



M Ű E G Y E T E M 1 7 8 2

Budapesti Műszaki és Gazdaságtudományi Egyetem  
Villamosmérnöki és Informatikai Kar  
Szélessávú Hírközlés és Villamosságtan Tanszék



# Gépi tanulási algoritmusok alkalmazása a magasabb frekvenciasávokban működő vezeték nélküli kapcsolatokban

Tézisfüzet

**Makara Árpád László**

Témavezető  
Dr. Csurgai-Horváth László

2025

A kutatásom fókusza a rádiókommunikáció bizonyos aktuális kihívásainak kezeléséhez szükséges elméleti háttér, valamint a lehetséges megoldások feltárása machine learning alkalmazásával. A modern technológiában egyre több területen használunk vezeték nélküli összeköttetést, ami gyakran további frekvenciasávok igénybevételét teszi szükségessé. Ennek oka, hogy a rádiós összeköttetések tulajdonságai tipikusan két stratégiai irány mentén optimalizálhatók. Az egyik megközelítés a csatornaátvitel javítása fejlettebb modulation and coding schemes kiválasztásával, illetve az egyes antennák közötti zavarvédetség növelésével. A másik stratégia további frekvenciasávok alkalmazása, amelyek sok esetben még újnak számítanak az adott felhasználási környezetben—gyakran más spektrumfelhasználási lehetőségek korlátozásának vagy blokkolásának árán.

A millimeter-wave (mmWave) frekvenciatartományban két kiemelt alkalmazás emelhető ki: a következő generációs mobilkommunikációs hálózatok telepítése a kiszolgálható felhasználók számának növelése és a magasabb adatsebesség elérése érdekében, valamint a műholdas kommunikáció, ahol a kulcskérdés a továbbított adatmennyiség maximalizálása.

Ugyanakkor a magasabb frekvenciasávok, mint például az mmWave tartomány használata számos kihívást jelent, mivel az elektromágneses hullámok hullámhossza összemérhetővé válik a környezeti objektumok méreteivel. Ennek következtében a kommunikációs linkeket jelentős reflexiók, erős csillapítás és fading befolyásolja. Továbbá a path loss a távolsággal arányosan növekszik, ezért a hatékony kommunikáció érdekében erősen irányított antennák alkalmazása szükséges. Kültéri környezetben az időjárás—különösen a csapadék—jelentős csillapításváltozásokat okozhat. Beltéri környezetben a reflexiók és az antenna irányítottsága további komplexitást visz a gyakorlati megvalósításba.

Eddigi kutatásaim során két kulcsfontosságú elméleti problémát kezeltem. Beltéri alkalmazások esetén a mozgó felhasználók által okozott kihívások mérséklését vizsgáltam, miközben törekedtem az adatátvitel maximalizálására. Kültéri alkalmazásoknál a légköri változások csatorna-csillapításra gyakorolt kedvezőtlen hatásainak előrejelzésére és mérséklésére fókuszáltam, amelyek jelentősen befolyásolhatják a kommunikáció megbízhatóságát.

## **1. 1. téziscsoport: A jelterjedéshez kapcsolódó modellek**

A machine learning algoritmusok nagy mennyiségű adatigényűek; a szükséges tanítópéldák száma könnyen elérheti a milliós nagyságrendet. Ha ez a mennyiség nem szerezhető meg mérésből elfogadható időn belül, szimulációt kell alkalmazni.

Ezzel a problémával szembesültem a beltéri hullámterjedés vizsgálatánál is. Megoldására olyan eljárásokat dolgoztam ki, amelyek egyenként külön tézist alkotnak.

### **1.1. 1. tézis: Fejlesztett modell az mmWave beltéri terjedési csillapítására**

Céлом az volt, hogy megértssem a jelszintek alakulását beltéri környezetben, és olyan modellt dolgozzak ki, amely alkalmas machine learning alkalmazásokhoz.

Megfigyeléseim alapján olyan modellt állítottam össze, amely:

- csak mérhető paramétereket tartalmaz,

- figyelembe veszi az antennák irányítottságát,
- akkor is képes leírni a terjedési környezetet, ha az antennák nem néznek közvetlenül egymásra.

A meglévő modellek elemzésével és továbbfejlesztésével elkészítettem a saját, továbbfejlesztett modelletemet [1]. A következő modellt találtam a fenti célok szempontjából legalkalmasabbnak:

$$P_L = 63.76 + 20.3 \cdot \log_{10}(d) + F(\vec{r}) + G(\alpha, \beta) + C, \quad (1)$$

ahol

- $P_L$  a csillapítás,
- $d$  a távolság méterben,
- $F$  a relatív környezeti függvény, amely a hely függvénye ( $\vec{r}$  a helyvektor),
- $G$  a két antenna irányítottságából adódó csillapítás, és
- $C$  az ITU ajánlásban szereplő konstans (ITU-R P1238 2019) specifikációja.

