

# Mesterséges intelligencián alapuló eljárások alkalmazása infokommunikációs hálózatokban

FARKAS KÁROLY

BME VIK Hálózati Rendszerek és Szolgáltatások Tanszék / Gloster Networks Kft.  
farkas.karoly@vik.bme.hu / farkas.karoly@gloster.hu

Kulcsszavak: mesterséges intelligencia, SDN, NFV, VNF, hálózatmenedzsment, anomáliadetekció, ASEP

A mesterséges intelligencia robbanásszerű fejlődése szinte minden területre hatást gyakorol, így ez alól az infokommunikációs hálózatok sem jelentenek kivételt. A gépi tanuláson alapuló eljárások jelentős segítséget nyújthatnak az egyre komplexebb feladatok megoldásában, illetve bizonyos funkciók automatizálásában, ezáltal hatékonyabbá téve a hálózatok tervezését, kialakítását, működtetését és felügyeletét. A cikkben röviden áttekintjük az MI-alapú eljárások alkalmazásának főbb lehetőségeit az infokommunikációs hálózatok menedzselése kapcsán, valamint bepillantást nyújtunk a hálózati anomáliadetekció terén elért saját kutatási eredményeinkbe.

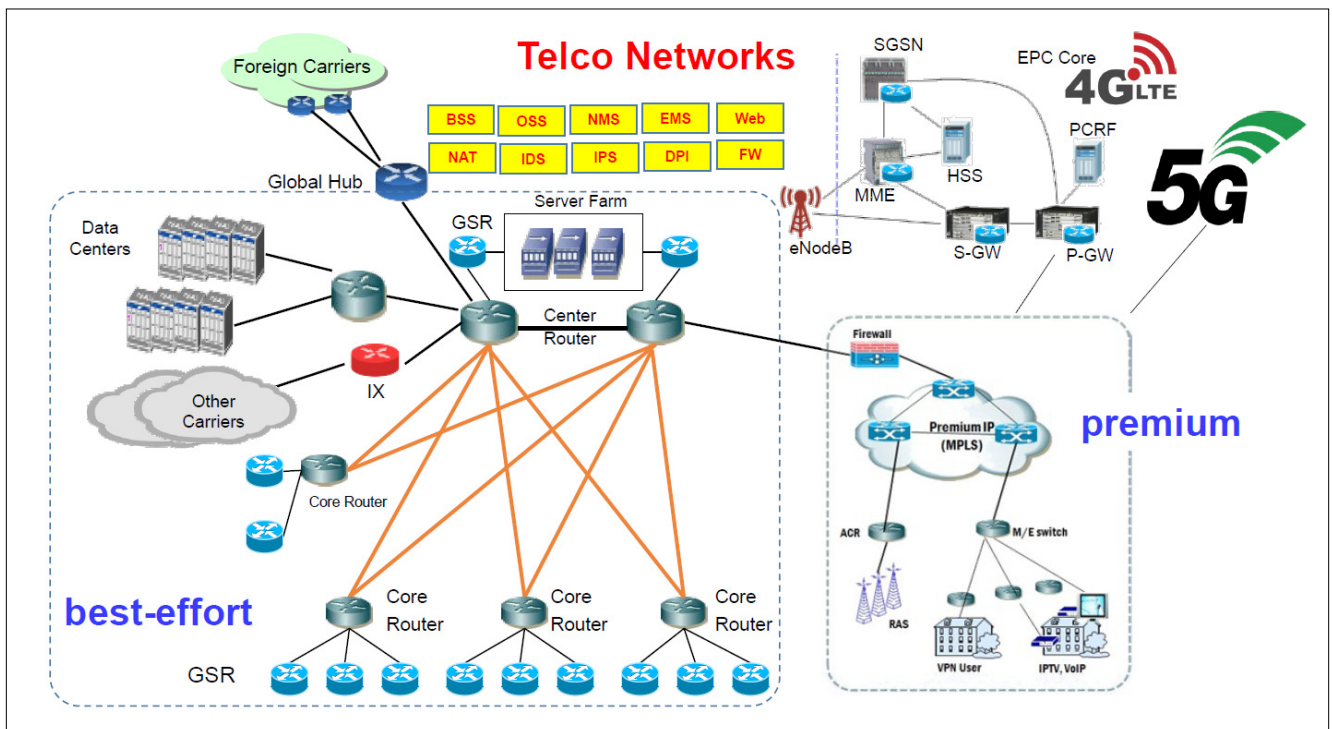
## 1. Bevezetés

Az infokommunikációs hálózatok hagyományosan rengeteg, adott funkcióra dedikált eszközből (pl. útvonalválasztók, kapcsolók, tűzfalak, mobilhálózati bázisállomások, tornyok és antennák) épülnek fel, ahogyan ezt a 1. ábra szemlélteti. Ez a statikus, rugalmatlan szerkezet nehézkes és költségessé teszi ezen hálózatok üzemeltetését az operátorok számára. Ebben lényeges változást az egyre nagyobb teret nyerő, szoftveralapon megvaló-

sított virtualizált hálózatok és szolgáltatások használata és elterjedése hozhat. Azonban az ilyen SDN<sup>1</sup>-/NFV<sup>2</sup>- és VNF<sup>3</sup>- [2,3,4] alapú megoldások új kihívások elé is állítják az operátorokat az így kialakított hálózat menedzselésének megnövekvő komplexitása, vagy a gyors és flexibilis átkonfigurálhatóságból adódó hibázási lehetőségek tekintetében.

Ezen kihívások hatékony kezelésére a mesterséges intelligencián (MI) [5] alapuló eljárások robbanásszerű fejlődése szolgálhat. Az MI-kutatások felgyorsulása szín-

1. ábra Infokommunikációs hálózatok hagyományos felépítése [1]



1 Software Defined Networking – Szoftveralapú hálózatok

2 Network Functions Virtualization – Hálózati funkciók virtualizálása

3 Virtualized Network Function – Virtualizált hálózati funkció

