

Miskolci Egyetem



GÉPÉSZMÉRNÖKI ÉS INFORMATIKAI KAR

EGYEDI IGÉNYEK ALAPJÁN TÖRTÉNŐ IOT ESZKÖZÖK FEJLESZTÉSI MÓDSZERTANÁNAK KUTATÁSA

PhD értekezés

Készítette:

L. Kiss Márton

okleveles villamosmérnök

Hatvany József Informatikai Tudományok Doktori Iskola

Doktori iskola vezető:

Prof. Dr. Szigeti Jenő

A matematikai tudomány kandidátusa

Tudományos vezetők:

Dr. Trohák Attila

Egyetemi docens, PhD

Miskolci Egyetem

Dr. Pintér Judit Mária

Junior kutató, PhD

ÉMI Nonprofit Kft.

Miskolc

2024

Köszönetnyilvánítás

A kutatómunka előzménye az Európai Unió és a magyar állam támogatásával, az Európai Regionális Fejlesztési Alap társfinanszírozásával, a GINOP-2.3.4-15-2016-00004 projekt keretében valósult meg, a felsőoktatás és az ipar együttműködésének elősegítése céljából.

Témavezetői ajánlás

L. Kiss Márton: *”Egyedi igények alapján történő IoT eszközök fejlesztési módszertanának kutatása”* című PhD értekezéséhez

L. Kiss Márton szakmai fejlődését alapszakos hallgató korától volt szerencsém nyomonkövetni. Hamar megmutatkozott szakmai elhivatottsága, széleskörű érdeklődése és kivételes tehetsége, amelyet elsőként nyertes TDK dolgozatok, elnyert ösztöndíjak majd később szakmai publikációk és sikeres PhD felvétele is bizonyított a Hatvany József Informatikai Tudományok Doktori Iskolába.

Doktori témáját a FIEK projekt keretén belül valósította meg, melynek két fő vonulata van. Egyik fő témája a levegőminőség mérésére alkalmas low-cost szenzorok összehasonlító elemzését követően kiválasztott eszközök rendszerbe foglalása és hálózat kialakítása, melynek szoftveres kalibrációjához megvizsgált több típusú módszert, majd összehasonlítva fogalmazta meg téziseit. Másik fő témája egy Vagon nyilvántartási rendszer automatizálása volt, melyben megvalósított egy önszerveződő szenzor rendszeren alapuló helymeghatározást, térkép modell megalkotásával egybekötve. Teljesítményét alátámasztja, hogy a megalkotott berendezés és módszertan 2022-ben szabadalomként is bejegyzésre került.

L. Kiss Mártont nagy munkabírási, érdeklődő, motivált hallgatóként ismertem meg és nem csak témavezetőként, hanem volt Kollégaként is lojális, nagy szakmai tapasztalattal rendelkező segítőkész szakembernek tartom.

Kutatási eredményeit hazai és nemzetközi konferenciákon és folyóiratokban publikálta, ezek anyagi háttérét sikeres pályázatokkal teremtette meg.

Az értekezés L. Kiss Márton eredményeit tartalmazza és a Hatvany József Informatikai Tudományok Doktori Iskola szabályzatában megkövetelt követelményeknek mindenben megfelel. A fentiek alapján a jelölt számára a PhD cím odaítélését messzemenően támogatom.

Miskolc, 2024. június 3.

Dr. Pintér Judit Mária

tudományos vezető

Köszönetnyilvánítás

Szeretném megköszönni családomnak, de legfőképpen a feleségemnek a támogatást a doktori tanulmányaim alatt. További köszönet illeti a téma vezetőimet Dr. Pintér Judit Máriát és Dr. Trohák Attilát, akik végig terelgettek ezen az úton.

Tartalomjegyzék

Köszönetnyilvánítás	ii
Témavezetői ajánlás.....	iii
Köszönetnyilvánítás	iv
Tartalomjegyzék	v
Rövidítések listája	vii
Ábrajegyzék.....	viii
Táblázatjegyzék	xi
1 Bevezetés	1
2 Kültéri szállópor koncentráció szenzor kalibrációs eljárások összehasonlító elemzése.....	2
2.1 Költséghatékony szállópor mérő szenzorok tudományos irodalmi áttekintése .	7
2.2 Az elérhető költséghatékony eszközök rendszerezése	10
2.3 Adatok feldolgozása.....	19
2.4 Kalibrációs eljárások bemutatása	23
2.4.1 Neurális háló	23
2.4.2 Lineáris regresszió	27
2.4.3 Growing factor	28
2.5 Kalibrációs eljárások eredményeinek kiértékelése	33
2.5.1 A PMS7003 alap mérésének kiértékelése.....	37
2.5.2 Neurális háló kiértékelése	38
2.5.3 Lineáris regresszió kiértékelése	40
2.5.4 Growing factor kiértékelése.....	47
2.5.5 A sűrűség optimalizált adatok kiértékelése	52
2.5.6 Összegzés.....	53

2.6	Tézisek	54
2.6.1	Tézis I.	54
2.6.2	Tézis II.	54
3	LoRaWAN mérőhálózat kültéri szenzor fejlesztése	55
3.1	LoRaWAN alapú szenzor életciklus elemzése	62
3.2	Tézis III.	71
4	Tároló vágány környezet kutatása	72
4.1	Irodalmi áttekintés.....	76
4.2	Sorrend meghatározás	77
4.3	Helymeghatározás	86
4.4	Tárolóvágány-hálózat modellje.....	91
4.4.1	Vágány modell.....	92
4.4.2	Környezet modell.....	95
4.5	Tézisek	98
4.5.1	Tézis IV.....	98
4.5.2	Tézis V.....	98
4.5.3	Tézis VI.....	98
5	Összefoglalás.....	99
6	Summary.....	100
	Az értekezés témakörében készített saját publikációk	101
	Folyóiratcikkek	101
	Konferenciaközlemények	101
	Szabadalom.....	102
	Tudományos irodalomjegyzék.....	103
	Egyéb hivatkozások	107

Rövidítések listája

ARM	Advanced RISC Machine
ADP	Abiotic Depletion Potential
AP	Acidification potential
AQI	Air Quality Index
DBN	Deep Belief Network
DNN	Deep Neural Networks
ÉMI	Építésügyi Minőségellenőrző Innovációs
EP	Eutrophication Potential
FIEK	Felsőoktatási Ipari Együtműködési Központ
GPS	Global Positioning System
GRU	Gated Recurent Unit
GWP	Global Warming Potential
HTP	Human Toxicity Potential
IMU	Inertial Measurement Unit
IoT	Internet of Things
ISM	Industrial, Scientific and Medical
LCA	Life Cycle Assasment
LSTM	Long Short Term Memory
MPL	Multilayer
NN	Neural Network
OLM	Országos Légszennyezettségi Mérőhálózat
PWM	Pulse-Width Modulation
RMSE	Root Mean Square Error
UART	Universal asynchronous receiver-transmitter
WHO	World Health Organization

Ábrajegyzék

1. ábra - Miskolc egy téli, erősen szennyezett napon [3].....	2
2. ábra - Szállópor koncentráció anomália térkép [4].....	5
3. ábra – Fűtő ellenállás alapú szállópor mérő szenzor elvi felépítése [saját szerkesztés]	11
4. ábra –Ventilátor alapú szállópor mérő szenzor elvi felépítése [saját szerkesztés]	12
5. ábra - PMS7003 szállópor mérő szenzor [2]	14
6. ábra - Mérőrendszer felépítés [saját szerkesztés]	14
7. ábra – Egyedi fejlesztésű mérőrendszer.....	15
8. ábra - Node-Red Raspberry PI szoftver	16
9. ábra - Elkészült mérőrendszer.....	17
10. ábra - Mérőrendszer kihelyezése	17
11. ábra - OLM PM10 és PMS7003 adatok 2019.02.28.....	21
12. ábra - Hőmérséklet alakulása 2019.02.28.....	22
13. ábra - Páratartalom alakulása 2019.02.28.....	22
14. ábra - OLM PM10 és PMS7003 adatok 2019.08.15.....	23
15. ábra - Perceptron sémája [T5].....	24
16. ábra - Többrétegű neurális háló sematikus ábrája [saját szerkesztés]	24
17. ábra - Lineáris regressziós modell	27
18. ábra - PMS7003 szenzor által mért szemcseméret méret szerinti eloszlása	29
19. ábra - Átszámolt méret szerinti koncentráció eloszlás.....	30
20. ábra - Growing factor.....	31
21. ábra – Growing factor.....	33
22. ábra - Validációs eljárás.....	34
23. ábra - OLM havi átlagok.....	35

24. ábra - Hőmérséklet alakulása 2019	35
25. ábra - Páratartalom havi alakulása 2019	36
26. ábra - OLM PM10 - PMS7003 PM10 havi átlagok alakulása 2019	38
27. ábra - A használt neurális háló felépítése	39
28. ábra - PMS7003 neurális hálóval kompenzált adatok havi kiértékelése	40
29. ábra - Lineáris regressziós modell az OLM PM10 és a PMS7003 PM10 mérések függvényében.....	41
30. ábra – OLM PM10, PMS7003 PM10 lineáris regresszióval kompenzált havi átlagok	43
31. ábra - PMS7003 mérési hiba a páratartalom függvényére épített regressziós modell.....	44
32. ábra - OLM PM10 - PMS7003 Lineáris RH regresszióval kompenzált havi átlagok alakulása.....	46
33. ábra - OLM PM10 - PMS7003 growing faktor kompenzált havi átlagok alakulása	48
34. ábra - Growing factor optimalizálás	49
35. ábra - OLM PM10 - PMS7003 optimalizált growing factorral havi átlagok.....	51
36. ábra – PMS7003 PM10 méreteloszlásból átszámolt adatok éves alakulása.....	53
37. ábra - LoRaWAN hálózati topológia [T21]	56
38. ábra - Lamellás szenzor ház.....	58
39. ábra - LoRaWAN alapú szenzor panel forrasztási oldal.....	59
40. - LoRaWAN alapú szenzor panel alkatrész oldal.....	59
41. ábra - Kihelyezett szenzor Martinkertváros Szimbiózis Alapítvány.....	60
42. ábra - Miskolc-Martinkertváros anomália térkép	61
43. ábra - LoRaWAN alapú szenzor életciklusa.....	66
44. ábra - Alkotórészek GWP értékei	69
45. ábra - A szenzor egy éves ciklusának GWP értéke	70
46. ábra - tároló vágány rendszer.....	72
47. ábra - Level Systems GPS követő.....	74

48. ábra - Csillag hálózati topológia	79
49. ábra - Hálós (mesh) hálózati topológia	79
50. ábra - Vagon sorrend meghatározó rendszer felépítése	81
51. ábra - Adatgyűjtő egység felépítése.....	81
52. ábra - Adattovábbító egység felépítése	82
53. ábra - Adattároló egység felépítése.....	82
54. ábra - Teszt üzem.....	83
55. ábra - A példában bemutatott adatstruktúra végleges vagonrendje	85
56. ábra - Vagon indulási tranziens	85
57. ábra – BorsodChem vasúti próbamérések	86
58. ábra - Példa tároló vágány hálózat egyenes vonalú sínpályákkal.....	87
59. ábra - A példa vágányrendszer betájolva.....	88
60. ábra - Mérési pont a vágányokon.....	89
61. ábra - Az általam fejlesztett vasúti szoftver.....	91
62. ábra - Vágány modell [T11].....	92
63. ábra - Tárolóvágány hálózat példa.....	95
64. ábra - Példa hálózat gráfmodellje	96

Táblázatjegyzék

1. táblázat – OLM Miskolcon használt műszerei.....	4
2. táblázat - Szállópor koncentráció AQI szerinti osztályozása.....	6
3. táblázat - Digitális/Analóg IO-val rendelkező szenzorok.....	11
4. táblázat – Piacon kapható beépített ventilátoros szenzorok.....	13
5. táblázat - Mérőrendszer által mért adatok.....	18
6. táblázat - OLM által szolgáltatott adatok.....	20
7. táblázat - PMS7003 PM10 mérés havi kiértékelése	37
8. táblázat - PMS7003 éves átlag.....	38
9. táblázat - PMS7003 neurális hálóval kompenzált adatok havi kiértékelése	39
10. táblázat - PMS7003 lineáris regresszióval kompenzált adatok havi kiértékelése	42
11. táblázat - PMS7003 kompenzált éves átlagok alakulása	43
12. táblázat - PMS7003 lineáris RH regresszióval kompenzált adatok havi kiértékelése	45
13. táblázat - PMS7003 Growing faktorról kompenzált adatok havi kiértékelése	47
14. táblázat – Growing factor optimalizálás paraméterek	48
15. táblázat – Growing factor optimalizálás eredmény	49
16. táblázat - PMS7003 optimalizált Growing faktorról kompenzált adatok havi kiértékelése	50
17. táblázat - PMS7003 méret eloszlásból átszámolt kompenzált adatok havi kiértékelése	52
18. táblázat – Kihelyezett szenzorok Martinkertvárosban.....	61
19. táblázat – LoRaWAN alapú szenzor alapanyagai.....	65
20. táblázat – alapanagok környezetszennyezési adatai	67
21. táblázat – Akkumulátor technológiák összehasonlítása az önkiszülés szempontjából	78

22. táblázat – Bluetooth mesh és Zigbee hálózatok összehasonlítása	80
23. táblázat – Adattovábbító eszközöktől érkező adatok.....	83
24. táblázat – Fenti példa térkép végpontjainak koordinátái	87

1 Bevezetés

A doktori tanulmányaimat 2018-ban kezdtem el, akkoriban kezdett el nagyon hangzatos szóként népszerűvé válni az IoT, mivel előtte már sokat foglalkoztam beágyazott rendszerekkel és szenzorokkal, ezért közel éreztem magamhoz ezt a tématerületet. A FIEK projekt egy olyan háttérrel tudott biztosítani, amelynek keretein belül nem csak a végleges kutatási téma kristályosodott ki, hanem jó háttérrel adott ezeknek a fejlesztésnek az anyagi támogatására is.

Végül két nagyobb tématerületen kezdtem tevékenykedni, amelyekben az a közös, hogy mind a két terület valamilyen IoT alapú rendszerehez kapcsolódik. Számomra azok a témakörök voltak érdekesekek, ahol a kutatásnak valamilyen kézzelfogható eredményei is vannak, ezért igyekeztem a kutatási és publikálási tevékenység mellett a kutatáshoz megépített mérőegységeket és a prototípusokat magam építeni. Ezt a szemléletmódot próbáltam magammal vinni a doktori tanulmányaim során. A kutatásom két nagyobb tématerületre oszlik.

Az első nagyobb témakör a kültéri légszennyezés monitoring rendszer fejlesztése, ahol a szenzor technológia fejlődésével elérhetővé váltak olyan költséghatékony szenzorok, amelyekkel korrelációba lehet mérni a kalibrált laborműszerrel. Ezen szenzorokkal kezdtem el foglalkozni. Kiválasztottam egy szállópor koncentráció mérő szenzort, amelynek megvizsgáltam a mérését. A szenzor mérésének javítása érdekében több kalibrációs eljárást hasonlítottam össze. Egy IoT alapú mérőhálózat fejlesztését is célként tűztem ki.

A másik nagyobb tématerület a tároló vágányokon történő vagon lokalizációs rendszer fejlesztése volt, ahol nem találtunk olyan elérhető eszközt, amely képes lenne ezt a feladatot önmagában ellátni. Ezen a tématerületen az volt a legnagyobb kihívás, hogy a rendszer működési elvét meghatározzam. Itt nem volt referencia sem az eszközökre, sem az eljárásokra vonatkozóan, így a meglévő általam ismert technológiákra tudtam csak építeni. Ez a kihívás motiválólágg hatott rám.

2 Kültéri szállópor koncentráció szenzor kalibrációs eljárások összehasonlító elemzése

Napjainkban, az elektromos autók tömeges megjelenése mellett még mindig számottevő a benzines és dízel autók száma, amik koncentráltan jelennek meg a nagyobb városokban. Télen főként a lakóházak fűtéséhez elégetett fa és egyéb tüzelőanyagok nagymértékben emelik meg a városok szállópor koncentrációját. Ezen felül a nagyobb ipari vállalatok is kibocsáthatnak olyan anyagokat, amelyek szintén jelentősen szennyezik a levegőt. Az Egészségügyi Világszervezet (WHO) arról számolt be, hogy hozzáférnek 3000 város levegőminőségi adatbázisához, ami a globális városi népesség mindössze 43%-át képviseli. 2020-ban a WHO kiderítette, hogy a lakosság körülbelül 90%-a olyan légszennyezési szinteknek van kitéve, amelyek meghaladják a megengedett határértékeket, különösen a közepes és alacsony jövedelmű fejlődő országokban. Ezért véleményem szerint fontos lenne a levegő minőségét nagy sűrűséggel mérni, főleg a nagyobb városokban.

A következő képet egyik Kollégám készítette, Miskolc Hejőcsaba városrészről 2017. január 26-án. Látható, hogy olyan mértékű a szennyezés, hogy a látási viszonyokat is rontja.



1. ábra - Miskolc egy téli, erősen szennyezett napon [3]

Magyarországon az OLM (Országos Légszennyezettségi Mérőhálózat) felel a városok levegőjének méréséért. Országsszerte építettek ki kalibrált mérőállomásokat, ahol mérik a

levegő szennyezettségét. Miskolcon is van 3 telepített mérőállomás: Martinkertvárosban, Hejőcsabán és a Búza téren. Az OLM állomások a következő adatokat mérik:

- PM10
- PM2,5
- SO₂
- CO
- NO
- NO₂
- NO_x

A fent felsorolt paramétereket $\mu\text{g}/\text{m}^3$ koncentrációban mérik az OLM állomások.

A kén-dioxid (SO₂) színtelen, mérgező gáz, amely vízzel érintkezve kénsavat alkot. A levegőben szulfáttá alakul és savas esőt okoz. Ez a legveszélyesebb légszennyező anyag. A szervezetben való ülepedése légúti megbetegedéseket okoz. A természetes forrása vulkánkitörések, erdőtüzek. Az emberek okozta forrásai a kén-sav gyártás, kohászat, erőművek és családi háztartások fűtése során keletkezik.

A nitrogén oxidok (NO_x) alatt a nitrogén-monoxid (NO) és a nitrogén-dioxid (NO₂) összességét értjük. Az OLM állomások általában mind a 3 paramétert mérik. A levegő 78%-a nitrogén, amely hő hatására oxidálódik és nitrogén-oxidok jönnek létre. Nitrogén-oxidok jönnek létre villámláskor, az autókban az üzemanyag égésekor, valamint a gázkazánokban. Jelenléte nagy szerepet játszik a fotokémiai szmog kialakulásában. Az emberekre és állatokra is káros hatással van, a légutak nyálkahártyáját és a szem kötőhártyáját irritálja, 200 $\mu\text{g}/\text{m}^3$ fölött roncsolja a tüdő szöveteit.

A szén-monoxid a szénvegyületek tökéletlen égésekor keletkezik. Színtelen, szagtalan, íztelen gáz, ezért nehéz észrevenni a jelenlétét. Szén-monoxid mérgezés tünetei lehetnek a látás, illetve hallás romlás, valamint szédülés. A szén-monoxid mérgezések többnyire télen történnek, viszont megfelelően karbantartott fűtőberendezéssel elkerülhető, valamint szén-monoxid érzékelő felszerelésével minimalizálható a mérgezés kockázata.

A PM10 a 10 μm -nél kisebb szálló por részecskéket, a PM2,5 pedig a 2,5 μm -nél kisebb szálló por részecskék jelenlétét jelenti. Ez az úgynevezett finomszemcsés szállópor szilárd és folyékony halmazállapotú anyagokból is állhat. Tartalmazhat savakat, amelyek a levegő nedvesség tartalma és a légszennyező gázok elegyéből áll. Származhat fűtésből

és főleg a dízel gépjárművekből származó égési melléktermékekből. Lehetnek benne fémek és gombák, vírusok, valamint a talajerózió során létrejövő por. A 10 μ m alatt a szállópor részecskék már belélegezhetők, viszont a nagyrésze fennakad az orrban és a nyálkahátyán. A legveszélyesebb a 4 μ m alatti mérettartomány, mert az eljut egészen a tüdőbe és le is rakódik a hörgőkben, így csökken az oxigén-felvevő képesség, amely által pedig jobban terhelődik a szív.

A fenti paraméterek közül a PM10 10 μ m-nél kisebb szállópor részecskék jellemzik a legjobban a légszennyezettséget, ugyanis az 1 μ m alatti mérettartományt az egyes kén- és szén-oxidok és befolyásolják.

Mint említettem, a nagyvárosok levegőminőség méréséért minden országban a környezetvédelmi szervezetek a felelősek, Magyarországon az OLM. Magyarországon az OLM állomások laborműszerekkel vannak felszerelve, amelyeket folyamatosan hitelesítenek, így mindig hiteles adatokat közölnek. Miskolcon a következő helyeken kerültek telepítésre mérőállomások.

1. táblázat – OLM Miskolcon használt műszerei

Mérőállomás	Városrész	Műszer	Mérési elv	Mért szállópor tartomány	Ár [millió Ft]
Lavotta utca	Görömböly	FH62 C14	β -abszorciós	PM10	2 - 6
Alföldi utca	Martinkertváros	GRIMM EDM180	Lézeres	PM1, PM2.5, PM10	8 -10
Búza tér	Városközpont	MP101M	β -abszorciós	PM2.5, PM10	6 - 12


A Lavotta utca és a Búza téri műszerek a szállópor koncentráció port β -abszorciós elven működő szenzorokkal mérik, amelyben található egy szűrő papírszalag, amelyre lerakódik az átszívott levegőben lévő por. A β -abszorciós műszer β sugarakat ló a szűrőre és az áteresztő képesség alapján számítja ki a porkoncentrációt. Az Alföldi utcán lézeres szenzorral mérnek, amely a részecskékről visszeverte fényből számítja ki a koncentrációt.

Az utóbbi években viszont megjelent számos olyan új részecskeszámlálós, optikai elven működő olcsó szenzor, amelyek alkalmasak lehetne a szállópor koncentráció indikatív mérésére és 4000 – 15000 Ft-között van az áruk.

A Miskolci Egyetem FIEK (Felsőoktatási Ipari Együttműködési Központ) projektjének keretein belül az ÉMI Nkft.-vel (Építésügyi Minőségellenőrző Innovációs Nonprofit Kft.) célként tűztük ki, hogy kifejlesztünk egy több szenzorból álló mérőhálózatot. A mérőhálózat célja, hogy egy spektrális anomália térképet tudjunk az adatokból interpolálni, amely jól szemléltetné a légszennyezettséget városszerte.

A méréshez a PM10 (<10 μ m) szállópor koncentráció paramétert választottam ki, amely jól reprezentálja a szennyezés mértékét és jelenleg már sokféle szenzor megtalálható a piacon ennek a paraméternek a mérésére. Ezért kezdtem el a kutatást ebben a témakörben. A célom, hogy egy olyan mérési rendszert dolgozzak ki, amely képes szállópor adatok gyűjtésére, tárolására, valamint képes a szenzor adatokat kalibrálni és osztályozni a spektrális megjelenítéshez.







A következő képen látható egy anomália térkép, amelyhez hasonlót hozunk létre.



2. ábra - Szállópor koncentráció anomália térkép [4]

A térkép spektrális színezéséhez az AQI (Air Quality Index) osztályozást veszem alapul [1].