Számos egyéb (nemlineáris stb.) függvényt is teszteltem az eredmény eléréséhez; terjedelmi okokból azonban csak a legjobban teljesítő változatot mutatom be. A variánsok többsége azonos komponensek nemlineáris függvényeit alkalmazta. 38,72 GHz-en a következőt kaptam:

$$P_L = 63.76 + 20.3 \cdot \log_{10}(d) + 15 \cdot \hat{F}_{adv}(\vec{r}) + 20 \cdot \sqrt{(\alpha + \beta)} + C, \quad (2)$$

ahol

$$\hat{F}_{adv}(\vec{r}) = \frac{\sum_{n=1}^N t(n, k)}{N}, \quad (3)$$

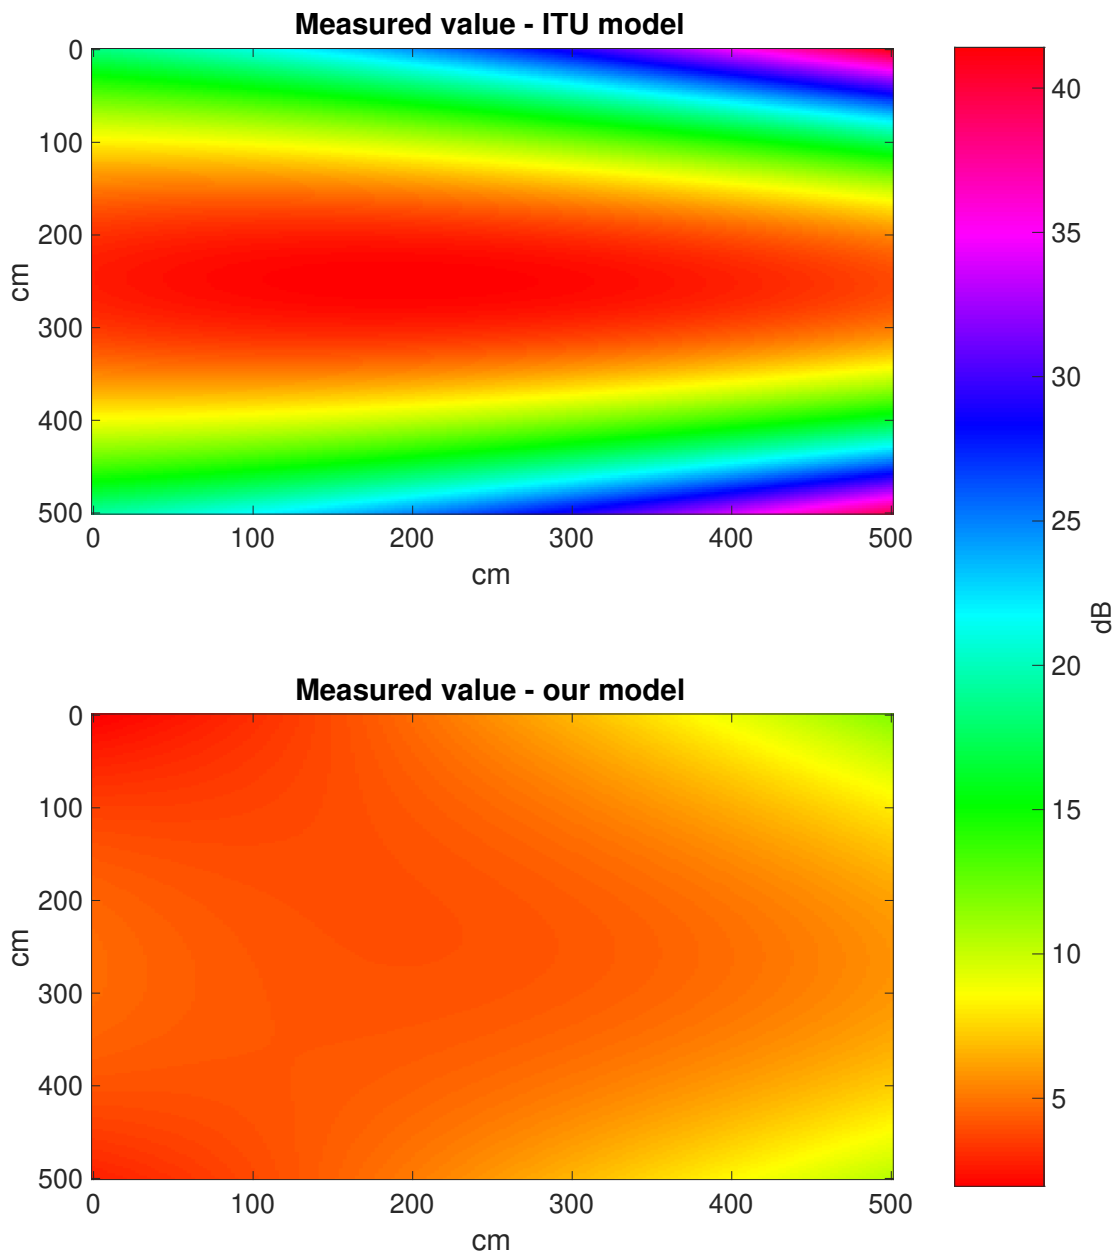
és a segédfüggvény alakja:

$$t(n, k) = \begin{cases} 1, & \text{ha } |(f(n, k))| > |k|, \\ 0, & \text{egyébként,} \end{cases} \quad (4)$$

ahol

- $||$  az abszolútérték jele,
- $f()$  az adott vevőponton mért teljesítmény,
- $k$  a választott teljesítményszint-határ,
- $n$  a diszkrét irányok száma,
- $N$  pedig az utolsó index.