te minden területre hatást gyakorol; a képfelismeréstől kezdve a nagy számosságú adathalmazok kezelésén és feldolgozásán keresztül a komplex feladatok automatizálásáig az alkalmazási lehetőségek tárháza szinte végtelen. Nem meglepő, hogy az infokommunikációs hálózatok tervezése, telepítése, működtetése és monitorozása kapcsán is egyre több MI-alapú eljárással találkozhatunk.

E cikkben ismertetjük a mesterséges intelligencia használatának néhány, a tématerület szempontjából releváns scenárióját. Megnézzük, hogyan tudják támogatni az MI-alapú eljárások többek között a hálózatmenedzsmentet, azon belül is az NFV életciklus-menedzsmentet, a Traffic Engineering<sup>4</sup>-et vagy a hálózati anomáliadetekciót. Ez utóbbi alkalmazási terület kapcsán rövid bepillantást nyújtunk a kutatócsapatunk által elért kutatási eredményekbe is. A továbbiakban először áttekintjük az SDN/NFV- és VNF-alapú hálózati megoldások és szolgáltatások által kínált előnyöket, valamint rendszerezük a mesterséges intelligenciával kapcsolatban leggyakrabban használt és népszerű fogalmakat. Ezt követően ismertetjük az MI fentebb említett releváns alkalmazási scenárióit, közülük az egyiket saját kutatási eredményekkel illusztrálva, végül rövid összeggzéssel zárjuk a témát.

## 2. A hálózatokban megjelenő korszerű paradigmák

Az infokommunikációs hálózatokban tradicionálisan alkalmazott, adott funkciókra dedikált eszközökből és eljárásokból álló megközelítést egyre inkább kezdi felváltani a szoftveralapon megvalósított és általános hardvereken futtatható, könnyen migrálható virtualizált funkciókból felépített SDN/NFV-hálózatok és VNF-alapú szolgáltatások használata. Ráadásul a mesterséges intelligencián alapuló eljárások alkalmazása az utóbbi időben robbanás-

szerűen terjed szinte minden területen, így az infokommunikációs hálózatokban is. Az alábbiakban röviden áttekintjük ezen paradigmák legfontosabb jellemzőit.

### 2.1. SDN


A hálózati eszközök hagyományosan egy monolitikus, zárt egységet alkotnak, amelyet telepítésük és konfigurálásuk után csak egy adott célra – például útvonalválasztásra vagy lokális kommunikációban adatcsomagok gyors továbbítására – lehet használni, alapvető működésüket nem lehet megváltoztatni. Ráadásul minden hálózati eszközön külön kell implementálni az adat-, vezérlő- és menedzsmentsíket.