2. táblázat - Szállópor koncentráció AQI szerinti osztályozása

AQI osztály	Színjelölés	PM10 [$\mu\text{g}/\text{m}^3$]
Jó		0-54
Mérsékelt		55-154
Egészségtelen az érzékenyek számára		155-254
Egészségtelen		255-354
Nagyon egészségtelen		355-424
Veszélyes		425+

Az egyes tartományok különböző mértékig egészségügyi hatással vannak az emberekre:

- **Jó:** A levegő minősége alkalmas a zavartalan kint tartózkodáshoz, ebben a tartományban a légszennyezettség nem jelent kockázatot.
- **Mérsékelt:** A levegő minősége ebben a tartományban még elfogadható, ám bár egészségügyi aggodalomra adhat okot a légszennyezésre fokozottan érzékenyek számára. A légúti betegségben (pl.: asztma) szenvedő gyerekeknek, illetve felnőtteknek korlátozniuk kell a hosszan tartó kint tartózkodást.
- **Egészségtelen az érzékenyek számára:** A légszennyezésre érzékenyek egészségügyi hatásokkal számolhatnak. A légúti betegségben (pl.: asztma) szenvedő gyerekeknek, illetve felnőtteknek korlátozniuk kell a hosszan tartó kint tartózkodást.
- **Egészségtelen:** A levegő minősége egészségtelen, a kint tartózkodók számolhatnak egészségügyi következményekkel, az érzékenyebbek súlyos következményekkel számolhatnak. Mindenkinek korlátoznia kell a kint tartózkodás idejét.
- **Nagyon egészségtelen:** Az egész lakosságot érintő egészségügyi hatásokkal jár. Mindenkinek korlátoznia kell a kint tartózkodás idejét.

- **Veszélyes:** Az egész lakosságot érintő súlyos egészségügyi hatásokkal jár. Mindenkinek korlátoznia kell a kint tartózkodás idejét.

Olyan mérőrendszert kifejlesztését tűztem ki célul, amely lehetővé teszi a nagy sűrűségű mérések végzését, hogy elérje a teljes városi lefedettséget. Képes legyen kezelni akár több 100 szenzorból álló mérőhálózatot. Rendszerünk adatai lapján fel lehessen ismerni a szennyezési gócpontokat, lehetővé téve a gyors beavatkozást és segítve az illegális hulladékégetés megállítását. Célunk a társadalom hozzáállásának megváltoztatása a légminőség minőség mérésével kapcsolatban.

2.1 Költséghatékony szállópor mérő szenzorok tudományos irodalmi áttekintése

A kutatást az egyes, szállópor mérésre alkalmas szenzorok irodalom-, valamint piackutatásával kezdtem. Ezen fejezet célja, hogy áttekintést adjon arról, hogy mi az aktuális trend ezen a tudományterületen. A továbbiakban szeretnék betekintést nyújtani az adott tudományterületre néhány olyan szakirodalom bemutatásával, ami meghatározta kutatásom irányát.

[T1] Ebben a cikkben a Sharp GP2Y1010AU típusú szenzornak állítják fel a hőmérséklet és páratartalom kalibrációját egy Dylos DC1100 szenzor segítségével. Megalkotnak egy modellt, amellyel átszámítva a nyersadatokat egy sokkal simább adatgörbét kapnak. A cikkben pozitív hipotézist állítanak a Sharp GP2Y1010AU szenzor hőmérséklet és páratartalom kalibrációja utáni mérési pontosságáról. Azt állítják, hogy így már megfelelő pontosságú környezeti méréshez. A szenzorkalibráció menete a következő volt:

- Konstans hőmérséklet és porkoncentráció, változó páratartalom.
- Konstans páratartalom változó hőmérséklet.
- Konstans hőmérséklet és páratartalom változó porkoncentráció.

Ezt a kalibrációs méréssorozatot a továbbiakban mi is felhasználhatjuk a szenzoraink kalibrációja során.

[T2] Ebben a cikkben IoT alapú környezeti levegő minőség mérő szenzort készítenek, amely a szállóporon kívül CO (szén-monoxid) koncentrációt is tud mérni. Az eszköz az adatait emailben tudja továbbítani a felhasználók számára, valamint fejlesztettek hozzá egy applikációt, amelyen keresztül több szenzor node is lekezelhető. Az eszközben a Sharp GP2Y1010AU szenzort használták a porkoncentráció mérésére.

[T3] A cikkben egy TEOM 1405 típusú gép segítségével vizsgálnak több olcsó szenzort. Ez egy olyan gép, amely képes szabályozni a porkoncentrációt egy zárt térben. Többféle méretű részecske-koncentrációt mértek, valamint kevert nagyságú részecske-koncentrációt is. A mérések során az adott méretű részecskék eloszlását lineárisan növelték a szenzorok környezetében. A mérések alapján arra a következtetésre jutnak, hogy a porkoncentráció és a szenzorok által mért adatok között kimutatható, hogy lineáris összefüggés van, így alkalmasak a környezeti felhasználásra, viszont amennyiben pontos $\mu\text{g}/\text{m}^3$ értéket szeretnénk kapni, úgy tudnunk kell adott térfogatban a részecskék tömegkoncentrációját.

[T4] Ebben a cikkben olyan mozgó alkalmazásokat mutatnak be, ahol forgalmas útvonalak mentén határozzák meg az egyes forgalmi szereplőkre jutó átlagos szállópor szennyezést. Mozgó alkalmazásokra az olcsó szenzorok nem alkalmasak a levegőáramoltatás módja miatt.

[T28] A tanulmány célja egy alacsony költségű részecskemérő szenzor terepi tesztelése és adatkalibrációja a finom részecskékkel való expozíció felmérése érdekében. A kutatás során különféle kalibrációs módszereket használtak, hogy pontos kalibrációs egyenleteket dolgozzanak ki ezekhez a szenzorokhoz, és az eredményeket referencia műszerekkel hasonlították össze. A terepi teszteként Santiago, Chile különböző helyszínein végezték. A szenzorokat referencia állomások közelében helyezték el, hogy összehasonlítsák az általuk mért adatokat a referencia műszerek által szolgáltatott adatokkal. A szenzorok méréseinek időbeli felbontása három percenkénti volt, és az adatokat automatikusan egy felhőalapú tároló platformra továbbították. A tesztek során kiderült, hogy az alacsony költségű szenzorok használhatóak a szállópor részecskék mérésére, azonban a pontos kalibráció és az adatok helyes feldolgozása elengedhetetlen a megbízható eredmények eléréséhez. Kimondja továbbá:

“Fontos megjegyezni, hogy a kereskedelmi forgalomban kapható eszközök nyers kimenetei jelentősen túlbecsülhetik a PM_{2.5} koncentrációkat (a vizsgálat eredményei szerint akár 2,5–5-szörös eltérés is megfigyelhető lehet). Ennek oka lehet, hogy a szenzorokat a gyártó olyan részecskékkel kalibrálja, amelyek tulajdonságai teljesen eltérnek a monitorozott levegő részecskéitől. Ezért a PM szenzorok kalibrálását (vagy újrakalibrálását) a végső mérési környezetben kell elvégezni. Az ilyen kalibrálás leggyakoribb módszere az együttműködő magasabb osztályú műszer adataira alapul.”

[T30] A cikk a PMS7003 alacsony költségű optikai részecske szenzorok kalibrációs képleteinek meghatározásához használt különféle regressziós módszereket hasonlítja össze. A tanulmány egy évnnyi adatgyűjtésen alapul, amely során a PMS7003 szenzorokat a TEOM 1400a kutatási műszerrel együtt használták, különös tekintettel a PM2.5 frakcióra. Az eredmények szerint az egyszerű egyváltozós regressziós modellek elegendőek voltak a jó illeszkedés eléréséhez, viszont a legjobb eredmény neurális háló betanítással érhető el. Továbbá a cikk megállapítja, hogy egyes PMS7003 szenzorok jó reprodukálhatóságot mutatnak, amit azt jelenti, hogy egymáshoz képest egyformán mérnek.

[T31] A tanulmány az alacsony költségű szállópor szenzorok mérését vizsgálja. A kutatás megállapította, hogy az ilyen szenzorok, különösen a PMS7003 típusúak, hasznos eszközök lehetnek a szállópor változásainak indikációs monitorozására. Ezek a szenzorok nagy reprodukálhatóságot mutatnak, ami azt jelenti, hogy egy egységre kidolgozott kalibrációs egyenletek más egységeknél is alkalmazhatók, minimális pontosságvesztéssel. Az egyszerű regressziós modellek eredményei alapján a PM1 kimenet jobb eredményeket mutatott, mint a PM2.5 kimenet. A többszörös regresszió bevonása és további változók, mint a hőmérséklet és páratartalom, javíthatják a modell illeszkedését. A lépésenkénti regresszió használata kompromisszumot kínál az egyszerűség és az illeszkedés pontossága között. Az neurális hálók is hatékonyak lehetnek az adatok kalibrációjában, de érzékenyek az adateltérésekre. A kutatás eredményei azt mutatják, hogy az alacsony költségű szenzorok hatékonyan alkalmazhatók a levegőminőség monitorozásában, de a pontos kalibráció és az adatfeldolgozás kulcsfontosságú a megbízható eredmények eléréséhez.

[T32] Az alacsony költségű szenzorok kalibrációs módszereit vizsgálja a magas színvonalú szállópor monitorozás érdekében. A kutatás során különféle regressziós modelleket alkalmaztak, hogy pontos kalibrációs egyenleteket dolgozzanak ki ezekhez a PMS7003 szenzorokhoz. A tanulmányban használt PMS7003 szenzor adatokat és a TEOM 1400a műszer mérésével hasonlították össze. Összességében az alacsony költségű PMS7003 hatékonyan alkalmazhatók a levegőminőség monitorozására, de a pontos kalibráció és az adatok helyes feldolgozása elengedhetetlen a megbízható eredmények eléréséhez.


A fent bemutatott cikkek bizonyítják, hogy ez egy aktívan kutatott terület és nagyon sokan a szenzorok kalibrációjával foglalkoznak. Megállapítható, hogy ezeket az olcsó

szenzorokat kalibrálni kell, valamint a kalibráció után alkalmasak a szállópor indikatív mérésére. Úgy gondolom, hogy a kalibráció eredménye különböző földrészeken, országokban vagy akár településenként is eltérhet a levegőben jelenlévő szennyezők függvényében. Más-más országokban mások a fűtési és közlekedési szokások, amelyből a szennyezők nagy része származik. Ezt a feltevést a [T28] támasztja alá. A kalibrációra különböző regressziós módszereket, valamint neurális hálót használnak. A mérési jószágának reprezentálására RMSE és R^2 értéket használnak. A legtöbb cikkben a Plantower PMS7003 szenzorral foglalkoznak, amely több cikk megállapítása alapján [T30][T31] jó reprodukálhatóságot mutat több szenzorral való referencia mérés esetén.

A kutatásom célja, hogy az általam kiválasztott szállópor koncentráció szenzorral elvégezzek egy terepi tesztmérést Miskolc-Martinkertváros Alföldi utcán lévő OLM állomás GRIMM EDM180 kalibrált műszer mellett. Az adatokat a fent talált irodalom alapján szeretném regressziós, valamint neurális háló alapú modellekkel kalibrálni. Az eredményeimet a fent leírtakkal az eltérő mérési környezet miatt nincs értelme összehasonlítani. A különböző fűtési és közlekedési szokások miatt eltérő eredmények szülehetnek.

2.2 Az elérhető költséghatékony eszközök rendszerezése

Ennek a fejezetnek a célja, hogy bemutassam a piacon jelenleg kapható költséghatékony szenzorokat. Ezen szenzorok mindegyike optikai úton érzékeli a szállóport. A fejezetben bemutatott szenzorok egy része megegyezik az irodalomkutatásban már említett (PMS7003, GP2Y1010) szenzorokkal. A szenzorokat az általuk használt kommunikációs interfész alapján fogom rendszerezni. Az első csoportot a digitális, vagy analóg IO-val rendelkező szenzorok alkotják.



3. ábra – Fűtő ellenállás alapú szállópor mérő szenzor elvi felépítése [saját szerkesztés]

A következő táblázatban szemléltetem a piacon kapható hőáramoltatás elven működő szenzorokat.


3. táblázat - Digitális/Analóg IO-val rendelkező szenzorok

Szenzorok	Sharp	Shinyei	Samyoung	Amphenol
Típus szám	GP2Y1010AU0F	PPD42NS	DSM501A	SM-PWM-01C
Méret [mm]	46*30*18	59*45*22	59*45*20	59*46*18
Detektálható méret	N/A	~ 1.0 μm	~ 1.0 μm	~ 1.0 μm
Mértékegység	0,5 mg/m^3	28 000 db/liter	1,5 mg/m^3	$\mu\text{g}/\text{m}^3$
Interfész	Analóg kimenet	Digitális (PWM)	Digitális (PWM)	Digitális (PWM)

A fent (3. táblázat) bemutatott szenzorok a Sharp GP2Y1010 kivételével PWM (Pulse-Width Modulation) interfésszel rendelkeznek, valamint az érzékelő közelében egy fűtőellenállással előidézett hőáramlással áramoltatják a levegőt. A PWM interfész úgy működik, hogy ha egy részecske a detektor és a gerjesztő fényforrás közé kerül, a PWM kimenet alacsony értéket vesz fel. Az alacsony impulzus hossza arányos lesz a részecskék

átmérőjével. Amennyiben tudjuk a részecskék adott térfogatra megadott tömegét, ki tudjuk számítani a koncentrációt $\mu\text{g}/\text{m}^3$ -ben. A Sharp GP2Y1010 analóg kimenettel rendelkezik, amelynek a feszültsége arányos a szállópor koncentrációval. A hőáramoltatás mérési elve nem túl előnyös abban az esetben, ha a szenzor közelében a levegő nincsen nyugalmi állapotban. Tehát szeles vagy mozgó környezetben ezeknek a szenzoroknak a mért adatai nem lesznek megfelelőek.

A következő képen látható a ventilátorral ellátott szenzor, amely a levegő áramoltatását a detektor környezetében egy ventilátorral végzi.



4. ábra –Ventilátor alapú szállópor mérő szenzor elvi felépítése [saját szerkesztés]

A következő táblázat a ventilátoros szenzorokat tartalmazza.

4. táblázat – Piacon kapható beépített ventilátoros szenzorok

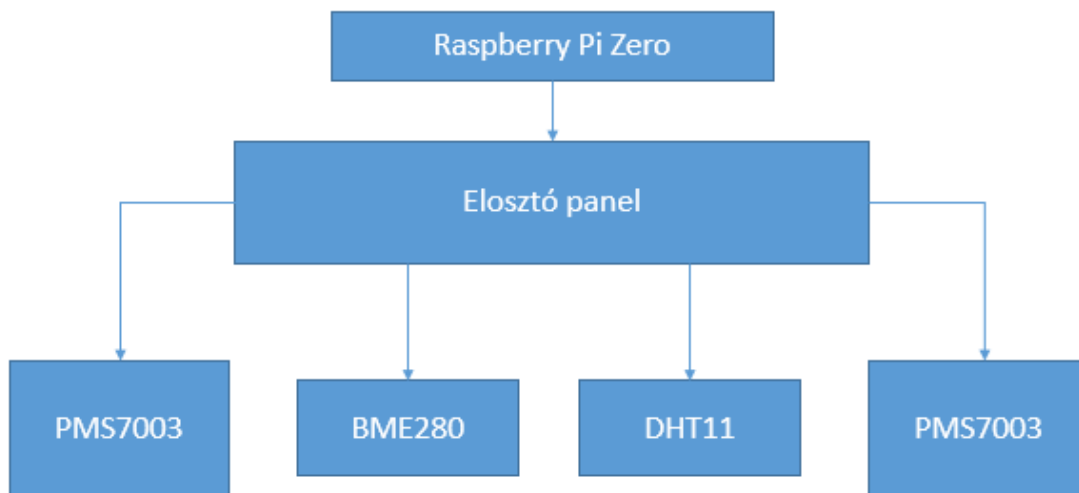
Szenzorok	Winsen	Honeywell	Plantower	Nova
Típus szám	ZH-03	HPMA215S0	PMS7003	SDS011
Méret [mm]	50*32,4*21	43*36*23,7	48*37*12	71*70*23
Detektálható méret	~ 1 μm	~ 1 μm	~ 1 μm	~ 1 μm
Mértékegység	$\mu\text{g}/\text{m}^3$	$\mu\text{g}/\text{m}^3$	$\mu\text{g}/\text{m}^3$	$\mu\text{g}/\text{m}^3$
Interfész	UART, PWM	UART	UART	UART

A 4. táblázatban bemutatott szenzorok mindegyike $\mu\text{g}/\text{m}^3$ értéket ad vissza, tehát valamilyen előzetes kalibrációval rendelkeznek, amelyet valahol elvégeztek. A kalibrációról az adatlapok nem írnak, ami hátrány, hogy a szenzorok nagy része kínai, ahol teljesen más a szállópor összetétele. Persze ettől még mérhet korrelációban a hitelesített szenzorokkal. Ami előnyös, hogy mindegyik egy ventilátorral áramoltatja át a levegőt az érzékelőn, így kevésbé lesz érzékeny a környezeti légállapotra. A Winsen ZH-03 szenzor hibrid kimenettel rendelkezik, amely azt jelenti, hogy van PWM kimenete is, amely a részecskék előfordulását jelzi, az UART-on pedig a már $\mu\text{g}/\text{m}^3$ -be átszámított értéket küldi. A PWM kiment lehetőséget ad arra, hogy a nyers adatokból lehessen kalibrálni a szenzort. A PMS7003 szenzor megadja különböző méreteken (0,3 μm , 0,5 μm , 1 μm , 2,5 μm , 5 μm , 10 μm) a részecskék darabszámát 1 dm^3 levegőben, amely szintén nyers, szűretlen érték. A többi szenzor nem szolgáltat hasonló adatokat, csak normál szállópor koncentrációt $\mu\text{g}/\text{m}^3$ -ben. Véleményem szerint ezen adatok kutatási szempontból nagy fontosságúak, mert ezek szűretlen nyers adatok, gyártói kalibráció nélkül. A méret-eloszlás mérése miatt a Plantower PMS7003 szenzorral fogok a továbbiakban foglalkozni. A következő képen látható a Plantower PMS7003 szenzor:



5. ábra - PMS7003 szállópor mérő szenzor [2]


A szenzor mérete mindössze 48mm×37mm×12mm. Egy egyedi fejlesztésű mérőegység építésébe kezdtem, amellyel a mérést végzem el. Lehetőségünk nyílt együttműködni az OLM állomásokat üzemeltető szervezettel és a Miskolc Martinkertváros mérőállomásra egy egyedi fejlesztésű szállópor mérő egységet helyeztem ki 2019. január 27-én. A kihelyezett szenzor egy GRIMM EDM180 típusú kalibrált műszer mellett méri az adatokat. A mérőegység a felépítését a következő ábrán keresztül szeretném szemléltetni.



6. ábra - Mérőrendszer felépítés [saját szerkesztés]

Az elosztó panel egy általam tervezett nyomtatott áramkör, amely tartalmaz egy 1A áramterhelhetőségű tápegységet, amely képes ellátni az egyes szenzorokat és a Raspberry Pi Zero-t is tápfeszültséggel, valamint beköti a Raspberry Pi Zero megfelelő lábait a

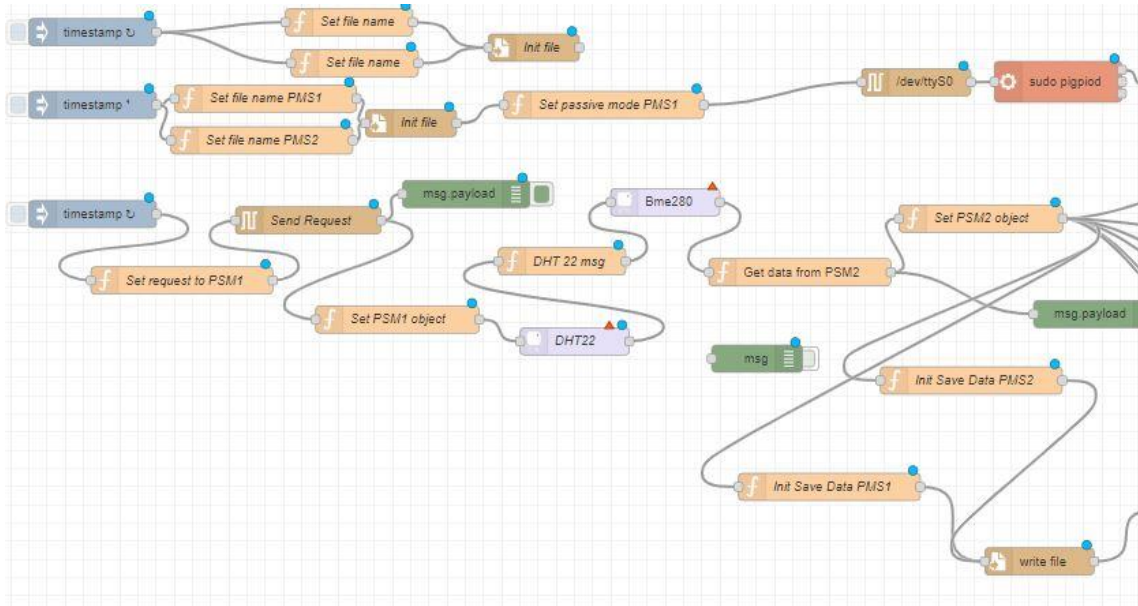
szenzor csatlakozókra a kommunikációhoz. Tartalmaz továbbá csatlakozókat az egyes szenzorokhoz, így egyszerűen össze lehet rakni a mérőegységet.



7. ábra – Egyedi fejlesztésű mérőrendszer

A Raspberry Pi Zero egy miniszámítógép, amely Raspbian (Debian ARM disztribúció) nevű operációs rendszert futtat, valamint rendelkezik egy SD kártyával, amely háttértárként funkcionál, ezt használjuk adatmentésre. A Raspberry Pi-n egy node-red szoftver fut, amely kiolvassa a szenzorok adatait, majd lokálisan elmenti a háttértárba. A szenzoradatok 6 másodpercenként kerülnek kiolvasásra és mentésre, amelyet azért választottam, mert így egy perc alatt 10 mérési adat áll rendelkezésre, és ha esetleg perces vagy órás átlagot kell előállítani akkor egyszerűen lehet átalgozni. A Node-RED egy böngészőalapú folyamatvezérelt programozási nyelv, amely megkönnyíti az egyes funkciók összekapcsolását. Egy 'node' egy adott funkciót valósít meg. Egy böngészőalapú szerkesztőt biztosít, amely megkönnyíti a funkciók összekapcsolását, valamint tartalmaz egy alap funkciókészletet, amely nagyban megkönnyíti a webes fejlesztést, valamint mivel Node-JS scprit nyelv alapú, ezért nem kell fordítani a szoftvert. Egy kattintással 'Deploy' láthatóvá tehető az eredmény. A fejlesztési környezet előnye, hogy moduláris, rugalmas és nem igényel nagy hardver erőforrást. További előny, hogy széleskörben használt, ezért sokan fejlesztik, így számos funkció elérhető az alap funkciókészletben [T23].

A következő ábrán szeretném szemléletetni a szoftver kinézetéről egy példát. A képen jól látható a Node-RED funkciók hogyan kapcsolódnak egymáshoz. Az ábra bemutatásával nem a részletes szoftver dokumentáció a célom, hanem hogy szemléltessem, hogyan néz ki a Node-RED a folyamat vezérelt programozása.



8. ábra - Node-Red Raspberry PI szoftver

A mérőrendszerben található 2 db PMS7003 szenzor, amelyek UART-on keresztül kommunikálnak a Raspberry Pi-vel. Azért helyeztem el két darab szenzort, hogy a két szenzor adatát adott esetben lehessen egymáshoz képest is vizsgálni, valamint amennyiben az egyik tönkremegy, úgy még mindig ott a másik szenzor, amellyel tovább tudjuk folytatni a mérést.

Beépítettem továbbá egy BME280 és egy DHT11 hőmérséklet és páratartalom szenzort. A BME280 I2C interfésszel rendelkezik, a DHT11 pedig 1 vezetékes soros kommunikáción (1wire) keresztül kommunikál a Raspberry Pi-vel. Ezt a kis adatgyűjtő rendszert egy U alakú PVC csőbe helyeztem el.