Modellem hatékonyságát a bázis ITU modellel (ITU-R P1238 2019, amely abban az időben a legjobb volt) vetem össze a az 1. ábrán. Sikerült nagy pontosságú modellt létrehoznom. A legjobb korábbi modellhez képest az alábbi különbségek figyelhetők meg:



1. ábra. A mért és a modellezett értékek különbsége dB-ben. Két mérési pont között lineáris interpolációt alkalmaztunk. A terem méretei centiméterben vannak megadva. Az adóantenna a terem/ábra jobb oldalán, középen (a határon) helyezkedik el, ami a számítási tartomány szélét jelöli, noha a mögötte lévő fal kb. 30 cm-re volt. A vizsgált sík kb. 140 cm-rel a padlószint felett helyezkedett el. A terem három fala erősen üvegezett. A berendezés egy kis egyetemi tanteremnek felelt meg. A antennával szemközti fal nagy része hagyományos iskolai tábla volt.

- Az eredeti modell által helyesen becsült értékek érdemben nem változtak.
- A mért értékektől vett abszolút eltérés kb. 10 dB-bel csökkent, az előző 40 dB-hez képest.

- Az elért eredmények hibája 70–80
- A reflexiók felületekhez közeli pontokon is helyes eredmények adódnak.
- A legnagyobb javulás az antenna síkjához közeli, a középvonaltól nagy szögeltérésű pontoknál figyelhető meg; ugyanakkor ezekben az esetekben a hiba relatíve magasabb marad más pontokhoz képest.

Ha a szimulált eredményekből ezeket az interpolált értékeket kizárjuk, a minimális pontosság kb. 84

### 1. tézis

Beltéri jelterjedési modellt dolgoztam ki a gigahertzes tartományra, amely figyelembe veszi az eszközök közötti távolságot, az antennák közötti szöveget és a környezet reflektív tulajdonságait.

## A tézishoz kapcsolódó publikációim

- [1] Á. L. Makara és L. Csurgai-Horváth, „Improved Model for Indoor Propagation Loss in the 5G FR2 Frequency Band”, *Infocommunications Journal*, 13. évf., 1. sz., 2–10. old., 2021, ISSN: 20612079. DOI: 10.36244/ICJ.2021.1.1.1. elérés dátuma 2022. dec. 27. cím: [https://www.infocommunications.hu/2021\\_1\\_1](https://www.infocommunications.hu/2021_1_1).

### 1.2. 2. tézis: Mozgó felhasználó modellezése

Eredetileg egy olyan felhasználói mozgásmodellezési megközelítés kidolgozását terveztem a beltéri jelterjedési problémákhoz, amelyben, ha a felhasználók nem befolyásolják jelentősen az elektromágneses teret, elegendő a statikus tér szimulációja. Ebben az esetben a dinamikus viselkedést az előre kiszámított térben mozgó egyes felhasználók hozzák be. Amíg a felhasználói mozgás nem módosítja a teret jobban, mint az inherens zajszint, a modell érvényes marad. Ez a megközelítés végső soron gyorsabb szimulációt tesz lehetővé, megkönnyítve a nagy adathalmazok generálását.

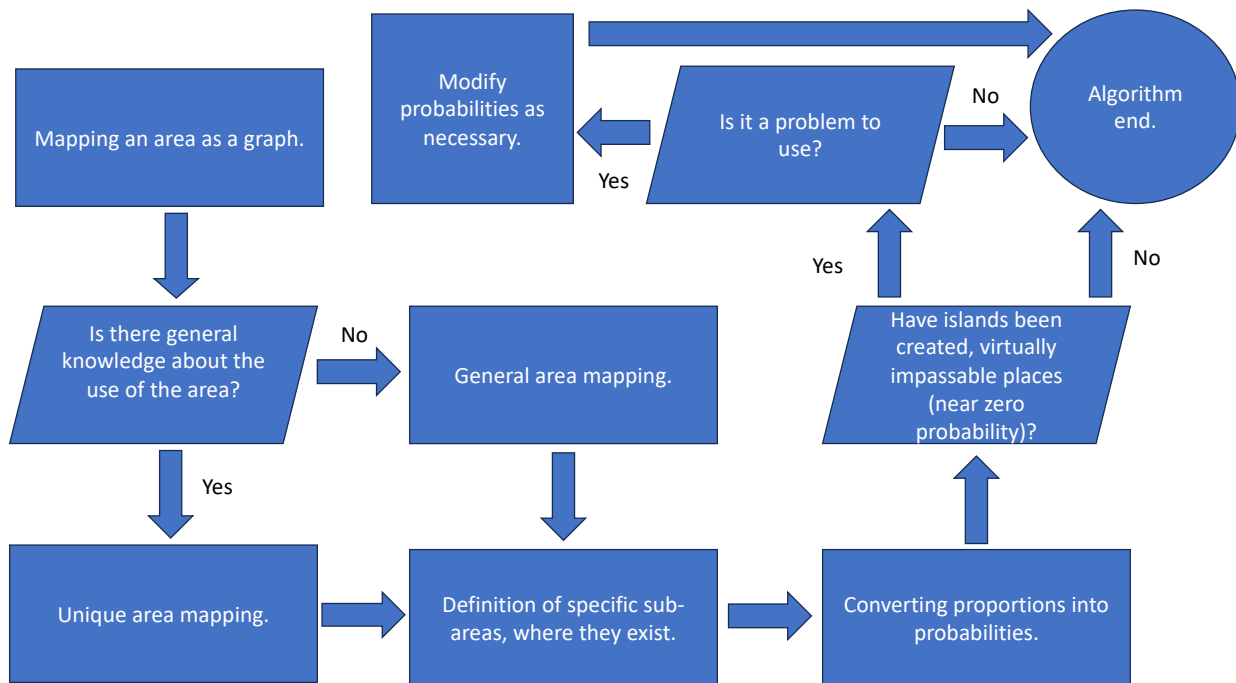
Különböző, jól megalapozott matematikai és fizikai elveken alapuló véletlen haladási megközelítéseket vizsgáltam a saját modellem kialakításához. A legelterjedtebb módszerek közé tartozik a *Brownian motion*, a *Monte Carlo* szimuláció, a *random walk*, a *Markov chain* és a *Langevin* egyenlet, stb.