Az SDN- [2] alapú megközelítés ezzel szemben az infokommunikációs hálózatok működését szoftveres alapkra helyezi, lehetővé téve a kialakított funkciók megváltoztatását, átprogramozását. Az adat- és a vezérlősík szétválasztásra kerül, így a vezérlési funkciók és a döntési intelligencia kikerül az eszközökből egy központi vezérlőbe, mely eszközök ezáltal egyszerű csomagtovábbító komponensekké válnak (2. ábra).

Itt van például az SDN-hálózatokban előszeretettel alkalmazott OpenFlow protokoll [6], amelynél egy központi controlleralkalmazás vezérli az útvonalválasztók működését, de a tényleges csomagtovábbítást továbbra is a rendszerint adott funkcióra optimalizált hardverrel ellátott útvonalválasztó végzi. Ezáltal maga az útvonalválasztó eszköz kialakítása egyszerűbb és olcsóbb, a központi vezérlő szoftverben pedig gyorsabban és hatékonyabban lehet az újonnan megjelenő megoldásokat és eljárásokat bevezetni.

Ezen megközelítés előnye még a programozhatóság, gyorsaság, rugalmasság mellett, hogy jóval egyszerűbbé válik gyártófüggetlen hálózatok kialakítása, illetve jelentős megtakarítás érhető el mind a beruházási (CAPEX<sup>5</sup>), mind a működési (OPEX<sup>6</sup>) költségek tekintetében.

2. ábra  
SDN-alapú hálózat [1]



4 Traffic Engineering – Hálózati forgalom elhelyezése, elvezetése

5 Capital expenditure – Tőkebefektetés, beruházási költség

6 Operational expenditure – Működési költség





A VNF-ek megvalósíthatók önálló entitásként rendszerint meglévő hálózati paradigmák használatával. Azonban az SDN-alapú megoldások számos előnyt nyújtanak az NFV-környezetek kialakításához, különösen akkor, ha nagy kiterjedésű, földrajzilag különböző elhelyezkedésű NFV-infrastruktúrát kell kezelni és összehangolni. Ezért nem meglepő, hogy számos olyan szolgáltatói platform létezik, amelyik egységes ökoszisztémába foglalja az SDN- és NFV-alapú megoldásokat.

A VNF-ek segítségével létrehozott hálózati szolgáltatások legfőbb előnyei a gyors és rugalmas kialakítás mellett a központosított menedzsment; optimális konfiguráció kialakítása a hálózat aktuális állapotának függvényében; gyors reagálás a hálózati környezet változásaira; valamint gyártófüggetlen infrastruktúra kialakításának lehetősége.

Azonban az előnyök mellett sajnos számos limitációval is számolni kell. Így a hálózatmenedzsment egyre komplexebbé válik a nagy mennyiségű hálózati forgalom gyors és megszakításmentes kezelése iránti elvárás miatt, valamint minden újabb SDN/NFV-komponens hozzáadása a rendszerhez bonyolítja a hálózatkezelést. Ezen túl a sebezhetőség is növekszik, mivel az SDN/NFV-megoldások ugyan lehetővé teszik az operátorok számára a hálózati környezet gyors és rugalmas konfigurálását, de az esetleges hibás konfigurációk hálózati fennakadásokhoz vezethetnek.

Ezeknek és egyéb kihívásoknak a kezelésében is segítségünkre lehetnek az MI-alapú eljárások. Az alábbiakban röviden áttekintjük és rendszerezük a mesterséges intelligenciával kapcsolatos fogalmakat.

#### 2.4. Mesterséges intelligencia

Az MI [5] mesterségesen létrehozott tudat általi intelligenciát jelent, amely képes önállóan viselkedni, tanulni, döntéseket hozni. Az MI, mint tématerület, a számítástechnika, számítógép-tudomány egyik ágát képviseli, de manapság már szinte minden területen találkozhatunk vele. Sokszor rokon értelemben használjuk a gépi tanulás kifejezéssel, bár annál szélesebb tartományt fed le.