A következő képen látható az összeállított mérőrendszer.



9. ábra - Elkészült mérőrendszer

A fent látható mérőrendszert 2019.01.27-én telepítettük ki a Matrinkerváros Alföldi utcán található OLM állomásra. Az üzemeltetők biztosítottak nekünk a helyszínen betápot, amelyről a rendszer működött. A következő fotó a telepítésen készült.



10. ábra - Mérőrendszer kihelyezése

A Raspberry Pi-t úgy konfiguráltam fel, hogy rendelkezzen egy saját Wifi hálózattal, amelyhez a helyszínen lehetett csatlakozni. Amikor rácsatlakoztam, meg tudtam nézni az eszköz státuszát a saját beépített webszerverén keresztül, valamint így lehetett letölteni az adatokat is.

A következő táblázat szemlélteti a mért adatokat, valamint ezek mértékegységeit.

5. táblázat - Mérőrendszer által mért adatok

Megnevezés	Mértékegység	Példa
Időbélyeg	Dátum	2019.2.8 0:0:5
BME Nyomás	Pa	1009,02
BME Hőmérséklet	°C	3.2
BME Páratartalom	%	80,43
DHT Hőmérséklet	°C	2.8
DHT Páratartalom	%	77,56
1. PMS7003 PM10	µg/m ³	34
1. PMS7003 PM2,5	µg/m ³	25
1. PMS7003 PM1	µg/m ³	13
1. PMS7003 0,3 um részecskék darabszáma	db/dm ³	2345
1. PMS7003 0,5 um részecskék darabszáma	db/dm ³	254
1. PMS7003 1 um részecskék darabszáma	db/dm ³	23
1. PMS7003 2,5 um részecskék darabszáma	db/dm ³	10
1. PMS7003 5 um részecskék darabszáma	db/m ³	3
1 PMS7003 10 um részecskék darabszáma	db/m ³	1
2. PMS7003 PM10	ug/m ³	38
2. PMS7003 PM2,5	µg/m ³	22
2. PMS7003 PM1	µg/m ³	18
2. PMS7003 0,3 um részecskék darabszáma	db/dm ³	2387

Megnevezés	Mértékegység	Példa
2. PMS7003 0,5 um részecskék darabszáma	db/dm ³	243
2. PMS7003 1 um részecskék darabszáma	db/dm ³	28
2. PMS7003 2,5 um részecskék darabszáma	db/dm ³	8
2. PMS7003 5 um részecskék darabszáma	db/m ³	1
2. PMS7003 10 um részecskék darabszáma	db/m ³	0

2.3 Adatok feldolgozása

A cél, a mért rendelkezésre álló különböző adatokból egy olyan, elemzésre alkalmas adathalmazt alkotni, amely együtt tartalmazza az OLM és az általam kihelyezett szenzorok által mért adatsorokat. Az adatok 2019. február - 2019. december időintervallumban állnak rendelkezésre. A miskolci légszennyezettség mérő állomásokból sikerült lekérni perces felbontású adatokat.

Az általam mentett adatok szöveges formátumban kerültek átadásra. A különböző fájlok maximálisan egy napnyi adatot tartalmaznak, de olyan eset is lehetséges, hogy egy napnyi adatot 5-8 fájlból kell kinyerni. A mérés gyakorisága 6 másodperc, amennyiben minden szenzort sikerül kiolvasni, így percenként maximálisan 10 adat áll rendelkezésre. Az adatok típusait a fenti (5) táblázatban már bemutattam.

Az adatokat vesszővel elválasztva tartalmazzák az adatfájlok, valamint egy sor jelent egy mérést. Elemzésre, valamint validálásra 852 darab fájlt mentettem le, összesen 547 MB tárhelyet igényelnek.

Az OLM adatok szabvány CSV formátumban állnak rendelkezésre, amely szintén egy szöveges állomány, viszont kötött formátumú és így akár excellel is megnyitható. További előnye az excelhez képest, hogy sokkal gyorsabb a beolvasása.

A következő adatokat tartalmazza az OLM adatfájl.

6. táblázat - OLM által szolgáltatott adatok


Megnevezés	Azonosító	Mértékegység	Példa
Mérés időpontja	DateTime	DateTime	28/02/2019 23:03
PM10	PM10	$\mu\text{g}/\text{m}^3$	40,6
Szélirány	WDIR	Fok	300
Szélereősség	WSPE	m/s	3
Hőmérséklet	TEMP	$^{\circ}\text{C}$	2,1
Páratartalom	HUMI	%	76
PM2,5	PM25	$\mu\text{g}/\text{m}^3$	23,4

Az OLM adatok perces átlagokat tartalmaznak, viszont vannak benne kisebb nagyobb kimaradások, akár 1 napon belül többször is.

Mivel ezek szöveges fájlok és nem szabvány formátum, ezért úgy döntöttem, hogy egy egyedi szoftvert fejlesztek az adatok feldolgozására, amely tartalmazni fog egy egyedi szöveg/adat értelmezőt, valamint az adatmodellt is. Az eddigi tapasztalataim alapján a C# consol applikáció mellett döntöttem, amely alkalmas minden elvégzendő szoftveres feladatra.

Kétféle kimeneti adatsort hoztam létre, az egyiknél létrehoztam a perces átlagokat az általam mért adatokból és az OLM adatok mellé helyeztem. A másik fajta kimeneti adatsor ugyanezeket az adatokat órás átlagban tartalmazza. Így létrejött az adathalmaz, amelyen vizsgálni lehet a PMS7003 szenzor különböző hibáit.


A következő ábrán látható egy téli napi adatsor.



11. ábra - OLM PM10 és PMS7003 adatok 2019.02.28

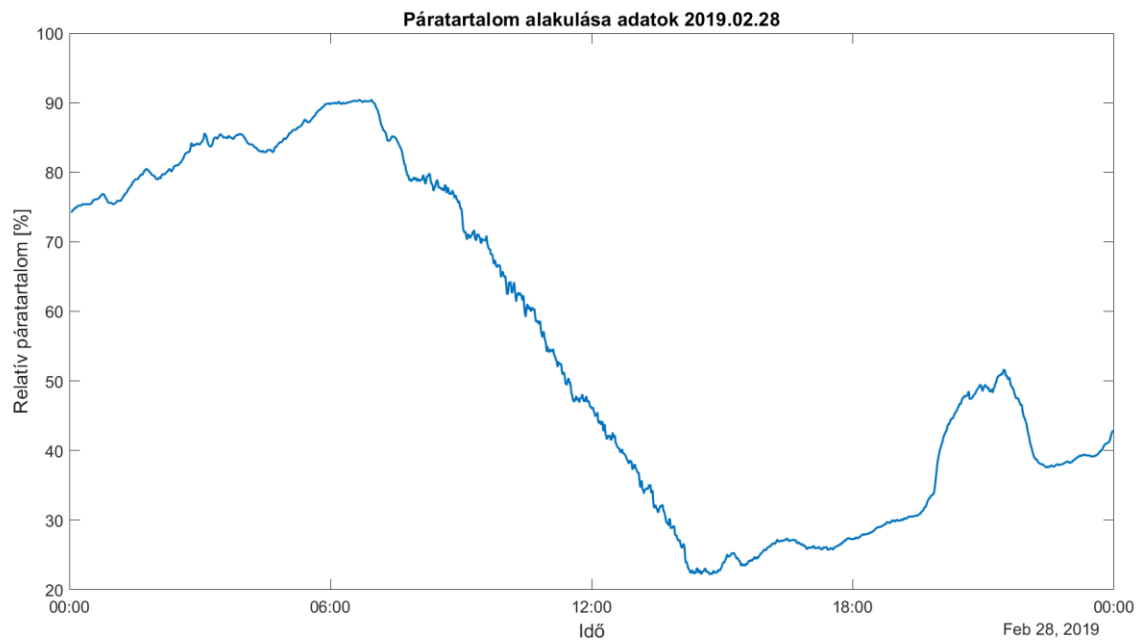
A fent példában látszik, hogy éjfél és reggel 9:00 tartományban a kalibrált szenzor fölé mér (napi átlagban: $12,78 \mu\text{g}/\text{m}^3$ -at, legmagasabb kiugró ponton 01:02:00-kor $83,4 \mu\text{g}/\text{m}^3$ a különbség). Az alacsonyabb tartományokban pontosabb a mérés. A mérési adatsoron jól látszik a téli fűtés a 6:00 óra utáni emelkedése arra utal, hogy akkor begyűjtanak, valamint a 19:00 utáni emelkedés is valószínű emiatt van. Az éjfél és 9:00 közötti felé mérés okának feltárása érdekében nézzük meg a hőmérsékleti és páratartalmi viszonyokat.

A következő ábrán látható a hőmérséklet alakulása.



12. ábra - Hőmérséklet alakulása 2019.02.28


A következő képen látható a páratartalom alakulása.



13. ábra - Páratartalom alakulása 2019.02.28

A két ábrát áttakintve azt a következtetést tudom levonni, hogy az éjfél és 9:00 közötti 85 % fölötti páratartalom okozhatja a mérési adatok eltérését.

A következő ábrán látható egy nyári napi adatsor.



14. ábra - OLM PM10 és PMS7003 adatok 2019.08.15

Látható, hogy nyáron a fűtési szezonon kívül alacsonyabb a mért érték. A fenti két példa mutatja, hogy az adatokból mostmár előállt egy olyan formátum, amelyen már le lehet futtatni a kalibrációs eljárásokat. Az adatokon a kalibrációs eljárások futtatás előtt, elvégeztem egy adat tisztítást, amely a durván kiugró értékeket és a 0 mérések törlését jelentette. Erre azért volt szükség mert, az OLM-től kapott adatokban voltak 0 értékek, amelyek fals adatok voltak.

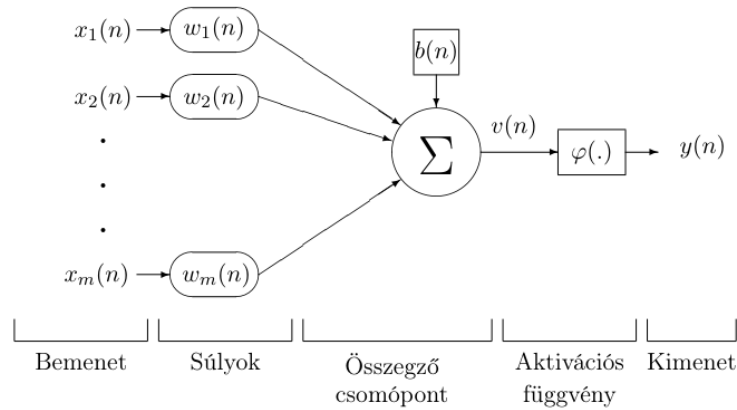
2.4 Kalibrációs eljárások bemutatása

Ebben a fejezetben a lineáris regresszió, neurális háló alapú modellezés alapjait mutatom be, valamint egy Growing factor nevű eljárást, amely a részecskék hidrophil tulajdonságait hivatott kompenzálni.

2.4.1 Neurális háló

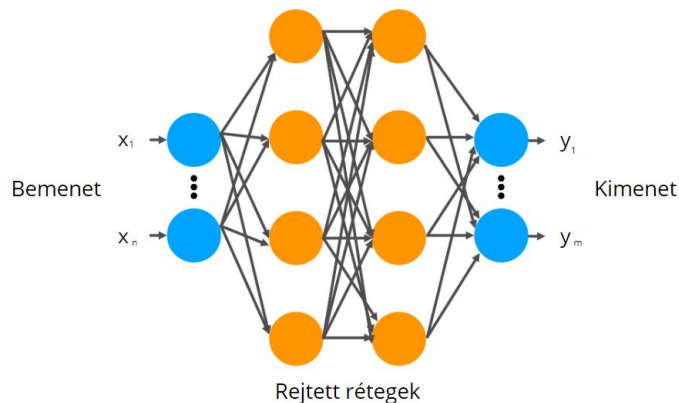
A neurális hálózatok (Neural Network, röviden NN) olyan mesterséges intelligencia rendszerek, melyek az emberi agy neuronhálózatainak működését utánozzák. Ezek a rendszerek képesek megtanulni és felismerni mintázatokat adathalmazokban, így használhatók különféle feladatok megoldására, például képfelismerésre, előrejelzésekre és az aktuális témát tekintve kalibrációs eljárásokhoz egyaránt. A neurális hálózatok alapeleme a neuron. A neuronok, más néven idegsejtek, az információfeldolgozás

alapegységei a neurális hálózatban. A legegyszerűbb neurális hálózat egyetlen neuronból áll. Az 15. ábrán egy neuron látható, amely általánosan reprezentálja a perceptron sémáját [T5].



15. ábra - Perceptron sémája [T5]

A mély neurális hálók (Deep Neural Networks, DNN) a mesterséges intelligencia és gépi tanulás területén használt modellek, melyek több rétegből álló neurális hálózatok. A hálózat rétegekből tevődik össze, ahol a bemeneti réteg az adatokat fogadja, a kimeneti réteg pedig az eredményeket szolgáltatja, közte pedig rejtett rétegek találhatóak. A rejtett rétegek az adatokat különböző szinteken dolgozzák fel (16. ábra).



16. ábra - Többrétegű neurális háló sematikus ábrája [saját szerkesztés]

A neurális hálózatnak több fajtája is létezik [T6]:

- Többrétegű Perceptron (MLP - Multilayer Perceptron): A legelterjedtebb neurális hálózat típus, melyben több rejtett réteg található az bemeneti és kimeneti rétegek között.
- A DBN (Deep Belief Network) egy típusa az összetett neurális hálóknak. Ez egy olyan architektúra, amelyben a neuronok réteges szerkezetben helyezkednek el,

és amely az egyes rétegek közötti kapcsolatokon keresztül képes bonyolultabb, hierarchikus jellemzők kinyerésére és reprezentációk kialakítására. A DBN-t gyakran felhasználják gépi tanulási feladatokban, például osztályozásban, mintázatfelismerésben vagy dimenziócsökkentésben. Azáltal, hogy hierarchikus jellemzőket tanul ki az adatokból, a DBN hatékonyabban tudja reprezentálni az adatokat, és javíthatja a gépi tanulási modell teljesítményét.

- Konvolúciós Neurális Hálózat (CNN - Convolutional Neural Network): Kifejezetten képfeldolgozásban és más térbeli adatokban használt hálózat, melynek konvolúciós rétegei kiemelik a képekben található fontos jellemzőket.
- Rekurrens Neurális Hálózat (RNN - Recurrent Neural Network): Olyan hálózat, amely képes visszacsatolást alkalmazni a korábbi időlépések eredményeinek figyelembevételével, gyakran idősorok és nyelvi modellezés területén alkalmazzák.
- Rekurrens Szekvencia Generáló Hálózat (RSGN - Recurrent Sequence Generative Network): Egy speciális típusú RNN, amely a bemeneti adatok alapján képes új, korábban nem látott adatok generálására.
- A GRU (Gated Recurrent Unit) egy típusa a rekurrens neurális hálózatnak. A GRU-t olyan feladatokban alkalmazzák, ahol az időbeli vagy sorrendi információk fontosak, például idősorok vagy nyelvi modellezés esetén. A GRU általánosan elterjedt a gépi fordítás, szöveggenerálás és idősorok előrejelzése területén, ahol hatékonyan kezelheti a hosszú távú függőségeket és segíthet javítani a modell teljesítményét.
- Hosszú és Rövidtávú Memóriával Rendelkező Hálózatok (LSTM - Long Short-Term Memory): Ezek a hálózatok kifejezetten az RNN gyengeségeivel szemben jöttek létre, hosszútávú függőségek kezelésére alkalmasak.

A neurális hálózat alkalmazásának fő lépései:

1. a modell létrehozása,
2. a modell betanítása,
3. a modell használata.

A modell kiválasztása a specifikus probléma alapján történik, például rendszámfelismerés vagy képfeldolgozás esetén az ismert modell osztályok közül választunk, figyelembe véve saját tapasztalatainkat. Például, ha MLP-t használunk, akkor annak specifikációit is meg kell adnunk. A modellt ezután betanítjuk a konkrét adatokra. A tanulási folyamat

során a hálózat az úgynevezett súlyokat módosítja a bemenetek és a várt kimenetek közötti hibák minimalizálása érdekében. A neurális hálók képesek nemlineáris kapcsolatokat is megtanulni, ami különösen hasznossá teszi őket komplex problémák megoldásában. A mérések validációját az RMSE és az AQI szerinti egyezséggel fogjom elvégezni. Nem képzünk külön teszt adatsort.

A neurális hálók betanításának az alábbi három módja van [T6]:

- Felügyelt tanítás: Ebben az esetben a hálózatot olyan bemeneti adatokkal és hozzájuk tartozó elvárt kimeneti értékekkel tanítjuk, amelyeket előzetesen címkéztek vagy osztályoztak. A tanítás során a hálózat az adatokból próbálja meg a megfelelő kimenetet előállítani és a tanítási adatok alapján módosulnak a súlyok és paraméterek annak érdekében, hogy a kimenet minél közelebb legyen a várt értékhez.
- Felügyelet nélküli tanítás: Itt a hálózatot olyan bemeneti adatokkal tanítjuk, amelyekhez nem társítottunk címkéket vagy osztályozást. A cél általában az, hogy a hálózat megtanulja a bemeneti adatok közötti struktúrákat, mintázatokat, vagy a reprezentációkat kinyerni anélkül, hogy specifikusan meghatároznánk a kimenetet.
- Megerősítő tanulás: Ebben az esetben a hálózatot egy környezettel való interakció során tanítják. A hálózatnak nincsenek előre meghatározott bemeneti-kimeneti párijai, ehelyett visszajelzést kap a környezettől és ennek függvényében próbálja megtanulni az optimális viselkedést. A cél az, hogy a hálózat megtanulja, hogy milyen cselekedetek vezetnek a legnagyobb jutalomhoz vagy haszonhoz a környezetben, és ezáltal maximalizálja a jutalmakat vagy minimalizálja a büntetéseket. A megerősítő tanulás például alkalmazható játékokban, robotika, autonóm járművek és egyéb interaktív rendszerek tervezésében és vezérlésében.


Az utóbbi években a számítási kapacitás növekedése és a nagy adathalmazok elérhetősége jelentősen hozzájárult a neurális hálók fejlődéséhez. Az iparban és a tudományos kutatásban is egyre több területen alkalmazzák őket, jelentős eredményeket érve el.

Kisméretű, célzott neurális hálózatok már ma már viszonylag kis teljesítményű környezetben, is futtatható illetve taníthatók. Például ilyen hálózatokat lehet alkalmazni nagy adatbázisokban, hogy kiszűrjék az összetartozó adatokat, automatizálják a

kapcsolatok és összefüggések keresését, melyek klasszikus statisztikai algoritmusokkal nehezen elemezhetők [T7].

2.4.2 Lineáris regresszió

A mérési hiba kiküszöbölésére szeretnék lineáris regressziós model alapú megoldást is adni és megvizsgálni milyen eredményt nyújt. A lineáris regresszió egy adott pontfelhőre képes ráilleszteni egy egyenest, feltételezve, hogy a pontok között lineáris kapcsolat van. A következő képen látható egy példa, hogyan is néz ki a PMS7003 mérési adata az OLM által mért koncentráció függvényében.



17. ábra - Lineáris regressziós modell

Ebben az esetben a PMS7003 szenzorból származó adatok predikátor értékek, továbbiakban x_1, x_2, \dots, x_n . Az OLM mérési pontjai pedig az úgynevezett predikált értékek, továbbiakban y_1, y_2, \dots, y_n . A predikátor és a predikált értékek kapcsolatát leíró egyenes általános összefüggése a legkisebb négyzetek módszere alapján írható fel. A következő összefüggés az \hat{a} az egyenes meredekségét írja le.

$$\hat{a} = \frac{\sum_{i=1}^n (x_i - \bar{x}) * (y_i - \bar{y})}{\sum_{k=1}^n (x_k - \bar{x})^2} \quad (1)$$

Ahol,

n a mérési pontok száma,

i, k az iterátor változó,

\bar{x}, \bar{y} a predikátor és predikált érték halmazok átlaga,

x_k, x_i, y_i pedig az iterátorok i, k által kijelölt predikátor és predikált változók.

A következő összefüggéssel az y tengelyen való metszéspont határozható meg.

$$\hat{b} = \bar{y} - \hat{a} * \bar{x} \quad (2)$$

Ahol,

\bar{x}, \bar{y} a predikátor és predikált érték halmazok átlaga,

\hat{a} az egyenes meredeksége.

Így az egyenes egyenlete a következő összefüggéssel írható le.

$$f(x) = \hat{a} * x + \hat{b} \quad (3)$$


A becslés hibáját az átlagos négyzetes hibával, vagy R^2 -el szokták jellemezni.

2.4.3 Growing factor

A feltevésem szerint a PMS7003 szenzor mérései hibája függ a páratartalomtól. Ezért kezdtem el megoldást keresni ennek a kompenzációjára. Nagyobb páratartalom esetén, az 1 μm körüli részecskék összeragadnak és nagyobb egységeket alkotnak, valamint megduzzadnak, amennyiben hidrofil részecskéről van szó. A hitelesített szállópor mérő laborműszerek ezt úgy oldják meg, hogy a levegőt előkészítik 50%-os páratartalomra és így folyamatosan változatlan páratartalomra mérnek.

Az általam használt PMS7003 szenzor megadja a szállópor részecskék eloszlását adott mérettartományokra.

Ahogy azt már említettem, a szenzor képes elküldeni a szemcseméret eloszlást, amelyet a következő ábra szemléltet.



18. ábra - PMS7003 szenzor által mért szemcseméret méret szerinti eloszlása

A fenti oszlopdiagram által szemléltetett eloszlás függvényen jól láthatóak a kiemelt méretek. Az is jól látszik, hogy a kisebb méretű részecskéből jóval többet érzékel, mint a 10 μm -es részecskéből. A továbbiakban ebből az eloszlásból fogok számolni egy $\mu\text{g}/\text{m}^3$ értéket. Ehhez viszont szükség volt a szállópor sűrűségére. A [9] publikáció megad egy értéket, amely $\rho = 1,65 \text{ g}/\text{m}^3$. A szállópor részecskéket jó közelítéssel gömbként modellezem. Ezen érték, valamint a következő összefüggések alapján meg tudtam határozni a koncentráció-eloszlást:

$$V_i = \frac{\pi}{6} * (D_i)^3 \quad (4)$$

$$M_i = \rho * V_i \quad (5)$$

Ahol,

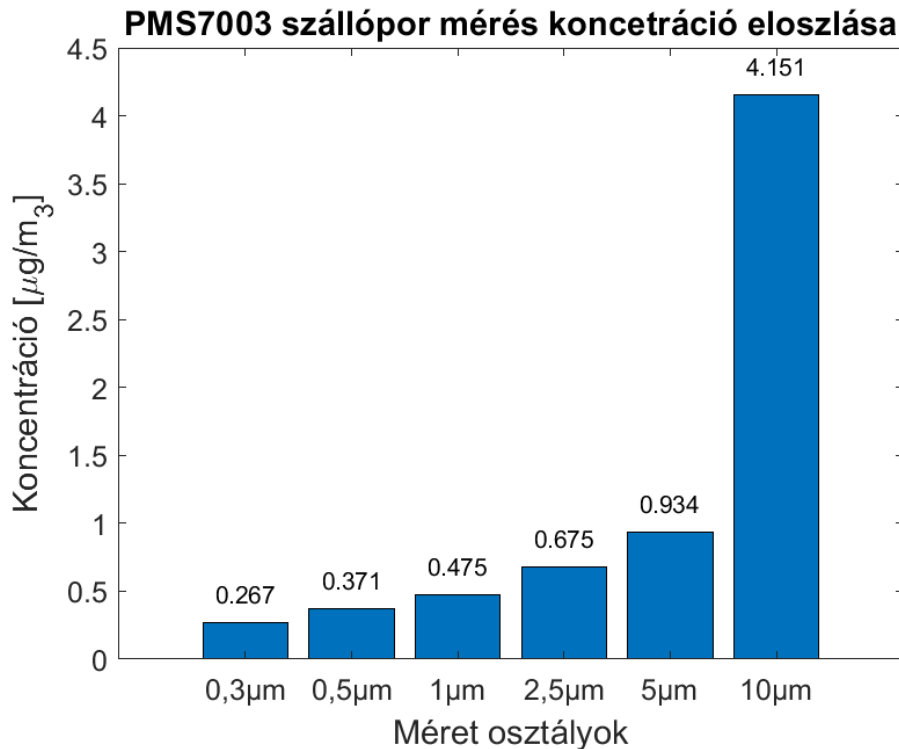
V_i a térfogat,

D_i az egyes méretekhez tartozó átmérő,

M_i a tömeg és,

ρ pedig a sűrűség.

