merged” szektorokra, az „Armed” szektorokra pedig 92,1% (38-ból 35). A csak a W és E légtérblökhöz tartozó eredményeket a 6. táblázat mutatja


| Főkomponensek száma | Validálási adatok | Összes állapot |        |         | Split  |        |         |
|---------------------|-------------------|----------------|--------|---------|--------|--------|---------|
|                     |                   | Összes         | Helyes | Helyes% | Összes | Helyes | Helyes% |
| 5                   | Q                 | 42             | 34     | 80,95   | 24     | 22     | 91,67   |
| 5                   | T                 | 132            | 130    | 98,48   | 77     | 77     | 100     |
| 17                  | Q                 | 42             | 40     | 95,24   | 24     | 24     | 100     |
| 17                  | T                 | 132            | 129    | 97,73   | 77     | 77     | 100     |
|                     |                   | Armed          |        |         | Merged |        |         |
|                     |                   | Összes         | Helyes | Helyes% | Összes | Helyes | Helyes% |
| 5                   | Q                 | 12             | 8      | 66,67   | 6      | 4      | 66,67   |
| 5                   | T                 | 38             | 36     | 94,74   | 17     | 17     | 100     |
| 17                  | Q                 | 12             | 11     | 91,67   | 6      | 5      | 83,33   |
| 17                  | T                 | 38             | 35     | 92,11   | 17     | 17     | 100     |

6. táblázat A neurális hálós modell eredményei a W és E légtérblökhöz

## 5. A FORGALMI GEOMETRIÁN ALAPULÓ MODELL EREDMÉNYEI


A forgalom geometriáján alapuló modell nem más, mint a forgalom geometriai eredetű komplexitásának egyfajta grafikus megjelenítése. A modell bemenő változóiként egy-egy forgalmi szituáció sűrűség, konvergencia és érzéketlenség értékei szolgálnak, de a neurális háló paraméterezésénél látottakkal ellentétben itt a teljes szituációra vonatkozó értékek számítanak és nem azok egy repülőgépre vonatkoztatott átlaga. Erre azért van szükség, mert a modell nem kezeli külön a repülőgépek számát, így azonban látens módon ez a tényező is bevihető a modellbe. A nagyobb szemléletesség érdekében a bemenő változók értékét nem egy, hanem több egymást követő időpillanatra érdemes meghatározni, majd az egymást követő állapotokat egy ábrában megjeleníteni. A különböző időpontokban adódó értékeket (az elsőt kivéve) nem a repülőgépek valós helyzete és sebessége határozza meg, hanem az első pillanatban felvett pozíció, sebesség

és haladási irány alapján állandó sebességet és irányt feltételezve extrapolálva kerülnek kiszámításra. Az értékek kiszámítása során a tapasztalatok azt mutatták, hogy a teljes légtérre vonatkozóan körülbelül 3 perc elteltével már minden szituációban folyamatos csökkenést mutat a konvergencia és az érzéketlenség is, vagyis ennél hosszabb intervallumot nem érdemes választani a vizsgálathoz. Fontos továbbá megjegyezni, hogy a modellben nem vesszük figyelembe a vizsgált idő alatt a légtérbe belépő járatokat, ezzel magyarázható, hogy egy ponton túl minden szituációban csökkenni kezd a konvergencia, az érzéketlenség és a sűrűség is (a fenti feltételek mellett egy idő után minden forgalmi helyzet széttartóvá válik. Az 1., 2. és 3. ábra egy aránylag nagy forgalmú szituációra (2012. 07. 29. 10:30) mutatja be a modell használatát. Az 1. és a 2. ábrán Delahaye és Puechmorel ötlete alapján [9] 3 dimenziós (sűrűség-konvergencia-érzéketlenség) koordináta-rendszerben látható a forgalom alakulása, míg a 3. ábra saját szerkesztés, ami a forgalmat leíró egyes pontok origótól mért távolságának időbeli alakulását mutatja. Az origótól mért távolság számításánál az egyes tengelyekhez tartozó tényezőknek nem a valós értékét vettük figyelembe, hanem annak egy maximálisnak tekintett értékkel történő osztás után előálló normált értékét. A maximálisnak tekintett érték a sűrűségnél 1000, a konvergenciánál 160 000, az érzéketlenségnél pedig 750 volt.




1. ábra Forgalmi komplexitáson alapuló modell használata általános forgalmi szituációra (3D grafikon)<sup>6</sup>

<sup>6</sup> forrás: saját szerkesztés Maple 15 használatával [9] alapján




2. ábra Forgalmi komplexitáson alapuló modell használata általános forgalmi szituációra (sűrűség-konvergencia és sűrűség-érzékenység grafikon)<sup>7</sup>



3. ábra Forgalmi komplexitáson alapuló modell használata általános forgalmi szituációra (origótól számított normált távolság alakulása az idő függvényében; az időértékek másodpercben vannak megadva)

Az ábrák szemléletesek, de nem derül ki belőlük, mutatnak-e a modell eredményei összefüggést az adott szituációhoz tartozó optimális szektorszámmal, azaz a munkaterhelés mértékével. Ennek kiderítésére vizsgáljuk meg az eredményeket egy-egy szituációra, melyek 1, 2, 3, 4, 5, illetve 6 szektort igényelnek (4. ábra).