A hétköznapiakban egyre sűrűbben találkozunk az MI-vel, illetve a gépi tanulással kapcsolatos fogalmakkal. A gyakoribb fogalmakat és ezek egymáshoz való viszonyát az 5. ábra szemlélteti<sup>7</sup>.

Adatok kezelését, feldolgozását, belőlük hasznos információ kinyerését rendszerint hagyományos matematikai módszerek – például statisztikai analízis –, vagy manapság egyre inkább mesterséges intelligencián alapuló eljárások segítségével végezzük. A gépi tanulás az MI egyik, ha nem a legnagyobb válfaja. Ezen belül megkülönböztünk felügyelt, felügyelet nélküli, illetve megerősítéses tanulást alkalmazó módszereket.

*Felügyelt tanulás* esetén az eljárásunkat először egy tanuló adathalmazon tanítjuk, majd az így létrehozott modellt alkalmazzuk problémák megoldására. Ennek előnye, hogy állandó mintázattal rendelkező adatokon nagy pontossággal és gyorsan működő modellt lehet előállítani. Hátránya a tanítás jelentős idő- és erőforrásigénye, valamint, ha változik az adatok mintázata, akkor újra kell tanítani a modellt.

*Felügyelet nélküli tanulás* esetén elmarad a különálló tanulási fázis, az eljárás működés közben tanul. Ennek előnye, hogy azonnal, valós időben használható az eljárás, ami képes adaptálódni az adatok mintázatának változásához. Hátránya, hogy sokszor pontatlanabb eredményt ad és működése erőforrásigényes.

*Megerősítéses tanulás* esetén az eljárás döntések sorozatán keresztül próbál egy stratégiát megtanulni, amelyre a folyamat végén kap csak visszajelzést, és a visszajelzések tükrében változtatja a stratégiát. Ez a megközelítés jól alkalmazható játékok, vagy olyan feladatok esetén, ahol valamilyen stratégia mentén kell döntéseket hozni vagy megoldást találni. Az emberi idegrendszer működését alapul vevő *neurális hálózatok* használata az egyik olyan eljárás, amely mindhárom tanulási módszer esetében alkalmazható



5. ábra  
Mesterséges intelligencia és a gyakoribb, kapcsolódó fogalmak viszonya

és amely egyre nagyobb népszerűségnek örvend manapság. Az ilyen hálózatok több rétegbe szervezett, egyszerű műveleteket végző neuronokból állnak, melyek egymáshoz kapcsolódva és együttműködve hozzák létre a kívánt eredményt. Több változatuk létezik az egyszerűbb előrecsatolt hálózatoktól kezdve a visszacsatolt hálózatokig. Ide lehet sorolni a *mélytanulást* alkalmazó módszereket is – bár sokan ezt bővebb kategóriának tekintik –, ahol a *mély* jelző arra utal, hogy a tanuló eljárás architektúrája több rétegből áll.

<sup>7</sup> Az egyes kategóriák határait illetően nincs egységesen elfogadott álláspont, ezért az irodalomban találkozhatunk az ábrán feltüntetettől eltérő kategorizálással is.

A mesterséges intelligencián alapuló eljárások számos feladat megoldásában nyújthatnak segítséget a hálózatok területén is, amit az alábbiakban néhány példán keresztül szemléltetünk.

### 3. Mesterséges intelligencia alkalmazási szcenáriók hálózatokban

Az MI-alapú eljárások széleskörűen alkalmazhatók az infokommunikációs hálózatokban is. Az egyik kézenfekvő alkalmazási terület a hálózatok menedzselésének támogatása, az egyre komplexebbé váló menedzsment feladatok elvégzésének elősegítése. Például MI-alapú módszerek segítségével automatizált módon azonosíthatók a hálózati események közötti korrelációk; megjósolható a hálózat jövőbeli viselkedése; vagy akár önmenedzselő hálózatok hozhatók létre, amelyek képesek saját magukat szervezni, optimalizálni, hibából helyreállni az üzemeltető beavatkozása nélkül.

MI használatával támogatható konkrét menedzsment-feladatok többek között az NFV életciklus-menedzsment; Traffic Engineering; hálózati anomália-detekció; gyökérhiba analízise; meghibásodás előrejelzése; hálózati erőforrások kihasználtságának előrejelzése; a hálózatot ért támadás, illetve behatolás detektálása. Az alábbiakban ezen feladatok közül néhány kapcsán röviden áttekintjük, hogyan is lehetnek az MI-alapú eljárások a segítségünkre.