A fenti (17. ábra) diagramon látható szemcseméret eloszlást átszámolva az (5) és (6) képlettel a következő ábrán látható koncentráció eloszlást kapjuk.



19. ábra - Átszámolt méret szerinti koncentráció eloszlás

Érdekes, hogy majdnem fordított állású diagramot kaptunk. Ez azzal magyarázható, hogy ugyan több 0,3 μm -es részecskét mért, a méretük viszont annyival kisebb, hogy a tömeget már a 10 μm -es, valamint a nagyobb méretű részecskék fogják jobban befolyásolni. A PM10 koncentrációt a következő összefüggéssel kapjuk a koncentráció-eloszlásból.

$$PM10 = \rho * (n_{0,3\mu\text{m}} * V_{0,3\mu\text{m}} + n_{0,5\mu\text{m}} * V_{0,5\mu\text{m}} + n_{1\mu\text{m}} * V_{1\mu\text{m}} + n_{2,5\mu\text{m}} * V_{2,5\mu\text{m}} + n_{5\mu\text{m}} * V_{5\mu\text{m}} + n_{10\mu\text{m}} * V_{10\mu\text{m}}) \quad (6)$$

Ahol,

ρ a sűrűség,

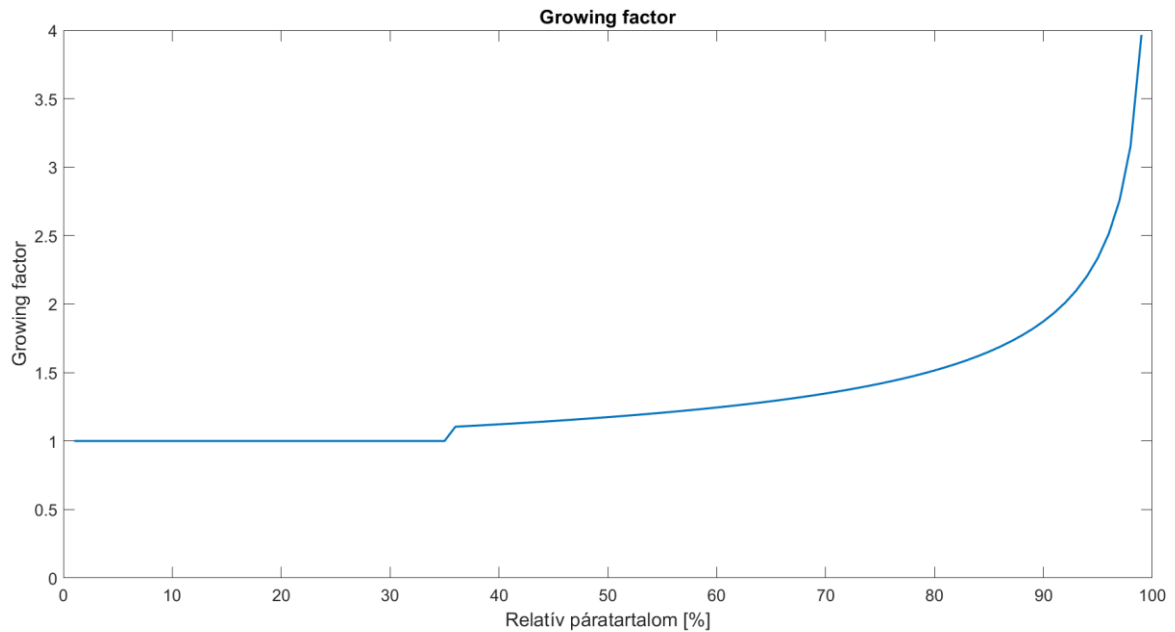
$n_{x\mu\text{m}}$ az x mérettartományban mért darabszám,

$V_{x\mu\text{m}}$ pedig az x mérettartományhoz tartozó térfogat.

Ezen átszámolás alapján minden egyes adatra kiszámoltam a méreteloszlásból származó PM10 adatot.

2.4.3.1 Páratartalom kompenzálás

A páratartalom kompenzálásra a [T8] irodalomban talált összefüggést, a growing factort használtam, amelynek lényege, hogy meghatározza a különböző mérhető részecskéknek a páratartalomtól függő méretnövekedését. A szállópor részecskék duzzadtságának változását a következő függvénnyel tudjuk leírni.



20. ábra - Growing factor

A fenti függvényt leíró összefüggés a következő:

$$g(RH) = \frac{D_{wet}(RH)}{D_{dry}} \quad (7)$$

Ahol,

$g(RH)$ a growing factor,

D_{wet} a szállópor részecskék páratartalom okozta duzzadt átmérője,

D_{dry} a szállópor részecskék kompenzált átmérője

A következő képlet szemlélteti a growing faktor egyenletét.

$$g(RH) = \left(1 + \kappa * \frac{RH}{100 - RH} \right)^{\frac{1}{3}} \quad (8)$$

Ahol,

κ egy levegő összetételétől függő konstans,

RH pedig a relatív páratartalom.

A [T8] cikkben a normál levegőszennyező anyagokra 0,62-t ajánl. A fenti összefüggések (8)(9) alapján a páratartalom kompenzálást a következő összefüggés alapján végeztem.

$$D_{dry} = \frac{D_{wet}(RH)}{\left(1 + \kappa * \frac{RH}{100 - RH}\right)^{\frac{1}{3}}} \quad (9)$$

Így megkapom, hogy mekkora lenne az adott tartományban (0,3, 0,5, 1, 2,5, 5, 10) a részecske átmérők kompenzált értéke. Például, amennyiben a mérést 65%-os relatív páratartalom mellett végeztem és kíváncsi vagyok az 5µm átmérőjű részecskék kompenzált méretére, behelyettesítve a (10) képletbe:

$$D_{dry} = \frac{5\mu m}{\left(1 + 0,62 * \frac{65}{100 - 65}\right)^{\frac{1}{3}}} = 3,87\mu m \quad (10)$$

A fenti példában a $D_{wet}(RH) = 5\mu m$ esetén a growing factorral történő kompenzáció után a teljesen száraz részecske átmérője 3,87µm lesz.

Az OLM mérőállomás a szállópor koncentrációt 50%-os relatív páratartalmon méri, így a fenti képletet úgy alakítom át, hogy ne kompenzálja ki teljesen a páratartalom okozta átmérő növekményt a képlet, hanem csak 50%-os relatív páratartalomig.

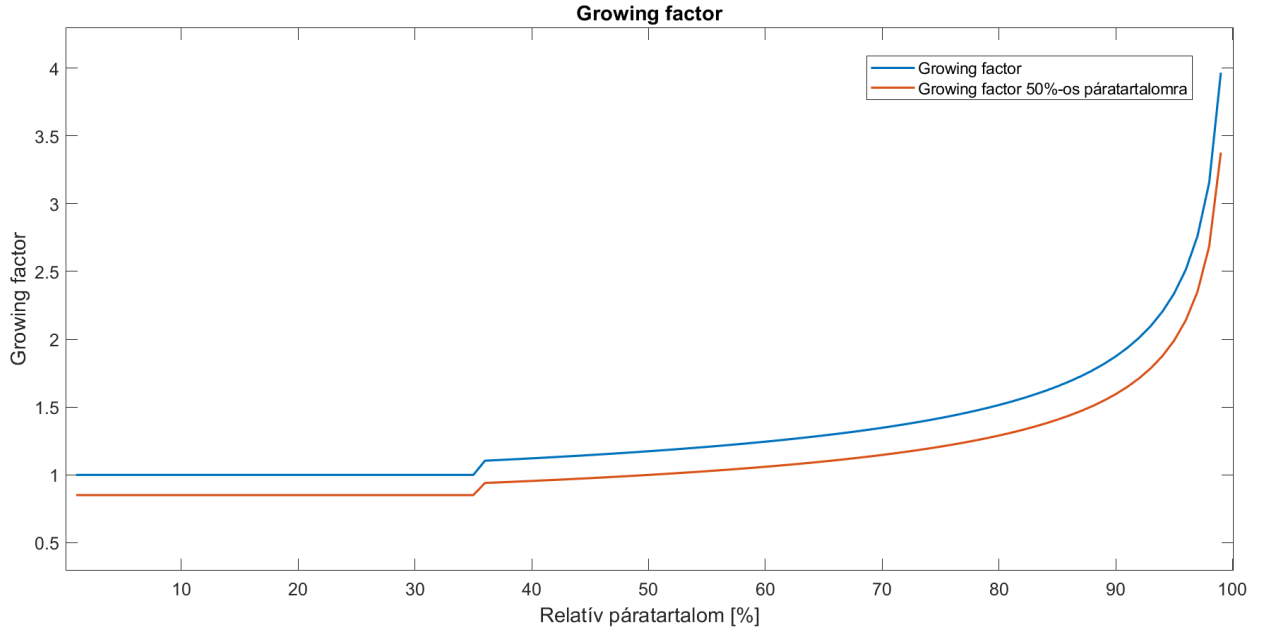
Ehhez az átalakításhoz elosztom a fenti (10) képletet az 50%-os páratartalomra kompenzáló képlettel a következők szerint:

$$D_{50} = \frac{\frac{D_{wet}(RH)}{g(RH)}}{g(50)} = \frac{\frac{D_{wet}(RH)}{\left(1 + \kappa * \frac{RH}{100 - RH}\right)^{\frac{1}{3}}}}{\left(1 + \kappa * \frac{50}{100 - 50}\right)^{\frac{1}{3}}} \quad (11)$$

A gyököt összevonva és az alsó képletbe behelyettesítve a következő formulát kapom:

$$D_{50} = \frac{D_{wet}(RH)}{\left(\frac{1 + \kappa * \frac{RH}{100 - RH}}{1 + \kappa}\right)^{\frac{1}{3}}} \quad (12)$$

Amennyiben a fenti képletbe a D_{wet} helyére 1-et helyettesíték és lefuttatom a számítást 0%-os relatív páratartalomtól 100%-ig, megkapom a részecskék méretváltozásának relatív értékét:



21. ábra – Growing factor

A kompenzációra a (13) képletet fogom használni.

2.5 Kalibrációs eljárások eredményeinek kiértékelése

A fent említett célok alapján az eredmények értékléséhez kétféle értéket fogok alapul venni a validáció során. Az egyik ilyen érték az átlagos négyzetes hiba gyöke (RMSE – Root Mean Square Error), amely a következő képlet alapján számolható.

$$RMSE(x) = \sqrt{\frac{1}{n} * \sum_{i=1}^n (y_i - x_i)^2} \quad (13)$$

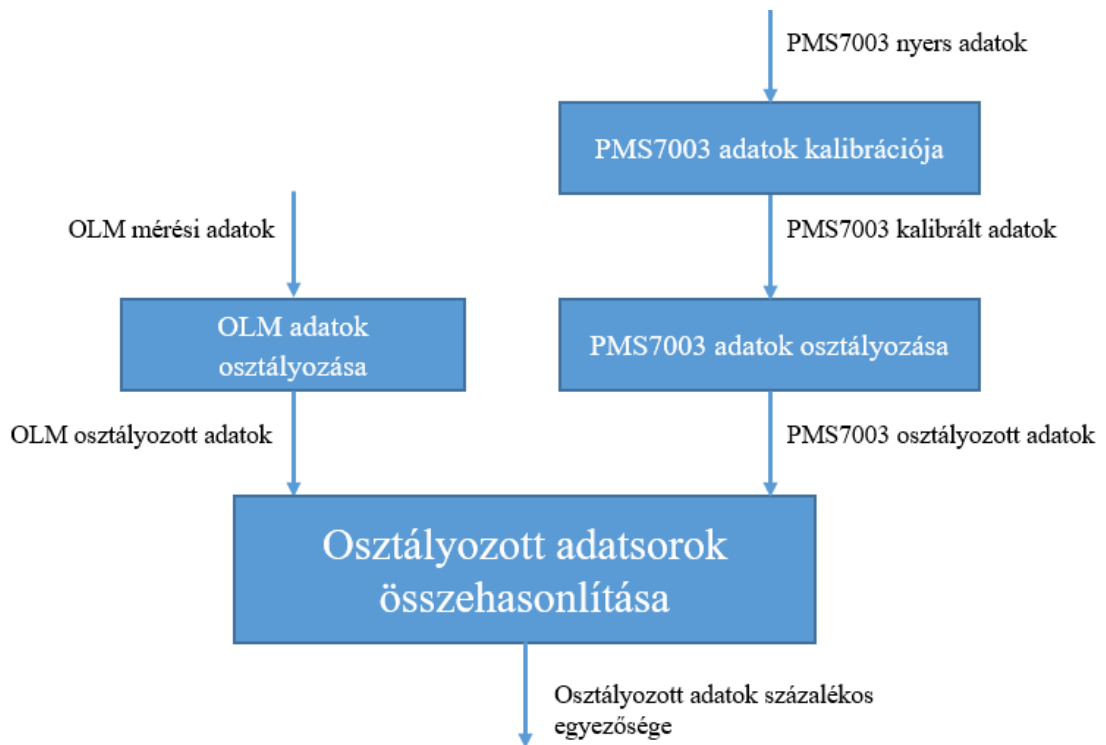
Ahol,

y_i a OLM által mért kalibrált műszertől származó adatot szimbolizálja,

x_i pedig az általam mért PMS7003 szenzor adat,

i az iterátor változó, n pedig az elemek száma.

További validációs szempont az, hogy az aktuális mérési adat egy AQI osztályba van-e a kalibrált OLM szenzoréval. Ezt a validációt három lépésben teszem a következő ábra szerint.

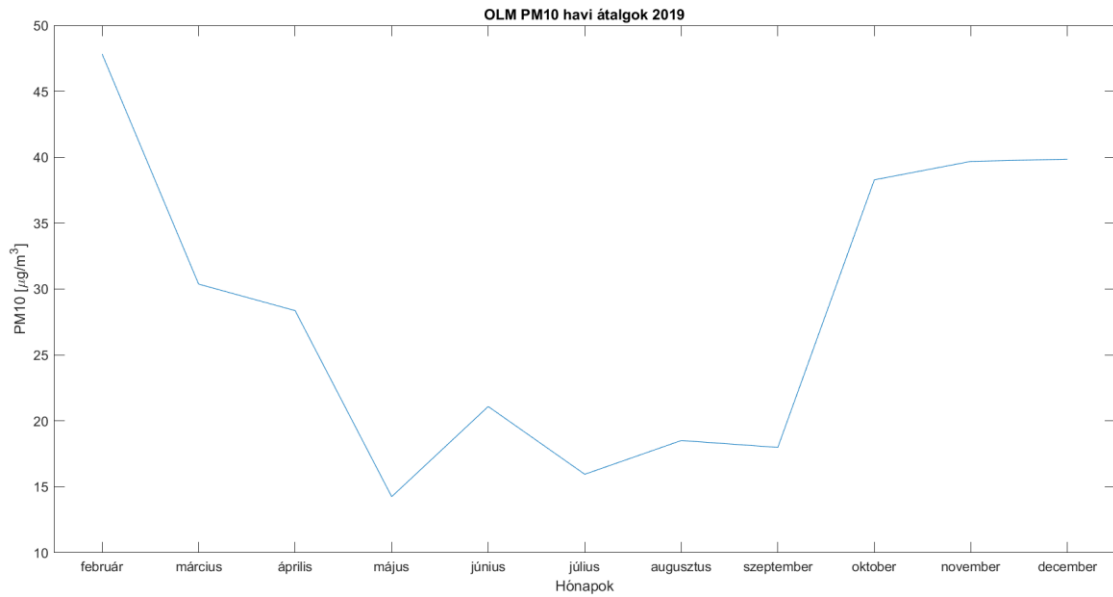


22. ábra - Validációs eljárás

Az adatok osztályozására egy Matlab scriptet írtam, amelynek a bemenő paramétere egy mérési adatsor és a már fent említett (2. táblázat) osztályok alapján egy egész számot rendel hozzá a függvény visszatérési értékéhez. A vissztérési érték egy vektor lesz, amely AQI osztály azonosítókból áll.

Az osztályozott adatok összehasonlítása során egyesével összehasonlítom az elemeket, megvizsgálom, hogy megegyeznek-e. Ezt végigcsinálom a teljes osztályozott adatsoron és végül kiszámítom, hogy hány %-ban egyeztek meg az osztályozott értékek. Ez az érték fogja főként megszabni az összehasonlítás alapját. Ez a paraméter azért lesz nekem nagyon fontos, mert a célom, hogy egy spektrális, osztályozott adatból készítsem el az anomália térképet.

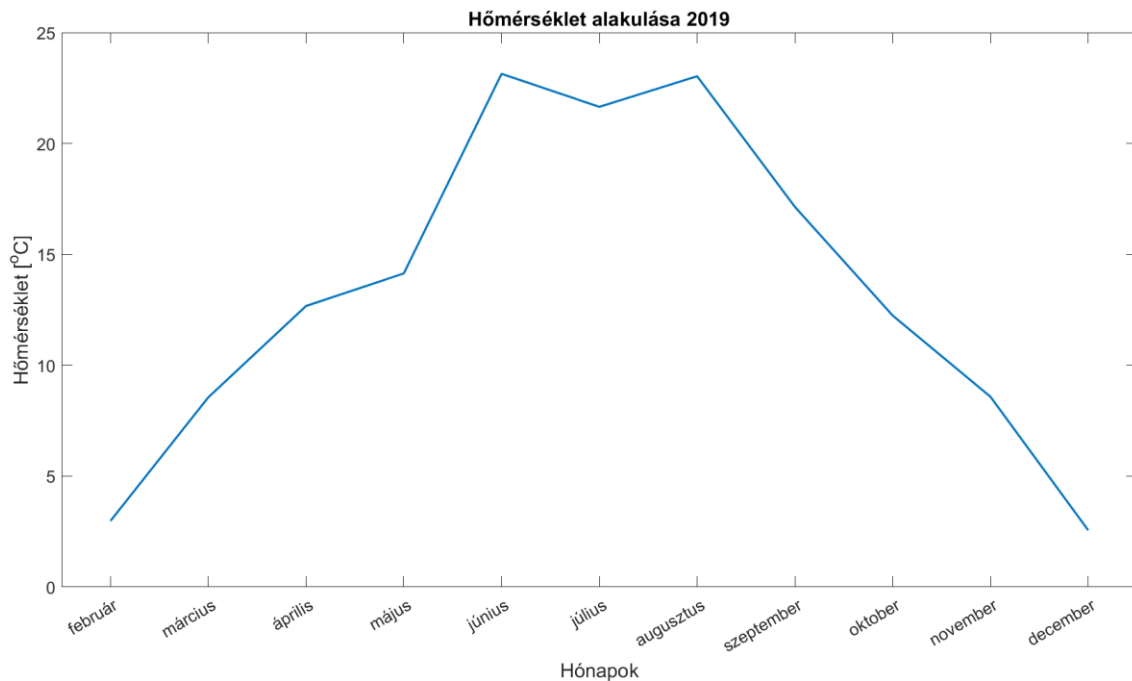
Szeretném továbbá szemléltetni az egyes mérési adatokhoz kötődő havi átlagokat is, amely által látható lesz, mely hónapok kritikusak pontosság szempontjából. A következő grafikonon szemléltetem az OLM PM10 havi átlagokat.



23. ábra - OLM havi átlagok

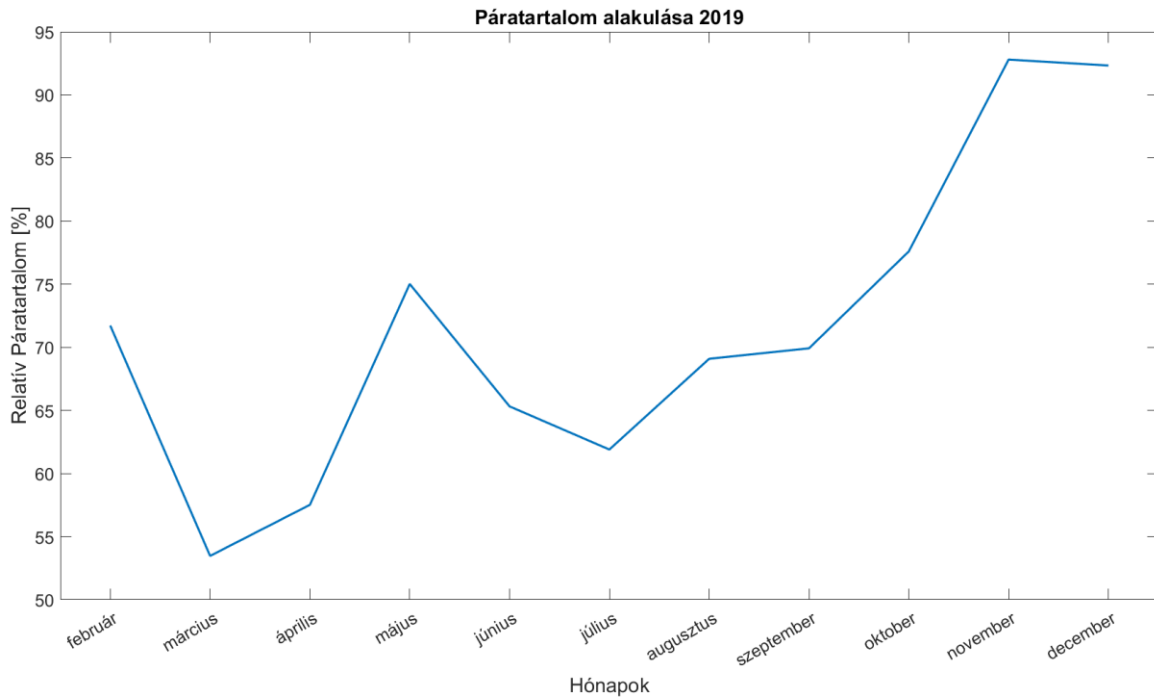
A validációs folyamat részeként a havi átlagokat is szeretném összehasonlítani az OLM által mérttel. Azért választottam ezt, mert nagyobb felbontású adatok reprezentációja átláthatatlan lenne egy A4-es oldalon, viszont a havi átlagok 11 adatpontja átláthatóan fogja szemléltetni a problémás hónapokat.

A következő képen látható az éves havi átlag hőmérséklet alakulása.



24. ábra - Hőmérséklet alakulása 2019

A következő képen látható az éves havi átlag páratartalom alakulása.



25. ábra - Páratartalom havi alakulása 2019

A szakirodalomban leírtak alapján a PMS7003 szenzornak jó a megismételhetősége, így a mérőrendszerbe elhelyezett két szenzor közül csak az egyik szenzort vizsgáltam. Nem hasonlítottam össze a két szenzor mérését egymáshoz képest.

2.5.1 A PMS7003 alap mérésének kiértékelése

A PMS7003 szenzor alap mérésnek vizsgálatával az a célom, hogy legyen egy olyan bázisértékem, amelyhez tudom hasonlítani az egyes kalibrációs eljárások eredményeit.