A kifejlesztett módszer túlteljesítette eredeti célját, és most tetszőleges felhasználók tetszőleges környezetben történő modellezését teszi lehetővé [2]. Ezt úgy érem el, hogy minden mozgást két komponensre bontok: az egyik arányos a statikus térrel, a másik a felhasználó egyedi viselkedésének felel meg.

Az eljárásom fő lépései:

1. A szimulált teret kétdimenziós gráfra képezem le. A gráf pontjai a lefedendő terület diszkrétizált reprezentációi.

2. Felépítem a környezet által generált Markov-láncot a 2. ábra szerint. Több szempontot is figyelembe veszek a környezetarányos címke kiszámításánál. Általánosságban meghatározható a rendelkezésre álló tér és az elmozdulási lehetőségek aránya. A mögöttes megfontolás, hogy a felhasználó ott hajlamos több időt tölteni, ahol több a tér, azaz abba az irányba mozog gyakrabban.
3. Minden felhasználóra mozgásprofil generálok, ahogy a 3. ábra mutatja. Memóriát építek be azáltal, hogy a felhasználó aktuális irányához viszonyítom a haladási irányt.
4. A *user movement behavior profile* (MBP) alapján minden beérkezési irányhoz Markov-láncot generálok.

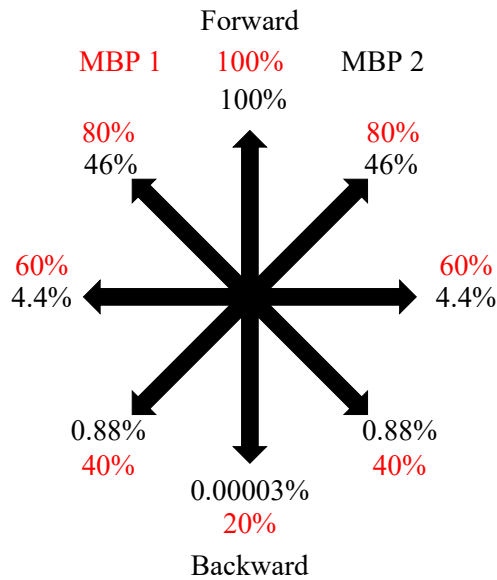


2. ábra. Egy tetszőleges tér leképezésének fő lépései. Az eljárás beltéren és kültéren egyaránt használható.

Az előállított Markov-láncok a következőképpen használhatók a mozgás modellezésére:

1. Válasszunk egy felhasználót és a hozzá tartozó Markov-láncokat. Induljunk el minden lehetséges pontból.
2. Az MBP szerint az új állapotba érkezés irányától függően válasszuk ki a megfelelő Markov-láncot, a szükséges átmenetelemekkel együtt.
3. Ismételjük a folyamatot a szimuláció végéig.

Az algoritmus a felfelé irányuló mozgások széles skáláját képes reprezentálni. Egy kiragadott példa a 4. ábrán látható. Az algoritmus minden lépése konstans időben végrehajtható. Ennek megfelelően a futásidő-komplexitás  $( ) O(n)$ , és a memóriaigénye kisebb, mint egy bonyolultabb Markov-láncé:



3. ábra. Két MBP példa. Felülnézeti vázlat. A helyben maradás nincs jelölve az ábrán. Az egyes értékek megválasztása a szimulálandó mozgástól függ; nem szükséges szimmetrikusan választani.

- Jól paraméterezhető, elegendő variabilitással az adatok generálásához.
- Statikus és dinamikusan változó terekben egyaránt használható.
- Számítási igénye nagy mennyiségű adat generálásához is elfogadható.

## 2. tézis

Markov-lánc alapú mozgásmodellező algoritmust hoztam létre, amellyel tetszőlegesen paraméterezhető véletlen felhasználói mozgások generálhatók bármely megadott környezetben.