#### 3.1. NFV életciklus-menedzsmentje


NFV-infrastruktúrán kialakított hálózatokban az NFV életciklus-menedzsmentje magába foglalja a VNF-ek létesítését, telepítését; a szolgáltatásfunkciók láncolását; az automatikus skálázást; illetve az anomáliadetekciót (6. ábra).

A működési költségek optimalizálása céljából a VNF-ek fizikai szervereken való létesítését, telepítését érdemes a forgalom változásához igazítani, így az adott időszakra az adott VNF-eket a forgalmi igényhelyhez közele, vagy kevésbé terhelt szervereken létrehozni. A VNF-ek dinamikus létrehozásában, áthelyezésében nyújthatnak támogatást az MI-alapú eljárások. Például a hálózati forgalom alakulásának megtanulására előrecsatolt, míg a hálózati topológia megtanulására gráfolapú neurális hálózatok alkalmazhatók, melyeket egy megfelelő modellben kombinálva előre megjósolható, hova érdemes az adott VNF-eket telepíteni vagy áthelyezni [7].

Összetettebb hálózati szolgáltatásokat az alapvető szolgáltatásfunkciókat biztosító VNF-ek egymás utáni láncolásával lehet biztosítani. Azonban azt meghatározni, hogy az adott funkciókat megvalósító, különböző szervereken futó VNF-ek kiválasztásának és láncolásának mi az optimális módja, közel sem triviális feladat. Ebben lehet segítségünkre például az MI-alapú, megerősítéses tanulást alkalmazó Q-learning<sup>8</sup> nevezetű eljárás [8].

A szolgáltatások megfelelő skálázása szintén olyan feladat, amiben segítségül tudjuk hívni az MI-t az erőforrások optimális kihasználása céljából. Így például adott funkciót ellátó VNF-példányok számának a felhasználói igények függvényében történő automatikus növelésére vagy csökkentésére hatékonyan alkalmazható az ugyancsak megerősítéses tanulást használó, deep Q-network<sup>9</sup> nevezetű eljáráson alapuló automata skálázó eszköz [9].

Az anomáliák – normálistól eltérő viselkedés – detektálása nem csak a hagyományos hálózatokban, hanem az NFV-környezetben is fontos feladat, hiszen ezek sokszor hibás működésre utaló jelek. Például az adott VNF-példányok abnormális állapotának detektálásával és a szükséges beavatkozással megelőzhetőek vagy gyorsan orvosolhatóak a szolgáltatás nyújtására vonatkozó követelmények megsértéséből adódó problémák. Erre al-