<sup>7</sup> forrás: saját szerkesztés Maple 15 használatával [9] alapján



4. ábra Forgalmi komplexitáson alapuló modell eredményei különböző szektorszámot igénylő forgalmi szituációkra<sup>8</sup>

Az 5. ábrán a fenti 6 szituáció képe látható egy ábrába szerkesztve (az egyes görbék a korábbi-  
val azonos színnel vannak jelölve).


<sup>8</sup> forrás: saját szerkesztés Maple 15 használatával [9] alapján



5. ábra 1, 2, 3, 4, 5 és 6 szektort igénylő forgalom sűrűség-konvergencia-érzékletlenség diagramja<sup>9</sup>


Az ábrán jól látható, hogy az egyes szituációknak megfelelő görbék az adott helyzethez tartozó optimális szektorszám növekedésével fokozatosan egyre távolabb helyezkednek el az origótól. Ez alapján úgy tűnik, a forgalom komplexitásának ilyen módon történő leírása jól reprezentálja a munkaterhelés mértékét és a koordinátarendszerben megfelelően elhelyezett ellipszoid felületekkel lehetne jelölni a szektornyitáshoz és –záráshoz tartozó értékhármasokat. Ne feledkezzünk azonban meg arról, hogy a munkaterhelés elsődleges meghatározója a járatok száma, ami a geometriai alapú modell által szolgáltatott eredményekben is nagy szerepet játszik és a sűrűség, a konvergencia és az érzékletlenség egyidejű növekedését ugyanúgy okozhatja a növekvő repülőgépszám, mint a forgalom komplexebbé válása. Meg kell tehát vizsgálni azt is, hogyan viselkedik a modell olyan szituációkban, amikor a járatok száma (közel) azonos, de a supervisorok szerinti optimális szektorszám különböző. Erre szolgáltatt példát a 6. és 7. ábra. A 6. ábra két, egyaránt 34 repülőgépes szituációt mutat. Mindkét forgalmi helyzet 2011. 07. 30-áról való, de az egyik 19:00-kor állt fenn, amikor a supervisorok szerint 3 szektor volt az optimális, a másik pedig 07:30-kor, amikor 4. A 7. ábra a 2012. 07. 29. 14:30 körül és a 2011. 07. 30. 12:00 körül fennálló forgalmi helyzetet hasonlítja össze. Mindkét esetben 46 repülőgép volt a légtérben, de míg előbbihez 4, utóbbihoz 5 szektor volt ideális.

<sup>9</sup> forrás: saját szerkesztés Maple 15 használatával [9] alapján



6. ábra Azonos repülőgépszámú (34), de különböző (19:00: 3, 07:30: 4) szektorszámot igénylő forgalom sűrűség-konvergencia, sűrűség-érzékenység és idő-origótól mért távolság diagramja<sup>10</sup>

<sup>10</sup> forrás: saját szerkesztés Maple 15 használatával [9] alapján



7. ábra Azonos repülőgépszámú (46), de különböző (14:30: 4, 12:00: 5) szektorszámot igénylő forgalom sűrűség-konvergencia, sűrűség-érzékletlenség és idő-origótól mért távolság diagramja<sup>11</sup>

Az első esetben a kétdimenziós ábrázolásból ugyan nem egyértelmű, hogy a több szektort igénylő szituáció geometriai komplexitása a nagyobb, de az origótól mért távolságot mutató ábra arra utal, hogy a nagyobb geometriai komplexitáshoz tartozik több szektor (azaz magasabb munkaterhelés). A második esetben ugyanakkor egyértelműen a kisebb szektorszámú szituáció forgalmi geometrián alapuló komplexitása a nagyobb. Ennek legvalószínűbb magyarázata az, hogy a modell által figyelembe nem vett komplexitási tényezők (például a magasságot váltó járatok száma, ami a 12:00-as esetben 18 volt, a 14:30-asban pedig csak 13) miatt a supervisorok a nagyobb geometriai komplexitás ellenére is kevesebb szektort tartottak optimálisnak 14:30-ra, mint 12:00-ra. Az eddigiek alapján tehát kijelenthető, hogy a modell önállóan nem alkalmas az optimális szektorszám meghatározására, legalábbis a magyar légtérben nem, mivel itt az irányítók munkaterhelésében jelentős szerepet játszanak olyan tényezők, melyekkel a modell nem foglalkozik. Ezzel együtt elképzelhetőnek tartjuk a használatát egyfajta vizuális segédeszközként supervisorok számára, aminek használatával a várható forgalom komplexitásának egy részét figyelemmel tudnák kísérni.