## 2. 2. téziscsoport: DNN-alapú antennadirigálás becslése mobil felhasználók számára

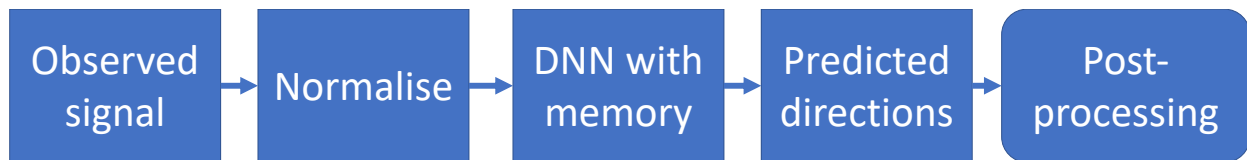
A téziscsoport egy központi gondolat köré szerveződik: hogyan jelezhető előre, hogy egy mozgó felhasználó a következő időpillanatban honnan igényel adatátvitelt. Más szavakkal: a hatékony megvalósításhoz merre kell irányítani az adót?

Kutatásom elsődleges célja az volt, hogy ezt a predikciót kizárólag a vett jelszint alapján, elméleti szinten valósítsam meg, amit sikerült elérnem. Ez azt jelenti, hogy nem használtam klasszikus, jelalapú követési módszereket, és a felhasználó sem szolgáltatott kiegészítő információt a folyamat támogatására.

### 2.1. 3. tézis: DNN-alapú antennadirigálás-becslő

Olyan módszert dolgoztam ki, amellyel megjósolható, hogy a felhasználónak a következő időszakban merre érdemes irányítani a saját antennáját az optimális vételhez [3][4]. A predikció kizárólag a mért jelszinteken alapul, ahogy a az 5. ábra szemlélteti.

Egy adott ponton a felhasználó több irányból végez méréseket, egy diszkrét lehetséges iránykészletből választva. A lehetséges irányok száma is véges és diszkrét. Tipikusan a felhasználó 4 bejövő irányból gyűjt méréseket, és 18 lehetséges adásirány közül választhat.



5. ábra. Az eljárás szematikus felépítése.

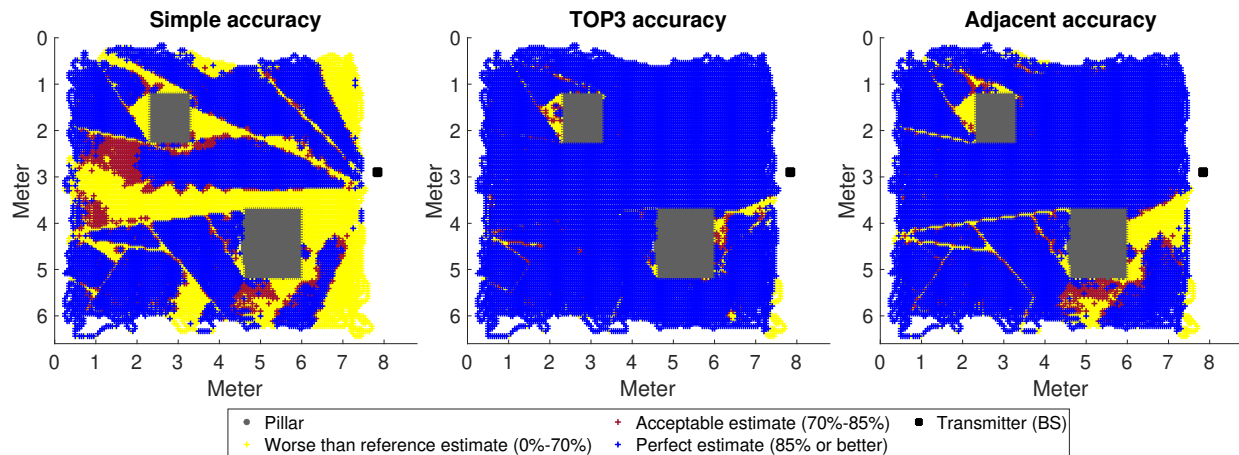
A probléma megoldásához belső memóriamechanizmussal rendelkező *Long Short-Term Memory* (LSTM) architektúrájú *deep neural network*-öt alkalmaztam. Emiatt kulcsfontosságú volt a struktúra minimalizálása, hogy bármely felhasználói eszközön a lehető leghatékonyabban fusson. A legkisebb, de még tanulni képes és legjobban teljesítő modell paramétereinek száma: 62,218.

Három különböző pontossági metrikát alkalmaztam az eredmények értékeléséhez, és ezek alapján az eredmény kielégítő (egy példa látható a 6. ábrán). Természetesen a hálózat bővítésével és újratanításával tovább javíthatók az eredmények.