7. táblázat - PMS7003 PM10 mérés havi kiértékelése

Hónapok	AQI szerinti egyezőség [%]	RMSE [$\mu\text{g}/\text{m}^3$]	havi átlagok [$\mu\text{g}/\text{m}^3$]	OLM havi átlagok [$\mu\text{g}/\text{m}^3$]
2019.február	70,69	29,35	68,19	47,82
2019.március	88,39	13,96	34,5	30,37
2019.április	90,8	17,18	26,98	28,36
2019.május	99,23	9,37	15,85	14,25
2019.június	99,23	9,11	19,99	21,09
2019.július	99,38	9,58	14,19	15,95
2019.augusztus	99,44	6,42	18,28	18,51
2019.szeptember	96,45	11,79	17,96	17,99
2019.október	82,46	20,55	43,62	38,28
2019.november	78,22	18,33	52,17	39,68
2019.december	71,16	21,81	56,57	39,85
Átlag:	88,68	15,22	33,48	28,38

A fenti táblázatban látszik, hogy a fűtési időszak a kritikus: ősztől tavasz elejéig ebben az időszakban a fűtés miatt magasabb a szállópor koncentráció és az időjárás miatt a páratartalom is. Ezekben a hónapokban magasabb ($25 \mu\text{g}/\text{m}^3$ felett) mérési tartományban mér a szenzor, az RMSE érték magasabb és a %-os egyezőség is kisebb.


A következő táblázatban szeretném bemutatni az éves átlag alakulását az OLM által mért értékhez képest.

8. táblázat - PMS7003 éves átlag

Adat forrás	Éves átlag [$\mu\text{g}/\text{m}^3$]
OLM PM10	28,38
PMS7003 alap mérés	33,48

Látható, hogy a szenzor éves átlagban 5,1 $\mu\text{g}/\text{m}^3$ -el fölé mér.

A következő ábrán az OLM PM10 és a PMS7003 PM10 havi átlagok alakulása látható.



26. ábra - OLM PM10 - PMS7003 PM10 havi átlagok alakulása 2019

Megállapítható, hogy az éves átlagban való fölé mérés a téli hónapokban jellemző.


2.5.2 Neurális háló kiértékelése

A neurális háló betanítása során az előzetesen meghatározott feed – forward típusú neurális hálót választottam a MATLAB szoftver Neural Network Toolbox kiegészítőjén belül. A tanításhoz a 2019. február-tól 2019. decemberig terjedő adatsort használtam fel egyben tanító adathalmazként.

A neurális háló hatékonyságát az alapján mérjük, hogy az OLM által mért PM10 érték AQI osztályba sorolása és a neurális háló által kalibrált adatok AQI osztályba való

sorolása hány százalékban egyezik meg, valamint meghatároztuk havonta az RMSE értékeket is.

A 26. ábra szemlélteti a tanítás során alkalmazott neurális háló felépítést, ami 1 rejtett rétegből és rétegenként 1 neuronból áll. Ezt a betanítást a PM10 szállópor koncentrációs adatokkal végeztük el.




27. ábra - A használt neurális háló felépítése

9. táblázat - PMS7003 neurális hálóval kompenzált adatok havi kiértékelése

Hónapok	AQI szerinti egyezőség [%]	RMSE [$\mu\text{g}/\text{m}^3$]	havi átlagok [$\mu\text{g}/\text{m}^3$]	OLM havi átlagok [$\mu\text{g}/\text{m}^3$]
2019. február	82,37	14,83	50,84	47,82
2019. március	91,83	11,63	28,98	30,37
2019. április	93,38	15,17	24,15	28,36
2019. május	99,6	6,92	16,95	14,25
2019. június	99,33	7,99	19,83	21,09
2019. július	99,56	7,25	16,04	15,95
2019. augusztus	99,6	5,66	18,55	18,51
2019. szeptember	97,88	7,67	18,21	17,99
2019. október	87,4	13,04	35,08	38,28
2019. november	88,11	10,64	40,48	39,68
2019. december	86,67	9,83	43,39	39,85
Átlag:	93,24	10,05	28,40	28,38

A 9. táblázatban és a 26. ábrán vizuálisan megjelenítve is láthatóak a havi szintű tanítások hatékonysági eredményei. A százalékos egyezőségekben a nyári hónapokban nagyobb egyezőség látszik. A legjobb hatékonysági érték augusztusban 99.6%, a legrosszabb pedig februárban 82.37% fordult elő. Ennek oka szintén a hőmérséklet és a páratartalom

értékekben kereshető, illetve télen a fűtési szezonnak és az alacsony hőmérsékletnek köszönhetően a szállópor koncentráció magasabb értéket mutathat, mint nyáron. A havi hatékonysági értékek átlaga 93.24%, ami 4,56%-al jobb eredményt mutat, mint a PM10 alap mérése. A RMSE értéken 5,17 $\mu\text{g}/\text{m}^3$ -el sikerült csökkenteni. A következő ábrán szemléltetem a neurális háló által kompenzált adatok alakulását az OLM adatok függvényében.

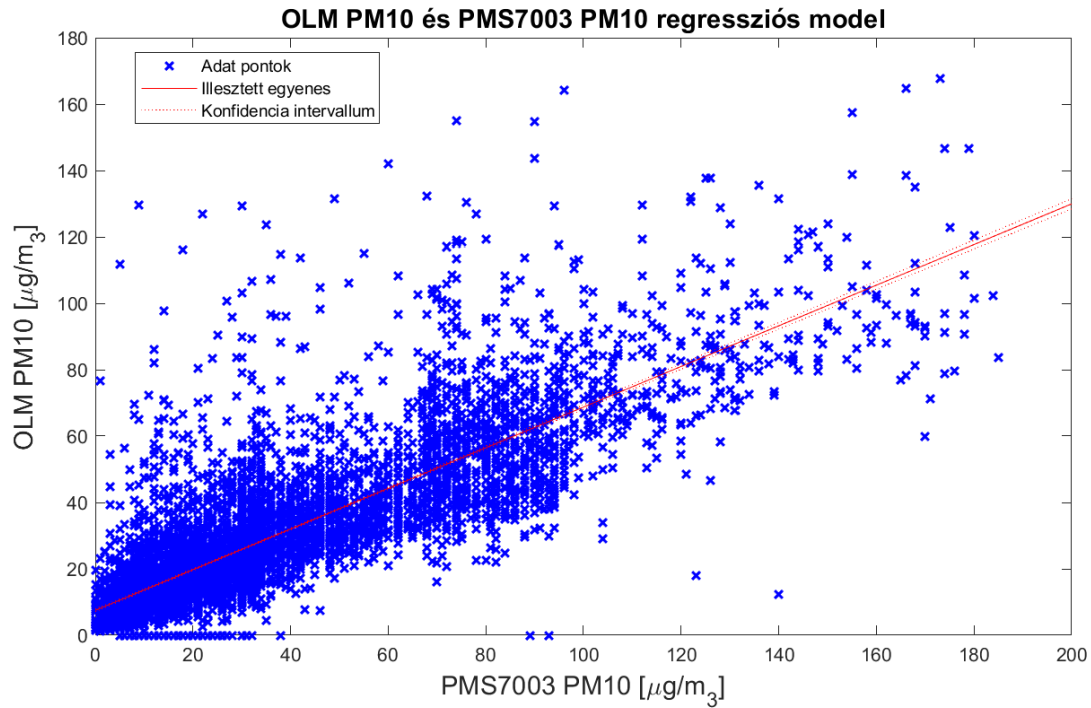


28. ábra - PMS7003 neurális hálóval kompenzált adatok havi kiértékelése

A diagramon a legnagyobb eltérés decemberben mutatkozik ($3,53 \mu\text{g}/\text{m}^3$).

2.5.3 Lineáris regresszió kiértékelése

Ebben a fejezetben a már ismertett lineáris regressziós módszerrel történő kalibráció eredményeit szeretném bemutatni. A Matlab szoftverben beépített lineáris regressziós toolkitet használtam a modell felépítéséhez. A modell felépítéséhez a PMS7003 PM10 értékeit és az OLM PM10 értékeit használtam fel, így egy olyan függvényt kapok, amelybe behelyettesítve a PMS7003 PM10 értékeket egy kalibrált értéket kapok. A következő képen látható a modelltől készült ábra.



29. ábra - Lineáris regressziós modell az OLM PM10 és a PMS7003 PM10 mérések függvényében

A pontokra illesztett egyenes egyenlete a következő:

$$f(x) = 0,6121x + 7,51 \quad (14)$$

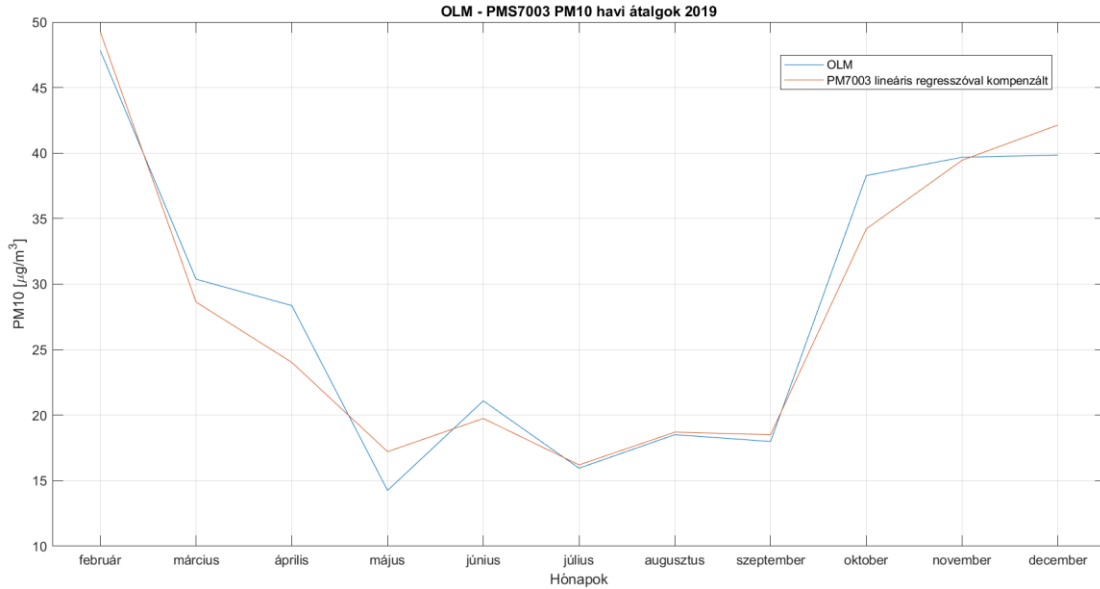
Látható, hogy a pontok nem teljesen illeszkednek az egyenesre. A modell R^2 hibája 0,69. A fenti függvényből (14) arra következtetnek, hogy a szenzor hibája a mért értékkel arányosan növekszik.

Megvizsgáltam, hogy amennyiben a fenti függvényt használom a nyers adatok kalibrációjára, úgy a következő eredményeket kapom.

10. táblázat - PMS7003 lineáris regresszióval kompenzált adatok havi kiértékelése

Hónapok	AQI szerinti egyezőség [%]	RMSE [$\mu\text{g}/\text{m}^3$]	Havi átlagok [$\mu\text{g}/\text{m}^3$]	OLM havi átlagok [$\mu\text{g}/\text{m}^3$]
2019. február	83,52	14,48	49,26	47,82
2019. március	91,54	11,62	28,63	30,37
2019. április	92,45	15,27	24,02	28,36
2019. május	99,54	6,97	17,22	14,25
2019. június	99,32	7,99	19,75	21,09
2019. július	99,50	7,18	16,20	15,95
2019. augusztus	99,58	5,88	18,70	18,51
2019. szeptember	97,95	7,65	18,51	17,99
2019. október	83,18	13,85	34,22	38,28
2019. november	87,43	11,77	39,45	39,68
2019. december	86,20	10,50	42,14	39,85
Átlag:	92,75	10,28	28,01	28,38

A 10. táblázatban és a 28. ábrán vizuálisan megjelenítve is láthatóak a havi szintű tanítások hatékonysági eredményei. A százalékos egyezőségekben a nyári hónapokban nagyobb egyezőség látszik. A legjobb hatékonysági érték augusztusban 99.58%, a legrosszabb pedig februárban 83.52% fordult elő. Ennek oka szintén a hőmérséklet és a páratartalom értékekben kereshető, illetve télen a fűtési szezonnak és az alacsony hőmérsékletnek köszönhetően a szállópor koncentráció magasabb értéket mutathat, mint nyáron. A havi hatékonysági értékek átlaga 92,75%, ami 4,07%-al jobb eredményt mutat, mint a PM10 alap mérése és 0,49%-al kisebb mint a neurális hálós kalibráció esetében. A RMSE értéken 4,75 $\mu\text{g}/\text{m}^3$ -el sikerült csökkenteni, ez az érték 0,23 $\mu\text{g}/\text{m}^3$ -el nagyobb, mint a neurális háló esetében. A következő ábrán szemléltetem a neurális háló által kompenzált adatok alakulását az OLM adatok függvényében.



30. ábra – OLM PM10, PMS7003 PM10 lineáris regresszióval kompenzált havi átlagok

Véleményem szerint a fenti ábrán a téli időszak mérései, ahol a szenzor alapmérésének értékelése során az adódott, hogy a szenzor jellemzően fölé mért, a kalibráció használatának köszönhetően közelebb került az OLM méréséhez.


A következő táblázatban szeretném szemléltetni az éves átlagok eddigi alakulását.

11. táblázat - PMS7003 kompenzált éves átlagok alakulása

Adat forrás	Éves átlag [µg/m³]	AQI szerinti egezőség [%]
OLM PM10	28,38	100%
PMS7003 alap mérés	33,48	88,68
PMS7003 neurális hálóval kompenzált	28,4	93,24
PMS7003 lineáris regresszióval kompenzált	28,01	92,75

Látható, hogy az eddig megvizsgált kalibrációs eljárások közül a neurális hálóval kompenzált adatok éves átlaga áll a legközelebb az OLM állomás által mért értékhez.

A következőben megvizsgátam a szenzor mérési hibáját a páratartalom függvényében. Erre is felépítettem egy lineáris regressziós modellt, amelyet a következő ábrán szemléltetek.



31. ábra - PMS7003 mérési hiba a páratartalom függvényére épített regressziós modell

A fenti ábrán lévő modell által illesztett egyenes egyenlete a következő:

$$f(RH) = 0,2995 * RH - 15,542 \quad (15)$$

Ahol az $f(RH)$ a mérési hibát adja meg.


Ezzel egy már említett tényt lehet igazolni, miszerint az OLM által használt szenzor 50%-os páratalmú levegőt mér. Amennyiben az $f(RH)$ helyére 0-át helyettesítünk, úgy megkapjuk, hol metszi az x tengely 0 pontját az egyenes. Ez az érték 51,89%, amely alátámasztja, hogy a kalibrált műszer valóban 50%-os páratartalomon mér. Az eltérést vélhetően a szenzor mérési hibája okozza.

A következő táblázatban szemléltetem a kiértékelés utáni eredményeket havi bontásban.

12. táblázat - PMS7003 lineáris RH regresszióval kompenzált adatok havi kiértékelése

Hónapok	AQI egyezőség [%]	RMSE [$\mu\text{g}/\text{m}^3$]	Havi átlagok [$\mu\text{g}/\text{m}^3$]	OLM havi átlagok [$\mu\text{g}/\text{m}^3$]
2019. február	75,37	22,56	62,25	47,82
2019. március	90,59	11,88	34,03	30,37
2019. április	91,93	13,98	25,33	28,36
2019. május	99,43	8,48	8,93	14,25
2019. június	99,31	9,25	15,97	21,09
2019. július	99,42	9,1	11,20	15,95
2019. augusztus	99,58	8,58	12,99	18,51
2019. szeptember	97,17	10,21	12,57	17,99
2019. október	84,56	13,01	35,93	38,28
2019. november	85,89	12,65	39,92	39,68
2019. december	82,46	13,98	44,76	39,85
Átlag:	91,43	12,15	27,63	28,38

A legalacsonyabb AQI szerinti egyezés februárban tapasztalható 75,37%, amely elmarad az eddigi eljárások által produkált eredménytől, ahol februárban is 80% fölött alakult ez az érték. A legnagyobb a nyári időszakban, augusztusban tapasztalható 99,58%. Az RMSE értékek is hasonlóan alakultak: február a legmagasabb, ahol 22,56 $\mu\text{g}/\text{m}^3$, a legalacsonyabb pedig 8,48 $\mu\text{g}/\text{m}^3$ májusban. A következő diagramon látható, hogyan alakulnak a havi átlagok. Összességében elmondható, hogy az alapméréshez képest az RMSE értéken 3,07 $\mu\text{g}/\text{m}^3$ -el sikerült javítani



32. ábra - OLM PM10 - PMS7003 Lineáris RH regresszióval kompenzált havi átlagok alakulása

A narancssárga a lineáris regresszióval kompenzált adatsor, a kék pedig az OLM PM10 havi átlaga. Látható, hogy a nyári időszakban alulkompenzál.

Összességében a két regressziós eljárás közül az első modell bizonyult jobbnak, ahol a két szenzor mérései alapján hoztam létre a regressziós modellt. A neurális háló által kompenzált adatsor eredményei a legjobbak.


2.5.4 Growing factor kiértékelése

Korábban már bemutattam a Growing factorral való kompenzáció matematikai hátterét. Az alap paramétereket felhasználva (growing factor: 0,62; sűrűség: 1,65 g/m³) kiszámítottam a kiértékeléshez a paramétereket, amelyet a következő táblázatban (13. táblázat) szemléltetek.

13. táblázat - PMS7003 Growing faktorról kompenzált adatok havi kiértékelése

Hónapok	AQI szerinti egyezés [%]	RMSE [$\mu\text{g}/\text{m}^3$]	havi átlagok [$\mu\text{g}/\text{m}^3$]	OLM havi átlagok [$\mu\text{g}/\text{m}^3$]
2019. február	67,82	36,38	19,71	47,82
2019. március	89,23	20,38	16,82	30,37
2019. április	92,86	23,92	10,95	28,36
2019. május	99,55	13,99	2,92	14,25
2019. június	99,3	18,93	4,66	21,09
2019. július	99,56	15,48	3,06	15,95
2019. augusztus	99,6	16,97	3,8	18,51
2019. szeptember	99,16	18,15	3,1	17,99
2019. október	72,9	37,97	8,19	38,28
2019. november	78,04	41,36	4,23	39,68
2019. december	76	40,66	4,94	39,85
Átlag:	88,54	25,84	7,48	28,38

Az AQI szerinti egyezőség alacsonyabb és az RMSE értékek pedig magasabbak, mint a PMS7003 PM10 alap mérése esetében, amely látszik a következő diagramon is.




33. ábra - OLM PM10 - PMS7003 growing faktor kompenzált havi átlagok alakulása

Látható, hogy túlkompensál télen és nyáron is. Véleményem szerint a growing factorral való átszámításhoz használt sűrűség érték ($1,65\text{g/m}^3$), valamint growing értékek (0,68) nem megfelelőek. Az éves átlag több mint $20\ \mu\text{g/m}^3$ -el kisebb mint az OLM által mért érték. Úgy döntöttem, hogy a sűrűsége és a growing factorra lefuttatok egy optimalizálást a következő táblázatban összefoglalt paraméterezés alapján.

14. táblázat – Growing factor optimalizálás paraméterek

Paraméter	Kezdő érték	Végő érték	Lépésköz
Sűrűség [g/m³]	1	2,2	0,05
Growing factor	0	0,8	0,01

Az optimalizáláshoz egy matlab scriptet írtam, amely végigsöpört a két paraméteren és kiszámította az egyes pontokba az AQI szerinti egyezőségeket, valamint az RMSE értékeket. Az optimalizálás eredményét a következő 3D diagramon szeretném szemléltetni.



34. ábra - Growing factor optimalizálás

Az optimalizálásban használt paramétereket az RMSE érték függvényében ábrázoltam. A diagramon látszik, hogy minél kisebb a growing factor, annál kisebb az RMSE hiba érték is. Amennyiben a growing factor érték csökken, annál kevésbé érvényesül a growing factor páratartalom függő kompezálása. Ez arra enged következtetni, hogy a szenzor hibája nem függ a páratartalomtól. A következő táblázatban szeretném szemléltetni az optimalizálás eredményét.

15. táblázat – Growing factor optimalizálás eredmény

Sűrűség [g/m ³]	GF	RMSE [µg/m ³]	AQI szerinti egyezőség [%]
1,8	0,01	17,5	91,65
1,85	0	17,62	91,53

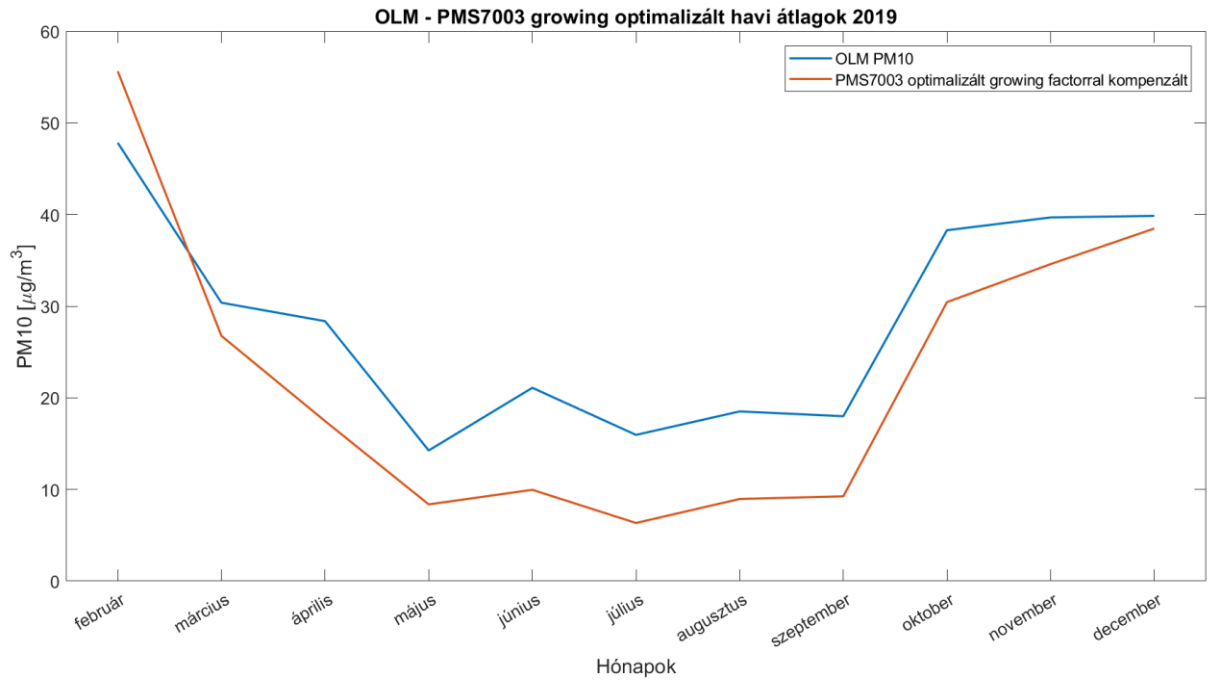
A táblázat első sorában található a minimális értékpár, amelyet az optimalizálás adott. A második sorban pedig az a minimum található, ahol a growing factor értéke 0, így ezt a továbbiakban sűrűség optimalizálásként fogom említeni. Látható, hogy nem sok különbség van az RMSE értékben.

Először szeretném bemutatni a 16. táblázatban az optimalizálás minimum paraméterezésével átszámolt havi kiértékelést.