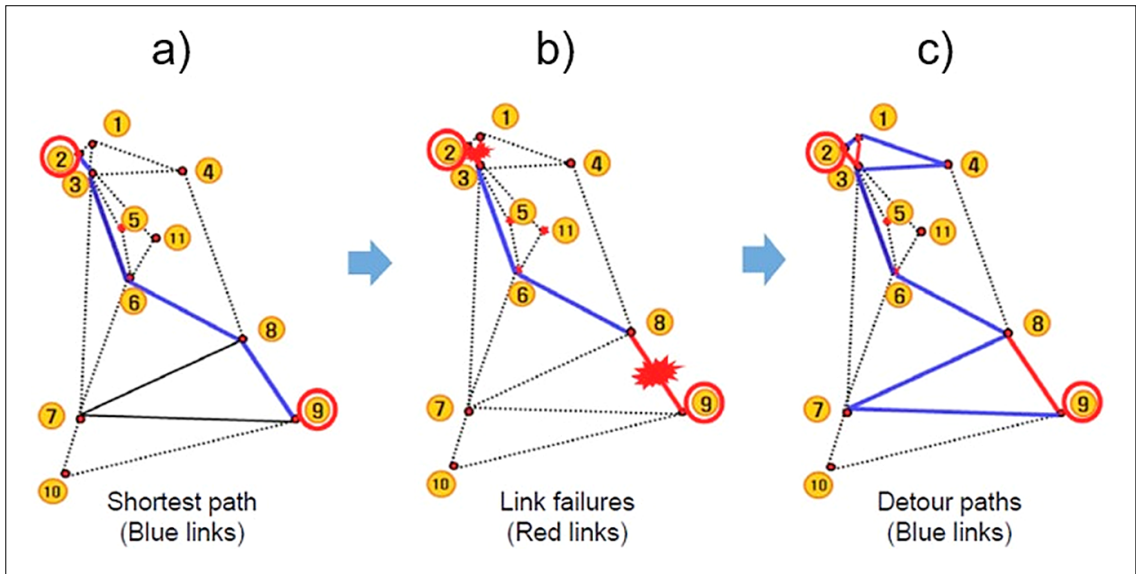


6. ábra  
NFV  
életciklus-  
menedzsmentje [1]

<sup>8</sup> Q-learning – Q-tanulás

<sup>9</sup> Deep Q-network – Mély Q-hálózat

7. ábra  
Kerülő útvonal  
meghatározásra  
link  
meghibásodás  
esetén [1]



kalmazható többek között a felügyelt tanuláson alapuló XGBoost-eljárás, amely a monitorozott modul normális működését megtanulva jelzi, ha ettől eltérő viselkedést tapasztal [10].

### 3.2. Traffic Engineering

A hálózattervezés egyik kiemelt tématerülete olyan redundáns erőforrásokkal rendelkező hálózatok tervezése, amelyek hibatűrők, így meghibásodás esetén is képesek ellátni a feladatukat. Az ilyen redundáns hálózatokon történő forgalomelhelyezést/elvezetést hívjuk Traffic Engineering-nek, amely egyrészt a terhelés elosztásával biztosítja az erőforrások hatékonyabb kihasználását, másrészt az elvárt működést még meghibásodás esetén is.


Példaként tekintsük a 7. ábrán látható hálózatot. Normál működés esetén a 2 és 9 csomópont közötti legrövidebb útvonalon, azaz a 2-3-6-8-9 csomópontok érintésével történik a forgalom elvezetése (7.a ábra). Tegyük fel, hogy meghibásodnak az 1-3, 2-3 és a 8-9 csomópontok közötti linkek (7.b ábra), ezért a szolgáltatási követelményeket kielégítő optimális kerülő útvonalat kell meghatározunk a kiinduló- és célcsomópont között.

Ez a kerülő útvonal esetünkben a 2-1-4-3-6-8-7-9 csomópontokat érinti (7.c ábra).

Egyszerűbb hálózati topológia esetén nem tűnik túl bonyolult feladatnak egy ilyen kerülő útvonal meghatározása, de nagyobb, komplex topológiájú hálózatoknál bizony ez már egy nehéz, összetett feladat. Ebben lehet segítségünkre a fentebb már említett, megerősítéses tanuláson alapuló Q-learning eljárás, amely meghibásodás esetén is képes automatikusan megtalálni a szolgáltatási követelményeket kielégítő legrövidebb útvonalat.

### 3.3. Hálózati anomáliadetekció

Az infokommunikációs hálózatok üzemeltetése során az egyik kiemelt feladat a hálózati komponensek jellemzőinek, teljesítményének folyamatos monitorozása. Így az esetleges anomáliákat azonnal detektálni lehet, jobb esetben előre lehet jelezni. Ezen a területen a kutatócsoportunk is aktív kutatómunkát végez, melynek keretében olyan mesterséges intelligencián alapuló anomáliadetektorok fejlesztésével foglalkozunk, amelyek képesek valós időben felismerni és jelezni az esetleges anomáliákat.



8. ábra  
Anomáliák  
hálózati  
eszközről  
gyűjtött  
telemetria  
adatokban  
[12]



A 8. ábrán (lásd az előző oldalon) például egy hálózati eszközről gyűjtött, az eszköz processzorának kihasználtságát megjelenítő telemetriaadatok láthatók az idő függvényében. Ezek az adatok többnyire egy konstans érték körül ingadoznak. Viszont az egyik időszakban megfigyelhető egy kiugróan alacsony, egy másik időszakban pedig egy kiugróan magas érték, amelyek a normálistól eltérő működésre, így esetleges meghibásodásra, vagy akár a hálózatunkat ért támadásra is utalhatnak. Amennyiben – lehetőség szerint valós időben – detektálni tudjuk ezeket az anomáliákat, úgy szükség esetén gyorsan be is tudunk avatkozni, biztosítva ezáltal a normális működést.