Ha a klasszifikáció helyett a becsült jelszintet értékeljük, kedvezőbb képet kapunk. Például ha helyesnek fogadjuk el azt a becslést, amely legfeljebb 6 dB-bel alacsonyabb a pillanatnyilag elérhető maximális jelszintnél, akkor minden tesztelt teremben az algoritmus az esetek 99

Munkám fő megállapításai:

1. Kifejleszthető olyan eljárás, amely klasszikus követési információk—például relatív elmozdulás vagy helyadat—nélkül is képes iránybecslésre.
2. Az iránybecslés elérhető a legmagasabb jelszint kiválasztásával, ami hatékony módszer a mozgásorientáció meghatározására.



6. ábra. 5,000,000 lépésnyi mozgás az A1 teremben; a pontosság a metrikák szerint értelmezve. A fehérrel jelölt területeket a teszt során nem látogattuk. Az ábra generálásához használt neurális hálót a saját Markov-lánc alapú mozgásmodellezéssel (lásd az 1.2. szakasz) előállított adathalmazon tanítottuk.

3. A vizsgált algoritmusok könnyen továbbfejleszthetők (újratanítással vagy online tanítással) vagy bővíthetők (további rétegek hozzáadásával vagy az architektúra átalakításával). A kutatás nem célzott azonnal alkalmazható, *production-ready* DNN-ek létrehozására; a jelenlegi eredmények alapján azonban további fejlesztés gyakorlati felhasználásra kész algoritmusokhoz vezethet.

### 3. tézis

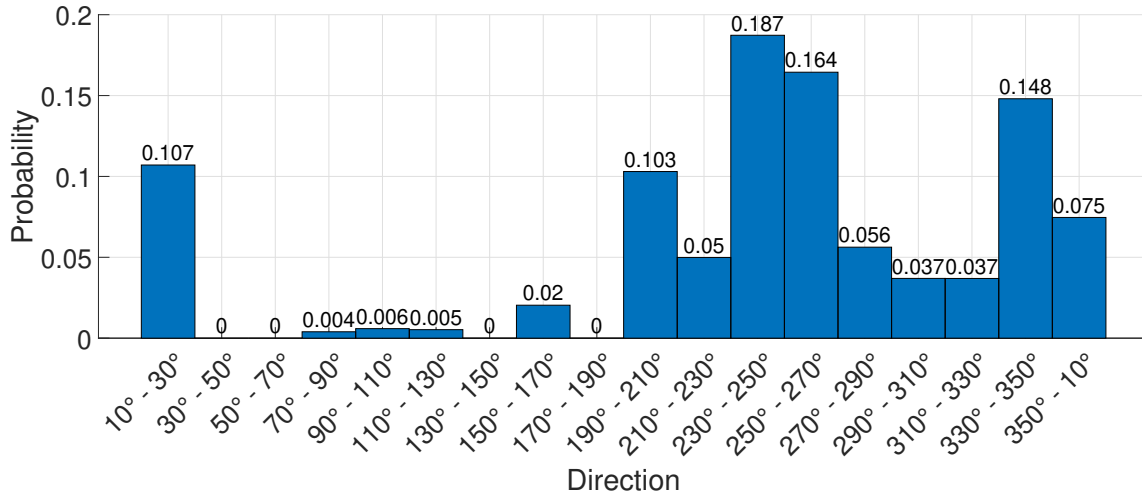
Módszert dolgoztam ki egy mozgó felhasználó antennakommutációjának megvalósítására. Az eljárás elméleti, fizikai korlátoktól mentes.

## A tézishoz kapcsolódó publikációim

- [3] Á. L. Makara, B. T. Csathó, L. Csurgai-Horváth és B. P. Horváth, „Measurement-based Indoor Beam Alignment Utilizing Deep Learning”, *2021 International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME)*, Mauritius, Mauritius: IEEE, 2021. okt., 1–6. old., ISBN: 9781665412629. DOI: 10.1109/ICECCME52200.2021.9590951. elérés dátuma 2022. dec. 27. cím: <https://ieeexplore.ieee.org/document/9590951/>.
- [4] Á. L. Makara, B. T. Csathó, A. Rácz, T. Borsos, L. Csurgai-Horváth és B. P. Horváth, „Deep-Learning-Based Antenna Alignment Prediction for Mobile Indoor Communication”, *Sensors*, 23. évf., 7. sz., 2023, ISSN: 1424-8220. DOI: 10.3390/s23073375. cím: <https://www.mdpi.com/1424-8220/23/7/3375>.

## 2.2. 4. tézis: Beltéri környezetek összehasonlításának lehetősége csillapítás-eloszlás alapján

Kutatásom során szükség volt különböző termek összehasonlítására abból a szempontból, hogy mennyiben különböznek a jelterjedés tekintetében. A lehetséges irányok eloszlásán alapuló metrikát dolgoztam ki [5]. Az átmenetek eloszlását (elsősorban memóriamentes esetben) irány szerint elemeztem (lásd az x. ábrát), és vizsgáltam korrelációjukat a különböző termekben elért pontossági szintekkel.



7. ábra. S mozgás, tanítóadat-eloszlás (a mozgás során választott legjobb irányok eloszlása) az A1 teremből.