16. táblázat - PMS7003 optimalizált Growing faktorról kompenzált adatok havi kiértékelése

Hónapok	AQI szerinti egyezőség [%]	RMSE [$\mu\text{g}/\text{m}^3$]	havi átlagok [$\mu\text{g}/\text{m}^3$]	OLM havi átlagok [$\mu\text{g}/\text{m}^3$]
2019. február	80,05	24,68	55,63	47,82
2019. március	88,36	18,77	26,76	30,37
2019. április	90,84	22,39	17,46	28,36
2019. május	99,05	12,38	8,37	14,25
2019. június	99,03	16,11	9,96	21,09
2019. július	99,38	14,02	6,34	15,95
2019. augusztus	99,23	13,97	8,96	18,51
2019. szeptember	98,18	14,46	9,25	17,99
2019. október	83,24	22,56	30,44	38,28
2019. november	86,28	16,92	34,59	39,68
2019. december	84,57	16,34	38,47	39,85
Átlag:	91,65	17,50	22,38	28,38

Látható, hogy az AQI %-os egyezősége 2,88%-al nőtt, viszont az RMSE érték is nőtt 2,28 $\mu\text{g}/\text{m}^3$ -el a PMS7003 alap méréséhez képest. Az RMSE érték majdnem 8 $\mu\text{g}/\text{m}^3$ -el magasabb, mint a lineáris regresszióval és neurális hálóval kompenzált érték esetén. Az alap growing factorhoz képes viszont szignifikáns javulás tapasztalható mind az RMSE (-8,34 $\mu\text{g}/\text{m}^3$) mind a %-os egyezőség (3,11%) tekintetében. A következő képen szeretném szemléltetni a havi átlagok alakulását az OLM PM10 mérés függvényében.



35. ábra - OLM PM10 - PMS7003 optimalizált growing factorral havi átlagok

Látható, hogy az RMSE értékek a nyári időszakban is átlagosan $-11,1 \mu\text{g}/\text{m}^3$ eltérést mutatnak.


2.5.5 A sűrűség optimalizált adatok kiértékelése

Ebben a fejezetben bemutatom a sűrűség optimalizált adatsor kiértékelését. A számítás során $1,85 \text{ g/m}^3$ sűrűséggel számoltam.

17. táblázat - PMS7003 méret eloszlásból átszámolt kompenzált adatok havi kiértékelése

Hónapok	AQI szerinti egyezőség [%]	RMSE [$\mu\text{g/m}^3$]	havi átlagok [$\mu\text{g/m}^3$]	OLM havi átlagok [$\mu\text{g/m}^3$]
2019. február	81,31	22,12	50,24	47,82
2019. március	89,65	17,91	22,79	30,37
2019. április	91,71	22,93	15,01	28,36
2019. május	99,19	12,37	7,55	14,25
2019. június	99,17	16,57	8,64	21,09
2019. július	99,43	14,21	5,65	15,95
2019. augusztus	99,36	14,32	7,95	18,51
2019. szeptember	97,96	14,76	8,69	17,99
2019. október	82,81	23,14	29,71	38,28
2019. november	84,1	17,6	37,99	39,68
2019. decemeber	82,19	17,95	42,51	39,85
Átlag:	91,53	17,62	21,52	28,38

Az eredmények nagyon hasonlóak az előzőekben bemutatott growing faktorról számolt optimalizált eredményekhez. Az alap méréshez képest nőtt a AQI egyezőség, az RMSE érték is nőtt. A következő ábrán az OLM és a PMS7003 sűrűség optimalizált havi alakulása látható.



36. ábra – PMS7003 PM10 méreteloszlásból átszámolt adatok éves alakulása

Látható, hogy alámér a szenzor, amelyet az éves átlag is alátámaszt, mivel $6,86 \mu\text{g}/\text{m}^3$ -el kisebb az OLM éves átlaghoz képest.

A growing factorral való optimalizálásban, a kutatás elején nagyon bíztam. A kiértékelés eredménye viszont sajnos csalódást okozott. Az optimalizálás eredménye arra enged következtetni, hogy a szenzor mérése nem függ nagymértékben a páratartalomtól. A havi adatok alakulásán viszont azt látom, hogy a téli hónapok hasonlóan a jobb eredményt produkáló eljárásokhoz közelebb vannak az OLM átlaghoz. A nyári hónapokban, ahol alacsonyabb a mérési tartomány ($50 \mu\text{g}/\text{m}^3$ alatt) túlkompenzál.

2.5.6 Összegzés

A fent bemutatott kalibrációs eljárások közül a neurális háló által kompenzált adatok nyújtották a legjobb RMSE $10,05 \mu\text{g}/\text{m}^3$ értéket, a százalékos egyezőség pedig 93,24%. A %-os eltérés véleményem szerint perces adatok esetében soha nem lesz 100%, mert a két légszennyezés mérő műszer nem közvetlenül ugyanazt a közeget méri. Amennyiben havi átlagot nézünk 100% az egyezőség. A lineáris regresszió is hasonló eredményt nyújtott minimális eltéréssel, előnye a neurális hálónak képest.

2.6 Tézisek

2.6.1 Tézis I.

Több módszert összehasonlítottam a PMS7003 szenzor PM10 mérésének lokáció specifikus kalibrációjának érdekében. A neurális hálózat alapú kalibráció éves perces adatokon vizsgálva 10,05 $\mu\text{g}/\text{m}^3$ RMSE hibát és 93,24% AQI szerinti spektrális egyezőséget mutatott. [S8][S11][S12][S5][S2][S3]

Ezzel az új kalibrációs eljárással 4,56%-al jobb AQI szerinti egyezőséget valamint, 5,17 $\mu\text{g}/\text{m}^3$ -el alacsonyabb RMSE értéket sikerült elérni. A kalibrációs eljárás használatát Miskolc és környéke szállópor koncentráció indikatív mérésére ajánlom alkalmazni.

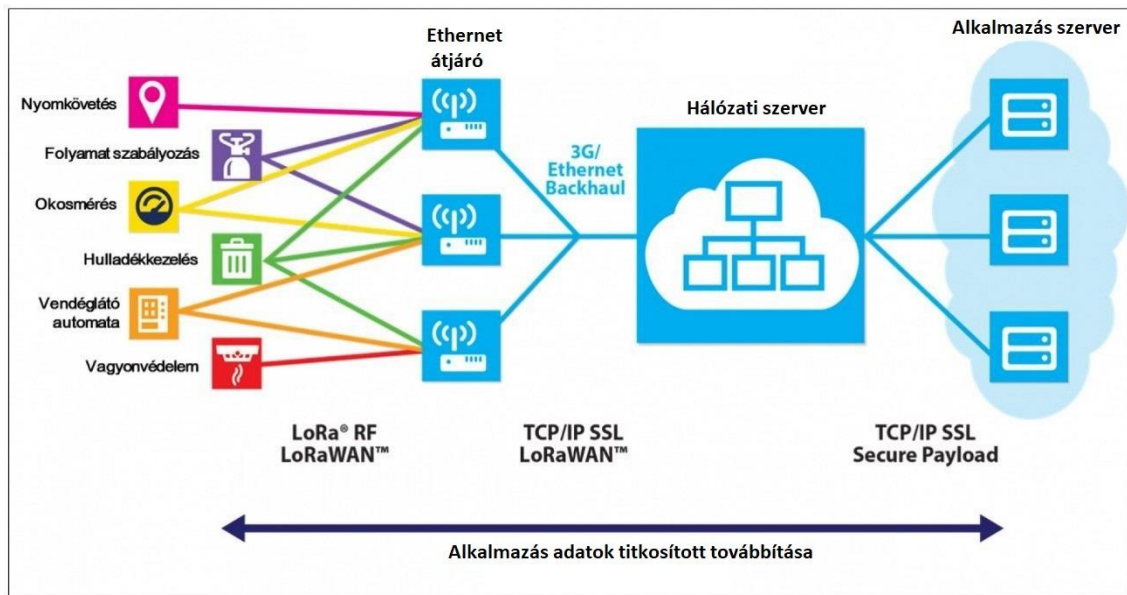
2.6.2 Tézis II.

Sikeresen alkalmaztam a growing factor eljárást a PMS7003 méreteloszlás adatain. Módosítottam az eljárást, az OLM állomással való pontosabb összehasonlítás céljából. Optimalizálás útján javítottam a growing factor által kompenzált szállópor koncentráción. [S5]

3 LoRaWAN mérőhálózat kültéri szenzor fejlesztése

A PMS7003 szenzor lokáció specifikus kalibrációja után belekezdtem a LoRaWAN alapú mérőhálózat fejlesztésébe. A fejlesztés során fontos kérdés, hogy hogyan tudjuk egyensúlyba hozni a környezetbarát megoldásokat a költséghatékonysággal és a hosszú élettartammal. Még a mindennapi életben is gyakran tapasztaljuk, hogy a környezetbarát megoldások gyakran drágábbak és rövidebb ideig használhatóak, de vannak olyan esetek is, amikor a költséghatékony megoldások nagyon rövid élettartammal és gyenge minőségű anyagokkal párosulnak, így nehéz megtalálni az egyensúlyt.

A célom, hogy a fent bemutatott anomália térképhez az adatokat egy IoT alapú mérőhálózat szolgáltatassa, ezért elkezdtem aktívan tanulmányozni, hogy milyen kommunikációval lehetne ezt megvalósítani. A legtöbb IoT kommunikációs technológiához (GSM, LTE, NBIoT) szükséges valamilyen SIM kártya, amelyhez tartozik egy fizetős szolgáltatás valamilyen nagyobb magyar telekommunikációs cégnél. A LoRaWAN előnye, hogy 10 eszközre ingyenes a szerver szolgáltatása, valamint már 2019-ben is meglehetősen jó lefedettsége volt, így végül a LoRaWAN hálózat mellett döntöttem. Előnye, hogy ISM sávon működőik (868MHz), így rendkívül nagy lefedettséget lehet elérni akár egy átjáróval is. Elhelyezkedéstől függően akár 14 km is lehet a hatótávolság. További előnye, hogy a LoRaWAN hálózat két-kulcsos titkosítással működik, így rendkívül nehéz feltörni vagy zavarni. Az Antenna Hungária Zrt. 10 eszközre ingyenes felhőszolgáltatást nyújt, valamint a LoRaWAN hálózata már 2019-ben is elérhető volt a legtöbb nagyvárosban, köztük Miskolcon is. A következő képen látható a LoRaWAN hálózat felépítése.



37. ábra - LoRaWAN hálózati topológia [T21]

A fenti ábrán balról jobbra haladva a következő komponensek találhatóak:

- LoRaWAN eszközök, adatgyűjtők, szenzorok: Ezek az eszközök adatot gyűjtenek és továbbítják a legközelebbi átjárónak egy úgynevezett uplink formájában. Az uplink az eszközök által az átjáró felé történő kommunikációt jelenti. Az átjárók képesek a LoRaWAN eszközök felé downlink üzenetet küldeni, viszont ez nem túl gyakori.
- LoRaWAN átjáró: Ez az eszköz rendelkezik LoRa rádióval, valamint internet összeköttetéssel, amelyen keresztül továbbítani tudja az adatokat a LoRa hálózati szerver felé.
- LoRaWAN hálózati szerver: Ez a hálózati szerver a hálózatot üzemeltető tulajdona és az a feladata, hogy az átjáróktól érkező adatokat továbbítsa különböző web-alapú kommunikációkon keresztül a LoRaWAN eszközök tudajdonosának. Mind a hálózati szerver felé, mind a hálózati szerver és az alkalmazás szerver közötti kommunikáció titkosított.
- LoRaWAN alkalmazás szerver: Ez a végpont, ahova a LoRaWAN hálózathoz tartozó adatok befutnak. Ez lehet egy adatbázis, vagy akár valamilyen megjelenítő webszerver.

Az egyetlen hátránya a LoRaWAN hálózatnak, hogy mivel ISM sávon működik, így tartani kell a 0,1%-os adási kitöltési tényezőt, amely azt jelenti, hogy az eszköz a működési idejének 0,1%-át töltheti rádiófrekvenciás jelek küldésével. Ezért nagy

mennyiségű adatok továbbítására nem alkalmas, viszont ebben az esetben nincs nagy mennyiségű adat és a mérendő mennyiségek sem változnak olyan gyorsan, így akár 5-10 percenként is elégséges lehet egy mérési adatot elküldeni.

Tehát a cél, egy LoRaWAN alapú szállópor koncentráció mérő hálózat kifejlesztése, amely olcsó, így nagy sűrűséggel kihelyezhető egy nagyobb városban. Így alkalmas lenne a mérőrendszer az AQI index által meghatározott színek alapján elkészített anomália térkép készítésre, amely a laikusok számára is érthető módon tudná megjeleníteni az adatokat. A kidolgozott kalibrációs eljárást szerver oldalon szeretném futtatni, így a kihelyezett eszközök a gyártásuk során nem igényelnék majd egyedi paraméterezést.


A kifejlesztett szenzor három fő hardveregységből áll: érzékelő modul, adatgyűjtő és átviteli modul, tápellátás. Ebből az eszközökből négy darabot telepítettem Miskolc – Martinkertvárosban. Az egész rendszer felépítésének szempontjából létezik egy negyedik modul is, maga az adatfeldolgozó és megjelenítő szerver. A továbbiakban részletesen bemutatom az egyes hardveregységeket.

Érzékelő modul: Ez az egység különféle paraméterek mérésére szolgáló érzékelőket tartalmaz, amelyeket egy saját tervezésű, 3D nyomtatott technológiával készült ABS-alapú burkolat vesz körül. A burkolat tervezésekor figyelembe kellett venni az időjárási körülményeket és biztosítani a burkolaton belüli levegőáteresztő képességet, ellenkező esetben hamis adatokat rögzítettek volna. A házban két érzékelő található, egy hőmérséklet- és páratartalom-mérő (DHT-22), valamint egy PM10 szálló por mérésére szolgáló érzékelő (PMS7003). A dobozt helyben gyártottuk saját 3D nyomtatónkon és az anyagot is egy miskolci filamentgyártótól szereztük be. Az érzékelő modul egy 7-eres kábelen keresztül csatlakozik az adatfeldolgozó és kommunikációs egységhez, amelyen keresztül az érzékelők számára szükséges tápfeszültség és kommunikációs lábak vannak bekötve. A 3D nyomtatott ház a következő képen látható.




38. ábra - Lamellás szenzor ház

Adatgyűjtő és átviteli modul: Az adatfeldolgozó és kommunikációs modul feladata az érzékelő modulban elhelyezett érzékelők adatainak megfelelő interfészen keresztül történő leolvasása és a LoRaWAN hálózaton keresztül történő továbbítása a hálózati szerverre. A saját tervezésű nyomtatott áramkör egy IP67-védett szerelődobozban kapott helyet, amelyet antennával láttak el a vezeték nélküli kommunikáció biztosítása érdekében. Fontos volt saját nyomtatott áramkör tervezése, mivel ez lehetővé tette számunkra, hogy sok funkciót egybe integráljunk, amelyekhez külön modulokat kellett volna vásárolni európai forgalmazóktól. Ily módon a nyomtatott áramkört egy 100 km-en belül működő gyártóval tudtuk elkészíttetni, és az alkatrészeit is magyar beszállítóktól vásároltuk. Ez az egység felelős az érzékelők által mért adatok gyűjtéséért és továbbításáért, valamint hiba esetén a megfelelő hibaiüzenet küldéséért. Ez a modul tartalmaz egy egyedi tervezésű nyomtatott áramkört is, amely tartalmaz egy mikrovezérlőt, mely az adatok gyűjtését, valamint a LoRaWAN hálózaton való kommunikációt végzi. A következő képen látható a nyomtatott áramkör forrasztási oldala.



39. ábra - LoRaWAN alapú szenzor panel forrasztási oldal

A fenti képen az IC1 a mikrovezérlő (STM32F042K6Tx) és a MODULE1 (RN2483) végzi a LoRaWAN kommunikációt. A következő képen látható a panel alkatrész oldala.



40. - LoRaWAN alapú szenzor panel alkatrész oldal

Tápellátás: A tápellátás egy 230V AC / 12V DC adapter, amely az eszközt táplálja. A tápellátásra az eszköz folyamatos működésének biztosítása érdekében van szükség. Felmerült a napelem használata is, de a beépített érzékelők elektromos teljesítménye túl magas ahhoz, hogy folyamatos működést biztosítson nagyobb számú akkumulátor telepítése nélkül.

A következő ábrán bemutatott kültéri érzékelő prototípus 2020 májusába lett kihelyezve Miskolc-Martinkertvárosban a Szimbiózis Alapítványhoz.



41. ábra - Kihelyezett szenzor Martinkertváros Szimbiózis Alapítvány

A tervezés és fejlesztés során különös figyelmet fordítottunk a megvalósítás bizonyos aspektusaira, mint például a szoftverfejlesztés, hálózattervezés, nyersanyaghasználat, karbantartás, hibafelismerés, stb.

A prototípus fejlesztése során a szoftver megvalósítását nemcsak a stabil és robusztus működés szempontjából vizsgáltuk, hanem figyelembe vettük az eszközök energiafogyasztására gyakorolt hatását is. Egy cikkemben leírtam a különböző szoftvermegvalósítások által a mérőrendszer fejlesztése során keletkező energiafogyasztás különbségeit, ezért megpróbáltunk olyan szoftvermegoldásokat

alkalmazni, amelyek alacsony energiafogyasztást biztosítanak, figyelembe véve a zöld informatika irányelveit [S7].

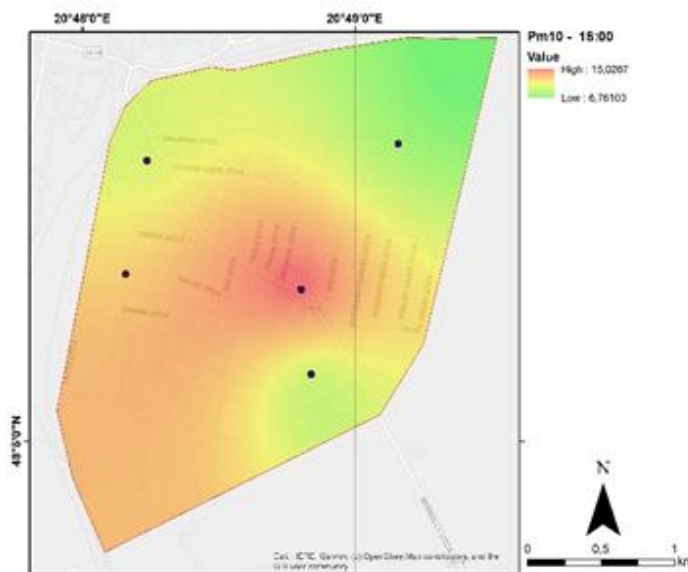
A prototípus mérőrendszert Miskolc Martinkertvárosban telepítettem ki a következő táblázatban felsorolt helyekre:

18. táblázat – Kihelyezett szenzorok Martinkertvárosban

LoRaWAN alapú szenzor címe	Szenzor helyének típusa
Alföldi utca	OLM állomás
Tapoly utca	Magánszemély, családi ház
Forgács Antal utca	Szimbiózis Alapítvány
Bajza József utca	Magánszemély, családi ház
Csonka Vitáz Mihály utca	Magánszemély, családi ház

A személyiségi jogok megsértésének elkerülése érdekében nem osztok meg pontos koordinátákat vagy házszámot, viszont a magánszemélyek önkéntes formában engedélyezték a szenzorok kihelyezését.

A következő képen már a szenzor adatokból elkészített anomália térkép látható. Elmonható, hogy a kitűzött célnak megfelelően sikerült megalkotni az általam fejlesztett mérőhálózat adataiból származó anomália térképet.



42. ábra - Miskolc-Martinkertváros anomália térkép

Az anomália térkép készítését a Miskolci Egyetem Geoinformatika tanszékének munkatársai végezték.

A következő fejezetben szeretném bemutatni a kifejlesztett LoRaWAN alapú szenzor életciklus elemzését. Az életciklus elemzés során arra keressük a választ, hogy a szenzorok egység egyes komponenseinek milyen környezetre gyakorolt hatása van. Így döntést tudunk hozni, a szenzor egység kostrucióját tekintve, és környezettudatos szemlélet mentén tudjuk a fejlesztést elvégezni.

3.1 LoRaWAN alapú szenzor életciklus elemzése

A LoRaWAN alapú szenzorok fejlesztése során az innovációja és környezettudatos szemlélet nagyon fontos szempontok voltak. Ma már nem az esztétikus formák létrehozása és az öncélú díszítések állnak a középpontban, hanem a környezetbarát technikai megoldások széleskörű alkalmazása. Ezért még az alacsony költségű szenzorok esetén is elengedhetetlen az energiahatékonyságnak és környezeti hatásainak felelősségteljes felmérése, figyelembe véve annak teljes életciklusát. Ez magában foglalja az alapanyagok beszerzésétől és helyszínre szállításától kezdve a leselejtezésig minden folyamatot.

A mérőműszerek tervezésében, és a teljes kapcsolódó hálózat fejlesztésében elsődleges fontosságú a környezetbarát tervezés és megvalósítás. Ezt a megközelítést nemcsak a hardver, hanem a szoftverfejlesztés, a hálózattervezés és a telepítés során is szem előtt tartottuk.

Az ökológiai tervezés legfontosabb tényezőire összpontosítottunk. Azonban az információs és kommunikációs technológia infrastruktúrák környezeti értékelése még mindig módszertani hiányosságokkal küzd. Bonvoisin et al. (2012) célja az volt, hogy azonosítsák a környezeti értékelés jelenlegi bizonytalanságait és javasoljanak megoldásokat ezek leküzdésére a vezeték nélküli szenzorhálózatok esetében [T24]. Ennek érdekében a fejezet első részébe áttekintjük az információs és kommunikációs technológia infrastruktúrák környezeti értékelésére vonatkozó meglévő irodalmat és az ezzel kapcsolatos módszertani problémákat és megoldásokat. Érdekes tanulmányok találhatóak az egyes információs és kommunikációs technológia infrastruktúrák és szolgáltatások elsődleges környezeti hatásairól, olyan módszereket alkalmazva, mint az életciklus hatásvizsgálat (LCA). Ezek a tanulmányok részletesen elemezték a környezeti hatásokat, amelyek segítettek azonosítani a problémás pontokat és hasznos információkat

nyújtottak az ökodizájnhoz. Azonban, ahogy Andrae és Andersen (2010) is megfigyelték, probléma van az elérhető, mélyreható környezeti adatok elérhetőségével és eloszlásával a környezeti tanulmányokhoz. Az információs és kommunikációs technológiai szektor nem rendelkezik a szükséges átláthatósággal [T25]. Ezért az ellentmondások nem érthetőek meg könnyen és nem vezethetnek a környezeti hatások jobb tudományos megértéséhez az információs és kommunikációs technológiák esetében. Néhányan megpróbálták bővíteni az elérhető módszerek skáláját, hogy lehetővé tegyék a környezeti hatásvizsgálatokat nagy rendszerek, például információs és kommunikációs technológia infrastruktúrák esetében. Egy ilyen módszer a hibrid LCA, amely sikeresen megszünteti a nagy adathiányosságokat és absztrakciókat [T26], de önmagában nem járul hozzá az átláthatóság növeléséhez. Mivel az információs és kommunikációs technológia infrastruktúrák környezeti értékelése már érdekes eredményeket mutatott, további kutatásokra van szükség az infrastruktúrák rendszerszintű leírásához. Az elemzéseket még mindig javítani kell az egyértelműség és átláthatóság terén, és modellekre van szükség a formalizálás javítására, mint például a [T27] publikációban. Ez pedig lehetővé tenné a környezeti értékelés eredményeinek hatékonyabb felhasználását a tervezés során. A hálózat környezeti hatásainak kiszámításakor az összes komponens életciklusát és szinergikus hatásait is figyelembe kell venni. Az életciklus elemzés során az érzékelők és maga a hálózat kombinált környezeti hatását is vizsgálni kell. Az érzékelő adatok előfeldolgozása szintén kulcsfontosságú lépés az adatok további feldolgozására való előkészítés részeként. Az eljárás segít tisztább adatokat nyerni kevesebb zajjal, mindazonáltal fontos figyelembe venni az ilyen eszközök beágyazhatóságát, hogy a gyártási költségeket csökkenteni lehessen. A prototípus mérőrendszer mostanra elérte azt a pontot, hogy LCA tesztelést végezhesünk. Ennek célja a késztermék környezeti hatásainak csökkentése. Továbbra is minimálisra akarjuk csökkenteni prototípusunk és végtermékünk környezeti lábnyomát, okosan megválasztva anyagainkat. Emellett tervezzük, hogy több száz ilyen rendszert telepítünk, ami még nagyobb előnyöket hoz a környezeti hatások monitorozásában és kezelésében nagy léptékben.