Kutatócsoportunknak sikerült egy LSTM<sup>10</sup>-alapú, memóriával rendelkező neurális hálózatot használni, AlterRe<sup>2</sup> névre keresztelt eljárást kidolgozni [11], majd ezt továbbfejlesztnie az AREP nevezetű eljárássá [12]. Ezek az anomáliadetektorok a felügyelet nélkül tanuló algoritmusok csoportjába sorolhatók, így valós időben alkalmazhatók az anomáliák jelzésére és képesek adaptálódni a monitorozott adatok mintázatának változásaihoz.


Az AREP teljesítményét – egyéb vizsgálatok mellett – összevetettük néhány korszerű, az utóbbi időben publikált anomáliadetektorral is, ennek az eredménye látható a 9. ábrán. Három különböző, ezen a területen általánosan használt metrika (Precision, Recall, F-score) mentén végeztük el az összehasonlítást. Minden esetben igaz, hogy minél nagyobb átlagos értéket kapunk, annál jobban teljesít az adott eljárás az adott metrika vonatkozásában. Az ábrán feltüntetésre került a kapott értékek szórása is. Az eredményekből kiolvasható, hogy az AREP az egyik metrika mentén (Precision) legalább olyan jól teljesít, mint a legjobban szereplő versenytársai, míg a másik két metrika esetén (Recall, F-score) túl is teljesíti azokat.



#### 4. Összefoglalás

Mesterséges intelligencián alapuló eljárások alkalmazása manapság már szinte minden területen tetten érhető, így az infokommunikációs hálózatok esetében is. Ami nem meglepő, hiszen az egyre komplexebbé váló hálózati környezetben a bonyolult, összetett feladatok elvégzését nagy mértékben elősegíthetik az öntanuló, nagy mennyiségű adatokat gyorsan feldolgozni képes eljárások.

A cikkben röviden áttekintettük az utóbbi időszakban az infokommunikációs hálózatok terén egyre jobban terjedő korszerű paradigmákat, így az SDN/NFV/VNF-alapú hálózati megoldásokat és a mesterséges intelligencia kapcsán gyakran használt alapvető fogalmakat. Ezután felvázoltuk, hogy a hálózatmenedzsmenthez kapcsolódóan hogyan tudják segíteni az MI-alapú eljárások – többek között – az NFV életciklus-menedzsmentjét vagy a Traffic Engineering-et, valamint bepillantást nyújtottunk az MI által támogatott hálózati anomáliadetekció terén elért saját kutatási eredményeinkbe.



9. ábra  
AREP  
összevetése  
egyéb  
korszerű  
anomália-  
detektor  
eljárásokkal  
[12]