Azt tapasztaltam, hogy a *Total Variation Distance* adja a legmegbízhatóbb módszert két terem, tanítókészlet stb. jelterjedési hasonlóságának meghatározására. A total variation distance több néven ismert: *statistical distance* (félrevezető lehet), *statistical difference*, vagy *variational distance*. Általános esetben:

$$\delta(A, B) = D_T = \sup |A(v) - B(v)|, \quad (5)$$

ahol a  $||$  abszolútértéket jelöl. Diszkrét valószínűségi változók esetén:

$$D_T(A, B) = \sum_v |A(v) - B(v)| \cdot \frac{1}{2}. \quad (6)$$

Az elért eredmények alapján pontosabb leíráshoz hasznos lehet további memória-eloszlások alkalmazása.

### 4. tézis

Eljárást hoztam létre tanítóadat-készletek jelterjedési szempontú hasonlóságának összehasonlítására.

## A tézishez kapcsolódó publikációim

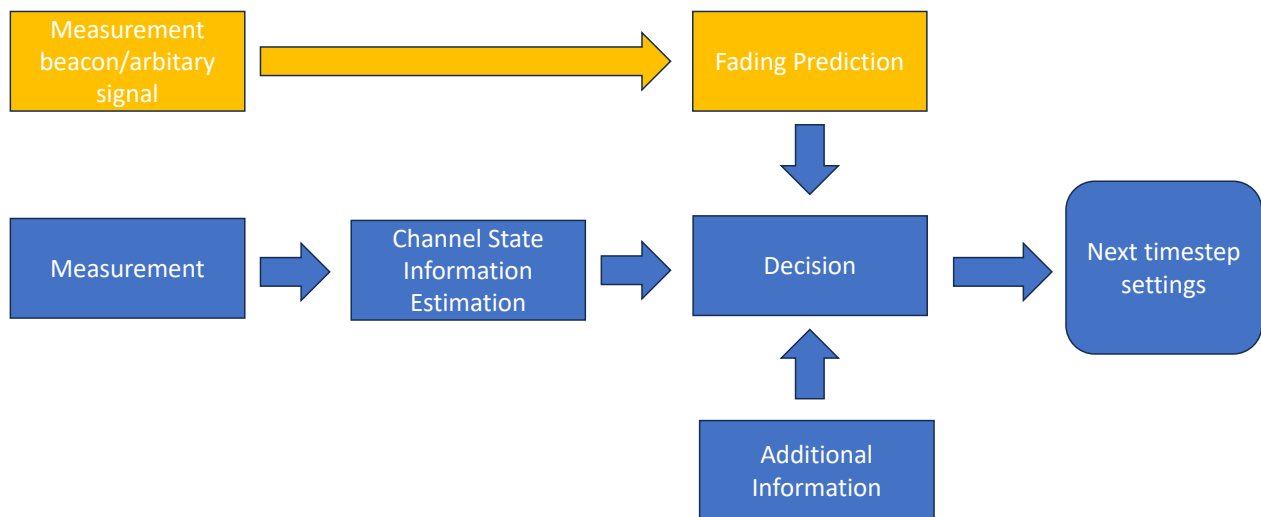
- [5] Á. L. Makara és L. Csurgai-Horvath, „Classification of Indoor Environment in Neural Network Controlled FR2-band Communication”, *2022 International Conference on Electrical, Computer and Energy Technologies (ICECET)*, Prague, Czech Republic: IEEE, 2022. júl., 1–6. old., ISBN: 9781665470872. DOI: 10.1109/ICECET55527.2022.9873040. elérés dátuma 2022. dec. 27. cím: <https://ieeexplore.ieee.org/document/9873040/>.

### 3. 3. téziscsoport: Műholdas csatorna csillapításának vizsgálata

Az utolsó téziscsoportban arra fókuszáltam, hogyan lehet adaptívan módosítani a vezeték nélküli összeköttetések beállításait a hasznos továbbított adatmennyiség maximalizálása érdekében. Ehhez Föld–műhold összeköttetésekben végeztem vizsgálatokat, mivel ezek jelentős kihívásokat jelentenek, és elég sokfélék ahhoz, hogy a különböző jelenségek széles körét lefedjék.

#### 3.1. 5. tétel: Fading előrejelzése műholdas csatornákon

Olyan módszert dolgoztam ki, amely bináris klasszifikációval jelzi előre, hogy a következő vételi periódusban bekövetkezik-e *fading* [6][7]. Ez többletinformációt szolgáltat a döntéshozatal során arról, hogy várható-e drasztikus jelszintcsökkenés vagy akár átvitelkimaradás. A módszer szematikus vázlatát a 8. ábrán látható.



8. ábra. A struktúra az általam javasolt *fading* előrejelző módszerrel kiegészítve, amely bármely meglévő megoldásba zökkenőmentesen integrálható. A saját kutatási hozzájárulásaim narancssárgával vannak kiemelve. Bármely bemenő jel, amely a csatornához hasonló viselkedést mutat, felhasználható a vezérléshez.

Az algoritmust a lehető legkisebbre választottam, mivel fontos volt a késleltetés és a számítási igény minimalizálása. A legkisebb, de még tanulni képes és legjobban teljesítő modell paramétereinek száma: 203,002. A bemutatott modell pontossága 93

1. táblázat. **Kiegyensúlyozott pontosság különböző LSTM-méreték mellett** (bináris klasszifikáció).