A fejlesztés során egy érzékelő életciklus-elemzést (LCA) végeztünk. Az elemzést az ISO 14040 szerint végeztük el, az összeszereléstől az élettartam végéig, és manuálisan, az alkatrészek jellemző tényezői alapján.

Az életciklus-értékelés, mint objektív módszer, lehetővé teszi egy termék vagy szolgáltatás teljes életciklusa során bekövetkező környezeti hatásainak számszerűsítését,

a nyersanyag-kitermeléstől az élettartam végéig. Ez azonban csak akkor lehetséges, ha az életciklus minden szakaszában rendelkezésre állnak a szükséges bemeneti és kimeneti adatok. Gyakran ezek hiányában az életciklus figyelembe vett szakaszait lerövidítik, például csak a kitermelési, szállítási és gyártási folyamatokat (A1-A3) foglalhatja magában az EN 15804 szerint. Ez az alapanyag-beszerzéstől a kapuig vagy akár a használati fázis végéig terjedhet. Ugyanakkor lefedheti a teljes életciklus spektrumát, beleértve az élettartam végi hulladékgazdálkodási megoldásokat is.

A GaBi és SimaPro szoftverek adatbázisait használva a következő hatáskategóriák vizsgálhatók az érzékelő környezeti hatásának felmérése érdekében a CML 2001 és ReCiPe módszerekkel, valamint az Európai Unió által 2018-ban elfogadott PEF/EF módszerrel. Az adatbázisból származó jellemző tényezőket a PEF/PE módszertan szerint normalizálási és súlyozási tényezőkkel korrigálva lehet aggregálni és a környezeti terhelési pontokban megkapni az eredményeket.

Az ISO 14040 és ISO 14044 szabványok szerint az LCA a következő fázisokat tartalmazza:

- cél és terjedeleme meghatározása,
- leltárelemzés, amikor az életciklus erőforrás-felhasználását és kibocsátásait számszerűsítik,
- hatásvizsgálat, amikor az erőforrás-felhasználás és kibocsátások potenciális környezeti hatásait értékelik,
- eredmények értelmezése.

Az értékelés célja, hogy meghatározza egy érzékelő éves környezeti terhelését. A funkcionális egység: 1 érzékelő környezeti hatása 1 év alatt.

A rendszerhatár magában foglalja a gyártási, fogyasztási és élettartam végi fázisokat, de a gyártási fázis magában foglalja a beszerzéshez kapcsolódó szerszámokat és a beépítendő alkatrészek korábbi környezeti hatását. Az érzékelő élettartamát az alábbi pontokban határoztuk meg.

A következő lépés a leltár elkészítése, adatgyűjtés és leltárelemzés volt. Mért adatokat használtunk, allokációt nem alkalmaztunk.

Miután alaposan megmértük és azonosítottuk a projekt szenzor egység érzékelőkomponenseiben felhasznált anyagokat, összeállítottuk az anyag típusok szerint

kategorizált leltáradatokat, ahogyan az az 19. táblázatban látható. A szállítás környezeti hatásának felmérése érdekében kiszámítottuk az egyes alkatrészek szállítási költségét tonnakilométerben (tkm). Ez a számítás figyelembe vette a beszerzési helyet, a szállítás módját és a szállítási távolságot. A modell üzemeltetése és monitorozása során a szállítási költséget pizza kilométerben (pkm) határoztuk meg. Ez a mérés egy oda-vissza utat egy pizzának megfelelő környezeti hatásra egyenlített ki. A számítás figyelembe vette az egyetem és a mérési pontok közötti távolságot, valamint a monitorozás gyakoriságát. Ezt követően ezeket az eredményeket rögzítettük a leltáradatokban.

Az elért eredmények csak az általunk összeszerelt érzékelő környezeti terhelésére vonatkoznak. Egy érzékelő környezeti terhelése az érzékelő alkatrészeinek környezeti hatásától, anyagától és a használati fázisban a monitorozás gyakoriságától és a közlekedés módjától függ. Az érzékelő környezeti terhelését összességében az élettartam végi lehet értékelni.

Az érzékelő komponenseit egyenként mértük tízes skálák segítségével, ahogy az az 20. táblázatban látható. A táblázat egyetlen érzékelő mérési adatait tartalmazza, ami azt jelenti, hogy ha 10 érzékelőt telepítünk, az anyagmennyiségeket a táblázatban 10-zel kell megszorozni.

19. táblázat – LoRaWAN alapú szenzor alapanyagai

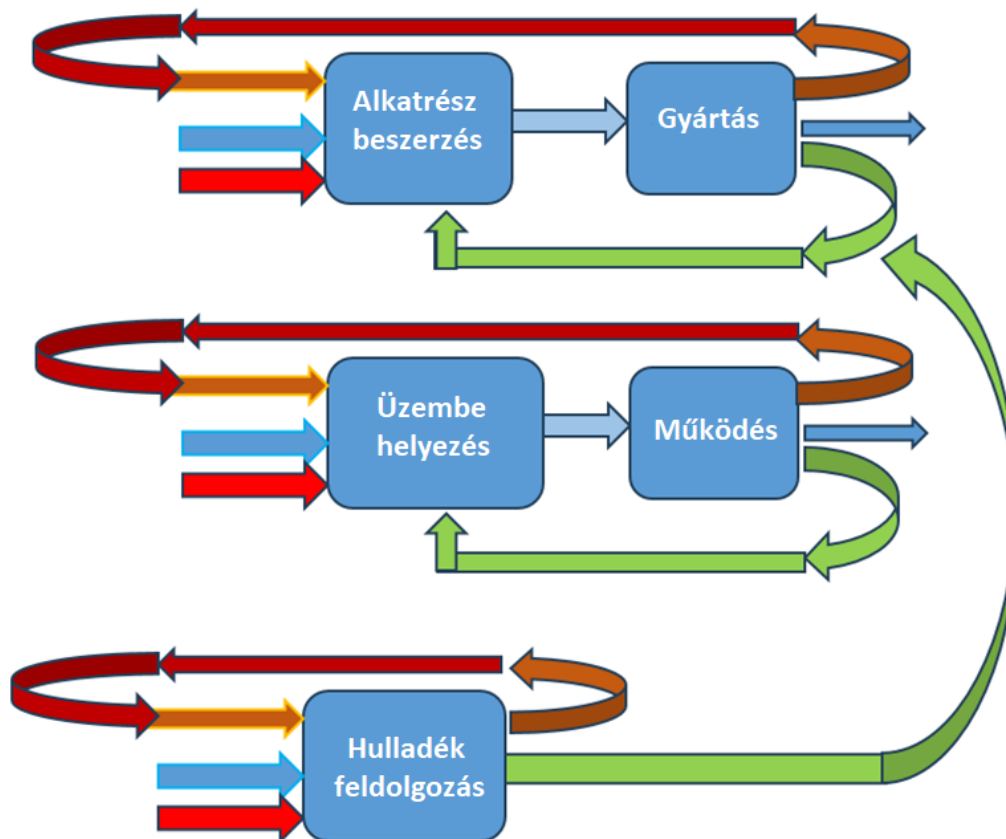
Komponensek	A1	A2	A3	B1	B2	B3	C1	C2	D1	Teljes [g]
<i>Őn</i>	1		0,8	2				4		7,8
<i>Egyéb fém</i>	1,5		0,5	3				10		15
<i>Epoxy gyanta</i>	1		0,5	9				4		14,5
<i>réz</i>	1,9	50		17	9		50	60		187,9
<i>Acél</i>	10	77		2		7			200	296
<i>Fermit</i>				2				10		12
<i>ABS</i>	6	15	0,9		2,4	174	10	11,5		219,8
<i>Kaucsuk</i>	2									2
<i>Mikorvezérlő</i>	2,6		1	1						4,6
<i>PLA</i>		180								180
<i>PVC</i>		17					30		400	447
<i>Melegragasztó</i>		80								80
<i>Ragasztó</i>									50	50
Total (g)	26	419	3,7	36	11,4	181	90	99,5	650	1516,6

Beszerezési távolság: 6831 km; 231 g. Ellenőrzési távolság: 10 km 12 esetben.
 Hulladékkezelés: égetés, 881 g, de 187,9 g réz újrahasznosítva, és 447 g PVC kétszer újrahasználva.

Hulladékgazdálkodási stratégiánk három fő megközelítést alkalmaz: újrahasználat, újrahasznosítás és égetés. Ezek a megközelítések összhangban vannak a körforgásos gazdaság elveivel, céljuk az anyagok életciklusának meghosszabbítása és az értékes erőforrások megőrzése.

Az újrahasználat egy olyan folyamat, amely arra törekszik, hogy a hulladékot újrahasznosítsa, csökkentve az új anyagok iránti igényt. Az újrahasznosítás során a hulladékot értékes termékekké alakítjuk, így kevesebb hulladék kerül a hulladéklerakókba. Égetési stratégiánk az energia-visszanyerésre összpontosít, csökkentve a fosszilis tüzelőanyagok felhasználását.

Ezekkel a megközelítésekkel kisebb ökológiai lábnyomot hagyunk magunk után és elősegítjük a fenntartható fejlődést.



43. ábra - LoRaWAN alapú szenzor életciklusa

Az 34. ábra bemutatja a vizsgált érzékelőrendszer életciklusához kapcsolódó folyamatokat: alkatrészbeszerzés, összeszerelés, karbantartás és hulladékgazdálkodás. Az elemzés figyelembe vette az érzékelő egyes alkatrészeinek élettartamát, és az egyes hatáskategóriák értékeit egy évre vetítve. Ezt azért tettük, mert a vizsgált alkatrészek többségének élettartama körülbelül egy év volt.

A teszteredményeket az alábbiak szerint mutatjuk be: Az értékelésekhez használt jellemző tényezők:

- Közeponti mutatók meghatározása:
 - az érzékelő alkatrészeihez,
 - az érzékelő életciklusához,
 - alternatív forgatókönyvekhez,
 - különböző érzékelő dobozokhoz,
 - különböző szállítási módokhoz,
 - megújuló energiához.
- A szén-dioxid semlegesítés lehetőségének vizsgálata erdősítéssel.

A 20. táblázat tartalmazza néhány alkatrész környezetszennyezési adatait.

20. táblázat – alapanagok környezetszennyezési adatai

	GWP	ADP	AP	EP	HTP
	[kg CO ₂ eq]	[kg Sbeq]	[kg SO ₂ eq]	[kg PO ₄ eq]	[kg1,4- DBeq]
Ón	20.6	0.315	0.542	0.170647	36.31747
Egyéb acél	3.18	0.0177	0.0199	0.002371	4.099038
Epoxy	8.05	0.0681	0.0214	0.003429	0.456291
Réz	0.787	0.00488	0.00352	0.000359	0.033034
Acél	1.63	0.0113	0.00833	0.00156	0.033034
Fermit	3.41	0.0477	0.00832	0.000743	1.393727
ABS	3.74	0.0451	0.0124	0.001579	0.104363
Kaucsuk	3.11	0.05	0.0471	0.001203	0.216929
Mikrovezérlő	0.269	0.00186	0.00196	2.494595	6.23E-06
PLA	3.11	0.0221	0.0116	0.011381	0.78657
PVC	2.83	0.0348	0.0198	0.001447	0.583863
Melegragasztó	1.31	0.0372	0.037	0.000501	0.456291
Ragasztó	2.64	0.0383	0.0108	0.003664	0.940736
Repülőszállítás	0.062	0.000403	0.000257	0.000791	0.83031947
Karbantartás	0.182	0.00124	0.000555	0.00014	0.066384

Ahol,

GWP: Globális felmelegedési potenciál, mértékegység: kg CO₂-egyenérték.

ADP: Abiotikus kimerülési potenciál, kg Sb egyenérték.

AP: Savanyítási potenciál, kg SO₂-egyenérték.

EP: Eutrofizációs potenciál, kg PO₄-egyenérték.

HTP: Emberi toxicitási potenciál, kg 1,4-DB egyenérték.

Az érzékelő gyártási fázisa az egyes érzékelő modulok összeszerelését foglalta magában.

Az alábbiakat vizsgáltuk:

- az azonos funkciót ellátó alkatrészek környezeti hatása,
- a beszerzési távolságok hatása,
- a beszerzéssel kapcsolatos szállítási módok hatása,
- az alkatrészek élettartama,
- az érzékelő doboz anyagának biztonsága, élettartama és környezeti hatása.

A használati szakasz az alábbiakat foglalta magában:

- Energiafogyasztás (ha lehetséges, megújuló energia, napelemek használata).
- Karbantartás.
- Ellenőrzés (logisztikai tervezés, szállítási eszközök kiválasztása).
- Adatfeldolgozás.

Az élettartam végi környezeti hatást az határozza meg, hogy mi történik az egyes alkatrészekkel. A szétszerelés utáni kiválasztás szerint:

- Anyagában újra felhasználható.
- Energia célokra alkalmas.
- Égetéssel ártalmatlanítható.
- Lerakással elhelyezhető.

A kutatás során egy összeszerelt érzékelővel reprezentált modellt használtunk.

$$EI = M_i * EF_i/T_i \quad (16)$$

Ahol,

EI a környezeti hatás kategória indikátorértékei,

M_i az egyes alkatrészek tömege,

EF_i az egyes anyagok környezeti tényezője a hatáskategóriával kapcsolatban,

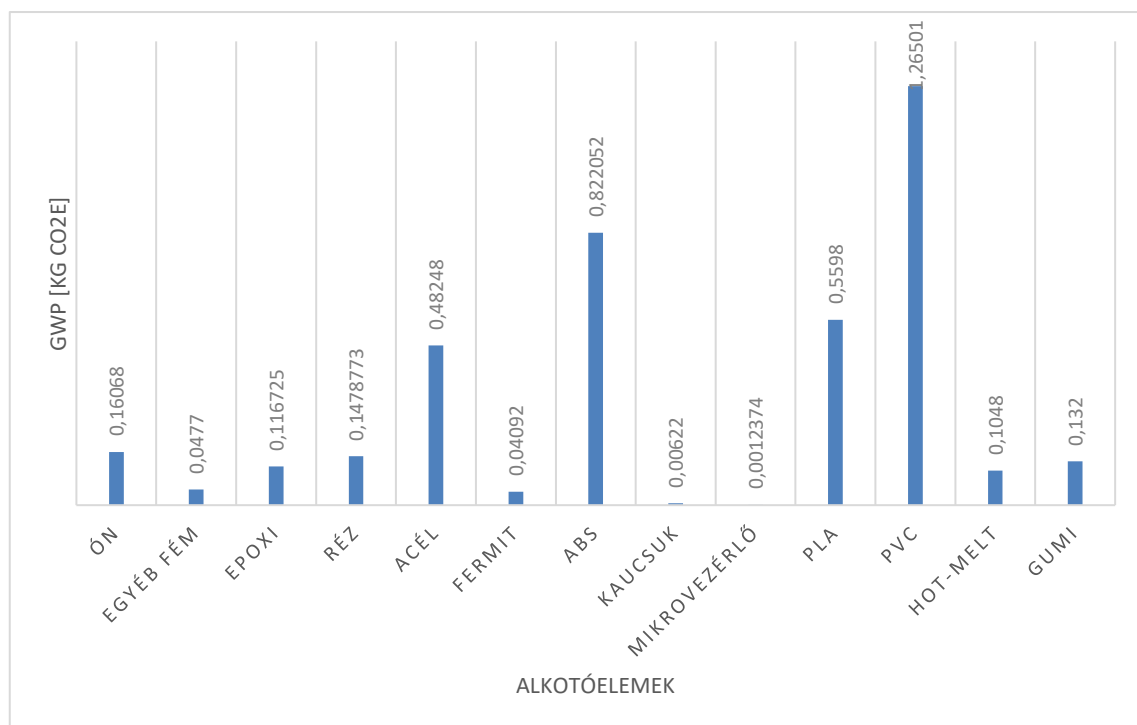
T_i az i -edik alkotóelem.

Az elemzés az LCA adatlapból meghatározott bemeneti és kimeneti áramokon alapult. Ez konkrétan magában foglalta az érzékelő alkatrészeinek szállítványozását, a beszerzéshez szükséges szállítások tonnakilométer (tkm) értékét, az összeszerelés során felhasznált energiát és az eszközök élettartama alatti arányos hatást. A kimeneti oldalon figyelembe vettük az érzékelő és alkatrészeinek csomagolási hulladékát, valamint az egyes alkatrészek élettartamuk végén keletkező hulladékáramait.

Vizsgáltuk:


- Hogyan alakul az egyes alkatrészek környezeti hatása.
- Hogyan változik az egyes életszakaszok környezeti terhelése, melyik fázis jelenti a legnagyobb terhelést.
- Hogyan lehet csökkenteni a környezeti hatást.

Az érzékelő életciklus-tanulmányának új eleme, hogy megpróbáltuk meghatározni a kültéri érzékelők életciklusához kapcsolódó szén-dioxid-mentesítési és üvegházhatás kompenzálási lehetőségeket.



44. ábra - Alkotórészek GWP értékei

Az ábra bemutatja az egy érzékelő egység anyagszintű összetételének megfelelő GWP - Globális felmelegedési potenciál értékeket. A legnagyobb üvegházhatású anyagok a PVC és az ABS voltak, amelyeket a PLA és az acél követett. Ezek az anyagok elsősorban a burkolatokban és a védőszigetelésekben fordulnak elő. A helyzet hasonló a többi kategóriában is: a PVC és a PLA anyagoknak van a legnagyobb hatása a környezetre.



45. ábra - A szenzor egy éves ciklusának GWP értéke

A súlyozott hatáskategóriák (az EU környezeti lábnyom tényezői alapján [24]) mutatják a környezeti terhelésekhez való relatív hozzájárulást. A környezeti terhelés 96%-a üvegházhatású gázokból származik és ez az életciklus használati fázisában bekövetkező karbantartási és ellenőrzési feladatok során keletkezik. Így jogosan merül fel a kérdés, hogyan lehetne ezt csökkenteni. A karbantartás során ellenőrizni kell a szenzor működését és ehhez ki kell menni a telepítés helyszínére. Ezt az elemzés során havi rendszerességre becsültük meg. Egy alkalommal körülbelül 20 km-t tesz meg a karbantartást végző személy.

A csökkentés érdekében megbecsültük, milyen környezet terheléssel járna, ha biciklivel menne a karbantartást végző személyzet. Ezzel drasztikusan lehet csökkenteni a környezet terhelést. További csökkentési potenciál lehet, ha több szenzort is útbajt egy ilyen karbantartási út során. Esetlegesen lehet csökkenteni a karbantartások gyakoriságát is.

A prototípus kifejlesztése során, amely alacsony költségű érzékelőt ír le és alkalmas a levegő minőségének és más paramétereknek a mérésére, több szempontból is törekedtünk a környezetbarát megoldások és a költséghatékonyság egyensúlyának megteremtésére. Az elvégzett életciklus-elemzések azt mutatták, hogy a tervezett rendszerünk három sarokköve a karbantartás, az eszköz nagy részét alkotó burkolóanyag megválasztása és az újrahasznosítási potenciál. A teszteredmények alapján a prototípus burkolatát mind formailag, mind anyaghasználat szempontjából át kell gondolni. Célunk az anyagfelhasználás csökkentése volt, miközben fenntartottuk az elvárt működési feltételeket.

Ezek az eredmények és fejlesztések nemcsak egy alacsony költségű légszennyezettség-mérő érzékelő gyakorlati fejlesztéséhez járulnak hozzá, hanem hangsúlyozzák a fenntartható gyakorlatok fontosságát az életciklus során. Jövőbeli terveink között szerepel a napelemes működés vizsgálata is. Ez a széles körű megközelítés aláhúzza elkötelezettségünket a környezeti felelősségvállalás iránt a technológiai innováció területén. [S1]

3.2 Tézis III.

Megépítettem egy olyan IoT alapú szállópor mérő hálózatot, amely képes adatokat szolgáltatni a szállópor koncentráció spektrális megjelenítéséhez. A mérő hálózat az általam kidolgozott kalibrációs eljárást használja az adatok pontosítására. Az általam alkalmazott eszközfejlesztési módszertan segítségével megépített IoT eszközök tervezéséhez szükséges szempont rendszereket életciklus elemzés segítségével igazoltam. [S1]

4 Tároló vágány környezet kutatása

Az utóbbi években az Ipar 4.0 nagyon elterjedt kifejezés lett az iparban. Ez egyfajta optimalizálást jelent, amellyel a gyártást igyekeznek hatékonyabbá tenni, a mai modern technológiák segítségével adatokat gyűjtenek a termelésről, amely segítségével növelhető a gyártási/termelési folyamatok hatékonysága. A FIEK projekt keretein belül a Miskolci Egyetem a Borsod Chemmel közreműködve dolgozott egy Ipar 4.0-s fejlesztésen, amely egy modern vagon helymeghatározó rendszer. A Borsod Chem területén több km vasúti pálya helyezkedik el, amelyen vagonok állnak. Ezekbe töltik az keletkezett anyagokat, majd szállítják tovább a megrendelőnek. A Borsod Chemnél a vasútüzem is egyfajta termelő szervezet, akiknek a hatékonysága mérhető, akár a tolatási műveletek számával, viszont a vagonok pontos helyének ismerete is jelentős mértékben növelheti a hatékonyságot. A közös munka keretein belül több alkalommal voltam szemtanúja annak, hogy a vasútüzemi dolgozó kockás papírra felírt vagon azonosítók alapján keresett vagonokat egy adott sín szakaszon. A vagonok pontos helyének nyilvántartása manuálisan történik a vasúti munkanapló alapján. Ez a nyilvántartó rendszer viszont pontatlan és lassú, ezért volt szükség ennek a modernizálására az Ipar 4.0 irányelveit figyelembe véve. A következő képen látható egy tároló vágány hálózat, amelyhez hasonló található a Borsod Chemnél is.



46. ábra - tároló vágány rendszer

A konzorciumi partner (Borsod Chem) elvárása, hogy egy adott tároló vágányon meg tudjuk határozni a vagonok sorrendjét, tehát nem kell pontos koordináta meghatározás. Minden vagonon található egy információs tábla, amelyen olvasható az egyedi azonosítója a vagonnak. Többek között erre a táblára erősíthetünk egy eszközt, amely képes a vagon pozíciójának meghatározására. A vagonok télen-nyáron kint vannak, így -20°C és $+70^{\circ}\text{C}$ hőmérséklet tartományban működni kell az eszköznek, ugyanis nyáron a sötét színű vagonok nagyon felhevülhetnek és akár 70°C -ot is elérheti a felületi hőmérsékletük. További elvárás, hogy az eszközt ne kelljen tölteni amíg a telep területén tartózkodik a vagon, amely akár 6-8 hónap is lehet. További megszorításokat jelentettek a BorsodChem vasúti szabályzatai, amely előírja, hogy a vágányok környékére, és a vágányok mellett elhelyezett oszlopokra és épületekre nem szerelhetünk semmilyen érzékelőt vagy eszközt. A mozdonyra és a vagonokra tudunk eszközöket erősíteni, amelyeknek meg kell valósítani a vagon lokalizációs rendszert. A vasúti térkép és a vagonok helyzetének tárolása nem volt része a feladatnak, ezt a BorsodChem fejlesztői végezték el, valamint ők fejlesztik az interfészt és az adatbázist, ahova az adatok bekerülnek.