<sup>10</sup> Long Short-Term Memory – Hosszú rövidtávú memória

**Hivatkozások**

- [1] Hong, J.W., "Artificial Intelligence-based Network Management," Webinar, Nov. 2021., <http://dpm.postech.ac.kr>
- [2] Benzekki, K., El Fergougui, A., and Elbelrhiti Elalaoui, A., "Software-defined networking (SDN): A survey," Security and Communication Networks, Vol. 9, no.18, pp.5803–5833, 2016. DOI: 10.1002/sec.1737
- [3] ETSI, "Network Functions Virtualization – Introductory White Paper", Oct. 2012. [https://docbox.etsi.org/isg/nfv/open/Publications\\_pdf/White%20Papers/NFV\\_White\\_Paper1\\_2012.pdf](https://docbox.etsi.org/isg/nfv/open/Publications_pdf/White%20Papers/NFV_White_Paper1_2012.pdf)
- [4] Stalling, W., "Foundations of Modern Networking: SDN, NFV, QoE, IoT, and Cloud," Pearson Education, 2016.
- [5] Russell, S.J., and Norvig, P., "Artificial Intelligence: A Modern Approach (2nd ed.)," Prentice Hall, 2003., ISBN 0-13-790395-2
- [6] McKeown, N. et al., "OpenFlow: Enabling innovation in campus networks," ACM SIGCOMM Computer Communication Review, Vol. 38, no.2, pp.69–74, Apr. 2008. DOI: 10.1145/1355734.1355746
- [7] Kim, H. et al., "Graph Neural Network-based Virtual Network Function Deployment Prediction," 16th International Conference on Network and Service Management (CNSM), Nov. 2020.
- [8] Lee, D. et al., "Q-learning Based Service Function Chaining Using VNF Resource-aware Reward Model," The 21st Asia-Pacific Network Operations and Management Symp. (APNOMS 2020), Daegu, Korea, Sep. 2020.
- [9] Lee, D. et al., "Deep Q-network-based auto scaling for service in a multi-access edge computing environment," International Journal of Network Management (IJNM), Vol. 31, no.6, Nov. 2021. DOI: doi.org/10.1002/nem.2176
- [10] Hong, J. et al., "Machine Learning based SLA-Aware VNF Anomaly Detection for Virtual Network Management," 16th International Conference on Network and Service Management (CNSM 2020), Virtual Conference, Nov. 2020.
- [11] Vajda, D., Pekar, A. and Farkas, K., "Towards machine learning-based anomaly detection on time-series data," Infocommunications Journal, Vol. 13, no.1, pp.36–44, March 2021. DOI: <https://doi.org/10.36244/ICJ.2021.1.5>
- [12] Farkas, K., "AREP: An adaptive, machine learning-based algorithm for real-time anomaly detection on network telemetry data," Springer Neural Computing & Applications Journal, Vol. 35, no.8, pp.6079–6094, March 2023. DOI: 10.1007/s00521-022-08000-y

**Köszönetnyilvánítás**

A cikkben feldolgozott téma és a bemutatott eredmények a Nemzeti Kutatási Fejlesztési és Innovációs Alap Mesterséges Intelligencia Nemzeti Laboratórium program, valamint a Pro Progressió Alapítvány támogatásával, a BME VIK Hálózati Rendszerek és Szolgáltatások Tanszék és a Gloster Networks Kft. együttműködésében valósultak meg.

**A szerzőről**

**FARKAS KÁROLY** 1998-ban szerzett műszaki informatikus mérnök, majd 1999-ben bankinformatikus szakmérnök diplomát a BME Villamosmérnöki és Informatikai Karán. Doktori tanulmányait a BME-n, majd a Zürichi Műszaki Egyetemen (ETH Zürich) folytatta, ahol 2007-ben megszerezte a PhD-fokozatot. 2007–2012 között a Nyugat-magyarországi Egyetem (NymE) Informatikai és Gazdasági Intézetének, 2008-tól a BME Hálózati Rendszerek és Szolgáltatások Tanszékének docense, ahol 2017-ben habilitált. 2016 és 2022 között a NETvisor Zrt. K+F igazgatója volt. 2022 júliusától a Gloster Infokommunikációs Nyrt., majd 2023 januárjától a Gloster Networks Kft. oktatási vezetője. A 2011/2012-es tanévet az Universtaet Zürich-en töltötte vendégprofesszorként. Farkas Károly oktatási és kutatási tevékenységét elsősorban a kommunikációs hálózatok területén végzi autonóm, önszerveződő vezeték nélküli mobil hálózatok, IoT, Ipar 4.0 és mesterséges intelligencia témakörökben. Több mint 100 tudományos publikációval rendelkezik és rendszeresen szerepel reguláris vagy meghívott előadóként, valamint szervezőként különböző hazai és nemzetközi eseményeken, konferenciákon, tanfolyamokon. 2016-ban az MTA elismerő oklevélben részesítette az MTA Bolyai János Kutatási Ösztöndíj keretében végzett kiemelkedő kutatói munkájáért. Koordinátora a BME-n működő lokális Cisco Hálózati Akadémiának, a Cisco Oktató Laboratóriumnak, valamint kezdeményezője és főszervezője a BME–Pannon–HTE NetSkills Challenge országos tanulmányi versenynek. A Cisco Hálózati Akadémia képezett instruktora, ill. instruktortréner, rendelkezik számos Cisco ipari vizsgával, 2017-ben Cisco Instructor Excellence Advanced Award díjban részesült. Farkas Károly tevékenységét a Hírközlési és Informatikai Tudományos Egyesület 2015-ben Arany Jelvénnel és Pollák-Virág díjjal ismerte el. 2020-tól a HTE tudományos területért felelős elnökségi tagja.