<sup>11</sup> forrás: saját szerkesztés Maple 15 használatával [9] alapján

## 6. ÖSSZEFOGLALÁS

A neurális hálós modell megbízhatóan működik, ha a teljes légteret vagy az elemi szektorokat modellezzük vele, azaz ha olyan szektorokra használjuk, melyeknek csak két lehetséges állapota van. Meglehetősen pontatlan ugyanakkor a három lehetséges állapottal rendelkező légtérblokkokra. A pontatlanság igazoltan csökkenthető, ha a modellt az összes légtérblokk helyett csak azoknak egy szektorgeometriai szempontból aránylag homogén részhalmazára készítjük el, ezzel azonban azt érzük el, hogy a légtérben létrehozható összes szektorra csak nagy mennyiségű háló együttes használatával lesz megbízható a modell. A probléma megoldására más lehetőségek is kínálkoznak, melyek alkalmazhatóságát jelen cikkben nem vizsgáltuk, a kutatás esetleges folytatása során azonban indokoltnak tartjuk a figyelembe vételüket. Ezek egyike a jelenleg használatnál professzionálisabb neurális-háló tervező szoftver beszerzése és alkalmazása a kutatásban szereplő adatokra. A másik lehetőség a szektorgeometria jelenleginél nagyobb súllyal történő bevonása a modellbe úgy, hogy további, ehhez kapcsolódó komplexitási tényezőket számítunk ki (pl. járatok szektorhatártól mért távolsága) vagy úgy, hogy a szektorgeometriai jellemzőket nem vonjuk be a főkomponens elemzésbe, hanem önálló bemenő változóként használjuk.

A forgalmi geometrián alapuló modell önmagában nem alkalmas a munkaterhelés, illetve az optimális szektorszám meghatározására, mivel túl sok olyan tényezőt hagy figyelmen kívül, melyek a magyar légtér viszonyai között nagy befolyással vannak az irányítók munkaterhelésére. Ezzel együtt a komplexitási tényezők egy részét jól összefoglalva és látványosan lehet a segítségével megjeleníteni, ami miatt elképzelhetőnek tartjuk a használatát egyfajta vizuális döntéstámogató segédeszközként supervisorok számára.

### KÖSZÖNETNYILVÁNÍTÁS

A szerzők köszönetüket fejezik ki a HungaroControl Magyar Légiforgalmi Szolgálat Zrt.-nek és a Magyar Közlekedési Mérnökképzésért Alapítványnak (AMKMA) a jelen cikkben bemutatott kutatómunka támogatásáért.

---

**FELHASZNÁLT IRODALOM**

- [1] ROHÁCS JÓZSEF – HORVÁTH ZSOLT CSABA A repülésbiztonság problémája és fejlesztési elvei. Repüléstudományi Közlemények, 2013/3, pp. 39-55
- [2] SCHVÁB ZOLTÁN Összehangolt biztonság a légiforgalmi irányításban. Közlekedéstudományi Szemle, 2013/63(5), pp. 45-49
- [3] KURUCZ MIHÁLY A repülésbiztonság megteremtésének feltételrendszere a légi navigációs szolgálatoknál. Közlekedéstudományi Szemle, 2013/63(5), pp. 51-56
- [4] SZABÓ GÉZA – SZABÓ KRISZTIÁN – ZERÉNYI ROLAND Safety Management Systems in Transportation: Aims and Solutions. Periodica Polytechnica – Transportation Engineering, 2004/32(1-2), pp. 123-134
- [5] PAWLAK, W. S. – BRINTON, C. S. – CROUCH, K. – LANCASTER, K. M. A framework for the evaluation of air traffic control complexity, AIAA national Conference, 1996
- [6] GROSSBERG, M. Relation of sector complexity to operational errors. Quarterly report of the Federal Aviation Administration's Office of Air Traffic Evaluations and Analysis, 1989
- [7] STAGER, P. – HAMELUCK, D. Ergonomics in air traffic control, Ergonomics 1990/33(4), pp. 493-499
- [8] RODGERS, M. D. – MOGFORD, R. H. – MOGFORD, L. S. The relationship of sector characteristics to operational errors, DOT/FAA/AM-98/14, 1998
- [9] DELAHAYE, D. – PUECHMOREL, S. Air traffic complexity: towards intrinsic metrics, Proceedings of the third USA/Europe Air Traffic Management R & D Seminar, 2000
- [10] GIANAZZA, D. – GUITTET, K. Evaluation of air traffic complexity metrics using neural networks and sector status, 2nd International Conference on Research in Air Transportation, 2006
- [11] FLYNN, G. M. – BENKOUAR, A. – CHRISTIEN, R. Adaptation of Workload Model by Optimisation Algorithms and Sector Capacity Assessment, EEC Note No. 07/05, 2005
- [12] KOPARDEKAR, P. – MAGYARITS, S. Measurement and prediction of dynamic density, The 5th USA/Europe Air Traffic Management R & D Seminar, 2003