LSTM egységek	Recall (%)	Specificity (%)	Balanced Accuracy (%)
10	95.0	73.3	84.15
25	95.1	76.2	85.65
<b>50</b>	<b>94.9</b>	<b>81.2</b>	<b>88.05</b>
75	95.3	74.6	84.95
100	96.0	64.5	80.25
150	95.4	71.8	83.60
200	95.4	69.6	82.50
500	96.5	58.4	77.45

**Balanced Accuracy (BA):**  $BA = \frac{1}{2}(\text{Recall} + \text{Specificity})$ ; az osztályegyensúlytalanságot ellensúlyozza azzal, hogy a pozitív és negatív osztályokat azonos súllyal veszi figyelembe.

Ez itt azért hasznos, mert a *non-fading* dominál az adathalmazban, és a „**pozitív**” a *non-fading*ként van definiálva. A legjobb BA-t az 50 egységes LSTM éri el (88,05

## 5. tézis

Valós idejű *fading* előrejelzésére szolgáló eljárást hoztam létre.



9. ábra. A felső ábra néhány napnyi idősor *fading* címkézését mutatja. Az alsó ábra a DNN előrejelzési eredményét ábrázolja.

## A tézishez kapcsolódó publikációim


- [6] Á. L. Makara, T. Deli és L. Csurgai-Horváth, „AI-Supported Fading Prediction”, English, *26th Ka Band Communications Conference 2021 Propagation*, Propagation 4: sor., ISSN-2573-6124, Washington DC: Ka, Broadband Communications, Navigation és Earth Observation Conference, 2021. szept., 1–5. old. elérés dátuma 2021. okt. 14. cím: [https://proceedings.kaconf.com/papers/2021/ka4\\_2.pdf](https://proceedings.kaconf.com/papers/2021/ka4_2.pdf).
- [7] Á. L. Makara és L. Csurgai-Horváth, „Application of Artificial Intelligence in Satellite Communications”, *Selected papers of the 7th International Conference on Research, Technology and Education of Space (H-SPACE2022)*, 2022, 1–5. old. cím: [https://space.bme.hu/wp-content/uploads/2022/09/Proceedings\\_Papers\\_HSPACE-2022.pdf](https://space.bme.hu/wp-content/uploads/2022/09/Proceedings_Papers_HSPACE-2022.pdf).

### 3.2. 6. tétel: Deep-learning alapú ModCod prediktor műholdas csatornákhöz


A *fading* előrejelzés kutatása során felmerült az ötlet, hogy egy teljes *link adaptation deep neural network*-kel is megvalósítható, minimálisra csökkentve a hibákat. Ebben az esetben a struktúra a 10. ábrán látható.

Olyan *deep neural network* alapú módszert dolgoztam ki, amely megoldja ezt a problémát [8][9]. A *coding* és *modulation* opciók véges kombinációiból kategóriákat hoztam létre (lásd a 11. ábra). Így az adaptív probléma lényegében egyszerű klasszifikációvá válik (felügyelt *machine learning*).

Módszerem a vártnál jóval kisebb neurális hálóval is működőképes. A legkisebb, de még



10. ábra. Az általam javasolt új struktúra. Minden feladatot külön DNN-hez rendeltem, csökkentve a szükséges modulok számát. Megfelelő paraméterek mellett még gyorsabb is lehet a bonyolultabb rendszereknél.



11. ábra. A mért—az egyszerűség kedvéért skalár—jel zölddel jelölve (önkényes dimenzió). Bármely időpillanatban hozzárendelhető egy kategória, ami ténylegesen az ACM beállítás. A függőleges szaggatott vonalakkal egy tetszőleges diszkrétizációt jelöltem; ez az adott példa rendszer diszkrét ideje.

tanulni képes és legjobban teljesítő modell paramétereinek száma: 2,748. Alacsony számí-  
tásigénye miatt szinte bármely alkalmazásban jól használható. A módszer korlátja, hogy  
minden eltérő linkhez újratanítás szükséges.

Elemzésem alapján a háló még az optimális kapcsolási gyakoriságot is képes megtanulni,  
így költséghatékony is lehet. A kommunikációs csatornán küldött üzenetek hosszát figyelembe  
véve az algoritmus pontossága valamivel 95

**6. tézis**  
Módszert dolgoztam ki a *modulation and coding* állapot becslésére rádiós csatornán,  
amely a teljes csatornkapacitás közel 95

## A tézishez kapcsolódó publikációim

- [8] Á. L. Makara és L. Csurgai-Horváth, „Supporting Adaptive Coding and Modulation Techniques for Satellite Radio Channel”, *Proceedings of the 1st Workshop on Intelligent Infocommunication Networks, Systems and Services (WI2NS2)*, 2023, 31–36. old. DOI: 10.3311/WINS2023-006. cím: <https://m2.mtmt.hu/api/publication/33707827>.
- [9] Á. L. Makara és L. Csurgai-Horváth, „Deep-Learning-Based ModCod Predictor for Satellite Channels”, *Radioengineering*, 33. évf., 182–194. old., 2024, ISSN: 1805-9600. DOI: 10.13164/re.2024.0182.