A kutatási és fejlesztési eredmények leírása előtt szeretném röviden bemutatni a tároló vágány környezetet és a vasútüzem működését. A tároló vágányok egymással párhuzamosan húzódó hosszabb akár 1-2 kilométer hosszú vágányok. A vágányokon, olyan vasúti kocsik álnak, amelyekben például a BorsodChemben megtermelt valamint, az egyes üzemegységek működéséhez szükséges alapanyagokat tárolják. Ezek a vasúti kocsik általában tanker kocsik, de lehet akár pórekocsi is, amelyen többek között konténereket szállítanak. További speciális vasúti kocsi a só szállító kocsi. A vasútüzem feladata, hogy a telephelyre beérkező vasúti kocsikat ellenőrizze és rendeltetés szerűen tárolja, majd a töltő és lefejtő zónákba szállítsa. A vasúti kocsik telephelyről való elszállítását is a vasútüzem készíti elő. A tároló vágányok között lehetnek olyan speciális vágányok, amelyek például egy adott üzemszám töltő szerepét töltik be. További fontos pont a tömegmérő, amelyet a beérkezés, töltés és lefejtés utáni használnak.

Amikor megkaptuk a feladatot, felmerült bennem, hogy van-e már ilyen a piacon. Megkérdeztem a BorsodChem kollégáit, akik meséltek egy rendszerről, amelyet a Német telekom tudna telepíteni. Ezek GPS alapú egységek lennének, amelyek mindegyike rendelkezik SIM kártyával, mobil internet előfizetéssel is. Ez a rendszer a GPS adatokat tudta volna elküldeni, viszont a vágány lokalizációt nem. Egy ilyen eszköz bekerülési

külsége 300-400 ezer forint körül volt és emellett még havidíjas előfizetést kellett volna fizetni a SIM kártyák után. Ez túl drágának bizonyult, valamint nem volt speciálisan a tároló vágány környezetre specifikálva. A partner egy olyan eszközt szeretne, amelynek relatíve olcsó a bekerülési költsége, mert ha esetleg a telephelyet elhagyó szerelvényen rajta marad pár eszköz, ne legyen túl nagy kár belőle. A kutatás során folyamatosan kerestem olyan rendszereket, amelyekkel meg lehetne oldani a problémát, viszont nem találtam olyat, amely megfelelő lett volna. Léteznek GPS követők, amelyek beépített SIM kártyával rendelkeznek és vandálbiztos kialakításúak, viszont ezek célja nem a telephelyen belüli helymeghatározás, hanem inkább a vagon célbajutásának és a tulajdonoshoz való visszaillesztésének a nyomonkövetése. Ezek a vagonok a részét képezik a nemzetközi fuvarozásnak így egy hosszú út alatt van, hogy eltűnik 1-2. A következő képen egy vagonokon használt GPS követőt **Hiba! A hivatkozási forrás nem található.** szeretnék szemléleteni, amely a LEVEL Systems terméke.



47. ábra - Level Systems GPS követő

Az fenti eszköz egy beépített 68Ah-s akkumulátorral rendelkezik, amely akár 14 évig is képes üzemelni, amennyiben napi egy pozíció adatot küld. Folyamatos pozíció küldés esetén 1 év körül lehet az élettartama. Az árát nem merete közölni a gyártó, tapasztalataim szerint ennek a bekerülési költsége 300-400 ezer forint. Az eszköz vandálbiztos, hő-, por- és vízálló, valamint rendelkezik robbanásbiztos környezetben való használati engedéllyel is. Ehhez nagyon hasonló eszközökből sok található a piacon, viszont ez nekünk nem volt jó. A burkolat tekintetében nem elvárás a vandálbiztos kivitel. A GPS alapú helymeghatározás sem túl szerencsés, mert véleményem szerint nem lesz elég pontos az a típus, amelyet egy ilyen kis eszközbe be lehet integrálni, valamint túl nagy a fogyasztása is.

A rendszer megvalósítására kétféle alternatív megoldási javaslatom volt:

1. Vagonok helyzetének folyamatos monitorozása
 - Ebben az esetben olyan szenzorokat kell minden egyes vagonon elhelyezni, amely képes meghatározni a saját helyét a tároló vágány hálózaton.
2. A vagonok mozgásának monitorozása.
 - Ennek a megvalósításnak az a feltétele, hogy a rendszer beindításának pillanatában tudjuk a vagonok elhelyezkedését. Ezután már minden mozgást tudunk követni és tudjuk frissíteni a térképet.

Mind a két esetben elhelyezésre kerül a mozdonyban egy központi egység, amely egyrészt a mozdony helyzetét méri GPS alapon, valamint rendelkezik kapcsolattal a vasúti szoftver felé. Így képes információt továbbítani a saját helyzetéről, illetve a mozdonyra szerelt érzékelők mérését is képes továbbítani.

Az első megoldás előnye, hogy a vagonok képesek meghatározni a pozíciójukat. A pozíció meghatározásához az egyetlen megoldás a GPS-alapú helymeghatározás, ami szóba jöhet, mivel nem építhető semmilyen egyéb eszköz se a vágányok közé, se mellé. Ennek hátránya, hogy ez nem alacsony energiafogyasztású. Egy kisebb GPS modul is felvehet akár 500 mW teljesítményt, főként rádiós kommunikáció közben. Továbbá, nem szolgáltat azonnal pontos adatokat. Egy pár percnél el kell telnie, hogy megtalálja a szükséges műholdakat és képes legyen pontos adatot szolgáltatni. További negatívum, hogy az a GPS eszköz, amelynek pontossága elegendő ahhoz, hogy két egymástól 5 méterre elhelyezkedő sínpár között tudjon különbséget tenni, elég költséges. A mért pozíció-adat továbbítására alkalmas lehet egy privát LoRaWAN hálózat is.

A második megoldásnak az a hátránya, hogy a vagonokra szerelt eszközök nem képesek meghatározni a saját pozíciójukat. Ezek az eszközök csak kommunikációs modulokat tartalmaznak, így alacsonyabb kapacitású akkumulátorral megoldható a hosszú idejű, akár fél-, egy éves működés. Az eszközöknek csak annyit kell tudni, hogy valamilyen rövidtávon működő kommunikáción keresztül meghatározzák a szomszédos vagon azonosítóját és ezt az információt továbbítani kell a mozdonyban elhelyezett központi egység felé. Ebben a megoldásban a pozíciómeghatározás a mozdonyba beépített központi egységben történik, ahova be lehet ruházni egy nagyobb összegű, pontos GPS egységre, amellyel pontos helymeghatározást lehet megvalósítani. Ennél a megoldásnál a vagonok pozícióját a mozdonyhoz képesti relatív pozíció fogja megadni.

Mind a két megoldás esetén a beépített eszközöknek tartalmaznia kell egy beépített inerciális szenzort is, amely képes arra, hogy felkeltse az eszközt mozgás esetén. Nyugalmi állapotban ezek a vagonokra szerelt eszközök alvó állapotban üzemelnek az akkumulátorról való üzemidő maximalizálása érdekében.

A második megoldással fogok foglalkozni és ennek a fejlesztését fogom a továbbiakban bemutatni, mert a második megoldást

4.1 Irodalmi áttekintés

A feladat első lépéseként megvizsgáltam a tudományos irodalomban, hogy milyen publikációk foglalkoznak vasúti helymeghatározással, ezen belül is tároló vágányok modellezésével és vasúti járművek modellezésével.

Az utóbbi években egyre többen foglalkoztak vasúti kocsikkal kapcsolatos helymeghatározással [T9], valamint egyéb mérésekkel. Egy komolyabb vasúti kocsi helymeghatározó rendszert találtam, amelyről született több tudományos publikáció, ez pedig a RailSLAM [T10][T11][T12][T13]. Ez a rendszer hasonlóan az általunk fejlesztendő rendszerhez IMU-n, (Inertial Measurement Unit) valamint GPS [T14][T15] szenzoron alapszik, amely esetlegesen Kálmán-szűrő (EKF – Extended Kalman-filter) segítségével pontosítja a mozdony helyzetét, ha a GPS kapcsolat akadozna. Léteznek olyan rendszerek is, ahol számos szenzorból álló infrastruktúrát építenek ki a sínek mentén. Ezen szenzorok adataiból tudnak következtetni a szerelvény hosszára, tömegére, valamint sebességére [T16][T17][T18][T19]. Ezen rendszerek mindegyike a vasúti személyszállításra használt sínpályákon közlekedő vonatokra épít, nem találtam olyan publikációt az irodalom áttekintése során, amely tároló vágányokon álló vasúti szerelvények helymeghatározásával foglalkozott volna, azonban a fent bemutatott irodalmak jó alapot jelentenek a kutatásomhoz.

A tároló vágány környezetben történő helymeghatározás azért nehezíti meg a feladatot, mert itt több vágány található párhuzamosan egymástól legfeljebb 5 méter távolságra, míg a személyszállításra használt sínpályák esetén általában két párhuzamos vágányon közlekednek a vasúti szerelvények.

Az irodalom és a peremfeltételek ismeretében a következő nagyobb kutatási, fejlesztési egységekre bontottam a feladatot:

- Sorrend meghatározás.

- Helymeghatározás tároló vágány környezetben.
- Tároló vágány hálózat modellezése.

4.2 Sorrend meghatározás

A vagon sorrend meghatározó rendszer célja, hogy rendező pályaudvarokon tolatási műveletek során a mozgó vagonok sorrendjét meghatározza. Ebben a témában beadásra került egy szabadalmi bejelentés is, amely átment az újdonság kutatáson és az egyetem fent is tartja[S13]. A rendszer bármely vasúti tároló, tanker és egyéb vagonhoz kompatibilis.

A sorrend meghatározás két nagyobb egységre bontható: egy mérnöki fejlesztésre, ahol a vagonra szerelt eszköz prototípus fejlesztését végeztem el, valamint egy eljárás kidolgozására, amellyel meg tudom valósítani a vagon sorrend meghatározást.

A sorrend meghatározásra egy olyan eljárást dolgoztam ki, amelyben olyan eszközök kerülnek beépítésre, amelyek képesek a szomszédos vagon felismerésére, valamint az adatok továbbítására a mozdony felé. A szomszédos vagonok érzékelésére megfelelő lehet bármilyen kis távolságon működő kommunikáció.

A fejlesztés első lépése egy olyan akkumulátor kiválasztása volt, amelynek rendkívül alacsony az önkisülése és így alkalmas lehet a fél-, egy éves üzemre is.

A következő táblázatban szeretném bemutatni a különböző akkumulátor technológiák önkisülését.


21. táblázat – Akkumulátor technológiák összehasonlítása az önkisülés szempontjából

Akkumulátor Típus	Önkisülési Arány (havonta)	Jellemzők
LiFePO4 (Lítium-vasszulfát)	3-5%	Hosszú tárolási idő, alacsony önkisülés.
Lítium-ion (Li-ion)	1-3%	Magas energiasűrűség, alacsony önkisülés, széleskörű alkalmazás.
Lítium-Polimer (Li-Po)	2-5%	Rugalmasság formában, alacsony önkisülés.
Nikkel-fém-hidrid (NiMH)	20-30%	Magas kapacitás, gyors önkisülés.
Nikkel-kadmium (NiCd)	15-20%	Tartósság, nagyobb önkisülés, memóriaeffektus.
Ólom-sav (Lead-acid)	4-6%	Alacsony költség, alacsony önkisülés.

A fenti táblázat alapján a Lítium-ion akkumulátor technológiára esett a választás, ami széleskörben elterjedt, kiforrott technológia. Az akkumulátoros szerszámgépeknél is ezt használják.


A következő kihívás a kommunikációs technológia kiválasztása volt. Amennyiben a mozgó szerelevényt érzékeljük, úgy a szerelvényben mozgó eszközöknek kell kommunikálni. A szerelvények egészen hosszúak lehetnek, akár 15-20 kocsiból is állhatnak, amelynek a hossza 337-450 méter között van (átlagosan 22,5 méter/kocsi). A mozdonyban lévő adatgyűjtővel kell minden vagonra erősített eszköznek kommunikálnia, így csillag vagy hálós (mesh) hálózati topológiák használhatóak a kommunikációra.

- Csillag topológia: A csillag topológiában minden eszköz közvetlenül csatlakozik a központhoz (esetünkben a mozdonyhoz). Ez azt jelenti, hogy stabilan kell kommunikáljon akár 300-400 méter távolságból is ipari környezetben.



48. ábra - Csillag hálózati topológia

- Hálós (mesh) topológia: A hálós topológia lehetővé teszi, hogy az eszközök továbbítsák egymás üzeneteit, így amennyiben nem képesek pont-pont kommunikációt létesíteni 400 méteren, viszont minden kocsin 22,5 méterenként elhelyezésre kerül egy eszköz, amely képes az adat továbbításra. Így lecsökken az a távolság, amelyet át kell hidalni rádiófrekvenciás kommunikációval, amelynek köszönhetően használható alacsonyabb teljesítményű rádiós modullal ellátott eszköz is.



49. ábra - Hálós (mesh) hálózati topológia

A hálós topológiára esett a választásom, így a továbbiakban szeretném kiválasztani a hálós topológiát megvalósító kommunikációs technológiát. A Zigbee és a Bluetooth 5.0 mesh hálózatában gondolkodtam.

További előnye a hálós topológiának, hogy önszerveződő.

22. táblázat – Bluetooth mesh és Zigbee hálózatok összehasonlítása

Jellemzők	Bluetooth 5.0 Mesh	Zigbee
Átviteli tartomány	Akár 200 méter	10-100 méter
Sebesség	2 Mbps (csökkentett Mesh hálózatban)	Akár 250 kbps
Frekvencia	2,4 GHz	2,4 GHz
Energiafogyasztás	0,01 - 0,5 W	0,001 - 0,1 W
Alkalmazások	Ipari IoT, épületautomatizálás, egészségügy	Okos otthon, ipari IoT, egészségügy

Az általam fejlesztett rendszerben is, de általánosan főleg az ipari IoT rendszereknél nagyon fontos az adatbiztosnág, amelyet mind a Bluetooth, mind a Zigbee AES-128 titkosítással, valamint egyedi hálózati autentikációval old meg. Mind a két technológia bővíthető akár több ezer eszközre is.

A fenti táblázatban ugyan a Bluetooth mesh energiafogyasztása nagyobb a Zigbee energiafogyasztásánál, de amennyiben ezt súlyozzuk az adatátvitel sebességével, már a Bluetooth meshnek lesz alacsonyabb a fajlagos adatátvitellel súlyozott energiafogyasztása. További előnye a Bluetooth meshnek, hogy dupla olyan messzire tud kommunikálni, mint a Zigbee. Ezen érvek alapján a Bluetooth 5.0 mesh hálózatát választottam ki, mint kommunikációs technológia a fejlesztéshez.

A rendszer a sorrend meghatározását a vagonokra elhelyezett eszközök segítségével tudja elvégezni. Minden vagonra két eszköz kerül. Ezek az eszközök egymással, valamint az adatgyűjtő egységgel is kommunikálnak több interfacen keresztül. Olyan kommunikációs topológiát választottam, amely robosztus és lehetővé teszi az adott esetben több 100 méteres adat továbbítást. Az eszközök Bluetooth 5.0 mesh alapon kommunikálnak. A következő képen látható a rendszer felépítését ábrázoló blokkvázlat.

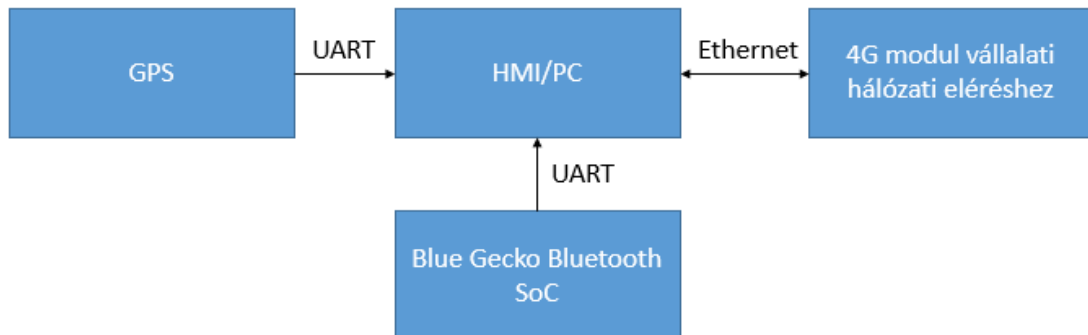


50. ábra - Vagon sorrend meghatározó rendszer felépítése

A továbbiakban bemutatom a rendszer építőelemeit. A rendszer három fő egységből áll:

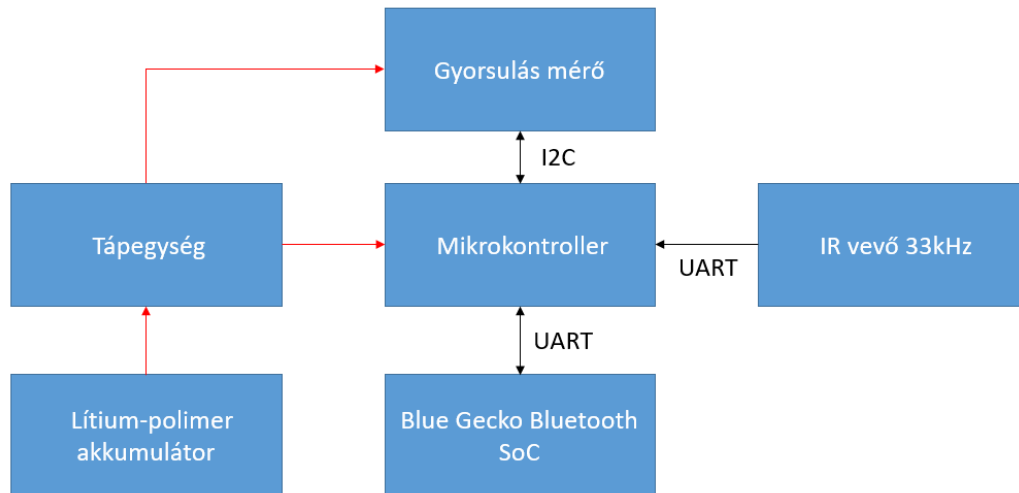
- Adatgyűjtő egység.
- Adattároló egység.
- Adattovábbító egység.

Az adatgyűjtő egység egy Blue Gecko Bluetooth SoC, amely kliens üzemmódban működik. Fogadja az összes broadcast üzenetet a mesh hálózatban. A fogadott üzeneteket továbbítja a feldolgozó eszköz felé USB-n keresztül. Az adatgyűjtő egység feladata, hogy kommunikáljon a szerelvényben mozgó kocsikkal és az adatokat feldolgozás után továbbítsa a BorsodChem vasúti nyilvántartó rendszere felé, valamint visszajelzést ad a mozdonyvezetőnek a húzott vagonok sorrendjéről. Ez az egység rendelkezik egy nagy pontosságú GPS egységgel, amely képes követni a vágányon a mozdony mozgását.



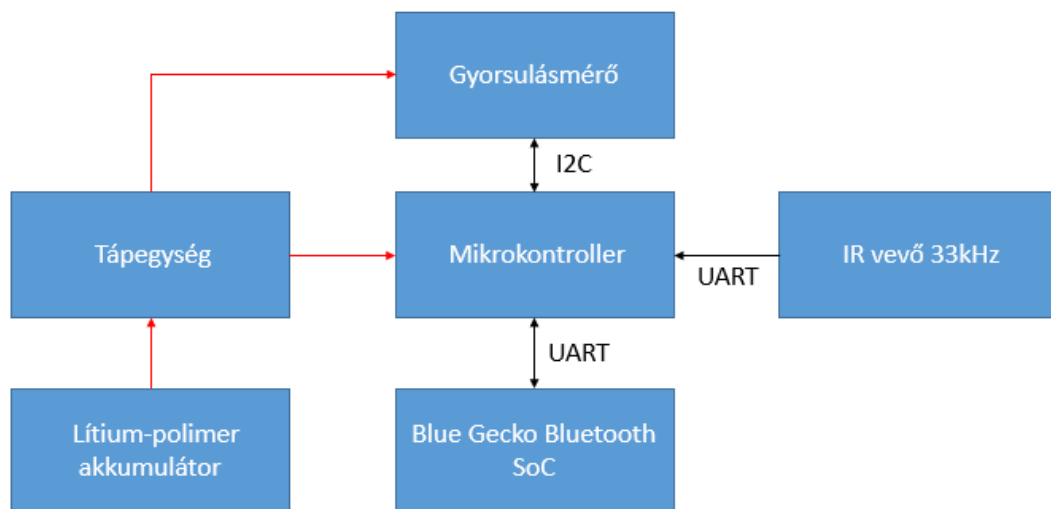
51. ábra - Adatgyűjtő egység felépítése

Az adattovábbító egység feladata, hogy amennyiben van szomszédos vagon, úgy érzékelje a jelenlétét és küldje el az azonosítóját Bluetooth mesh-en keresztül. Amennyiben az eszköz aktív, úgy részt vesz a Bluetooth mesh kommunikációban, tehát ha kap egy üzenetet, amely az adatgyűjtő eszköznek szól, akkor továbbítja azt is, nem csak a saját üzenetét. A fenti 50. ábrán ez a piros modul. Amennyiben nyugalomban van a szerelvény, amelyre fel van szerelve, alvó állapotban van az eszköz.



52. ábra - Adattovábbító egység felépítése

Az adattároló egység tárolja az adott vasúti szerelvény azonosítóját és amennyiben mozogni kezd, elkezd folyamatosan elküldeni a szomszédos vagon adattovábbító egysége felé. Amennyiben a vagon, amelyre fel van szerelve nyugalomban van, úgy nem kommunikál, alvó állapotban van.



53. ábra - Adattároló egység felépítése

A vagonra szerelt adattároló és adattovábbító eszközök között a vevő oldalon (adattovábbító eszköz) egy 33kHz-es infra szűrő található, így a kommunikációt az adó (adattároló eszköz) oldalán 33kHz-es négyzet impulzussal kellett modulálni. Ezt a kommunikációs megoldást azért így valósítottam meg, mert a két eszköz közötti kommunikációnak olyannak kell lennie, amelyet már a szomszédos vagon adattovábbító eszköze nem érzékelhet, tehát ez rövid távolságon működő kommunikáció, amely akár

szabályozható is a 33kHz-es modulált négyyszög impulzusok kitöltési tényezőjének változtatásával.

A következő ábrán láthatók a próbaüzem során felszerelt eszközök.



54. ábra - Teszt üzem

A fenti képen a kék egység az adattároló egység, a piros pedig az adattovábbító egység, amely Bluetooth mesh-en keresztül küldi tovább az adatait, amelyet a következő táblázat szemléltet. A táblázatban lévő számok mesh azonosítók, amelyek 16 bites integer számok.

23. táblázat – Adattovábbító eszközöktől érkező adatok

Adattovábbító mesh azonosító	Adattároló mesh azonosító
32	45
50	32
63	12
45	63
38	50

A fenti tábla a szomszédsági viszonyokat írja le. Amennyiben az Adattovábbító mesh azonosítók között van olyan szám, amely a másik oszlopban nincs benne, úgy az lesz az első vagon a szerelvényben. Amennyiben van olyan elem, amely csak az Adattároló mesh

azonosító oszlopban van benne, úgy az lesz az utolsó vagon a sorban. A közbülső elemek megtalálhatók mind a két oszlopban.

Ezt az adatstruktúrát a Bluetooth module párokban küldi, ezért a következőképpen kezelem.

```
A = [ [32,45],  
      [50,32],  
      [63,12],  
      [45,63],  
      [38,50]]
```

Az adatokból készítek egy mátrixot a fenti példa szerint, ahol az A változó a szomszédsági viszonyokat leíró mátrix.

Ezekből az adatokból kell tudni meghatározni a vagonok sorrendjét, amelynek az első lépése az első elem megkeresése. Ezt a következő algoritmus szerint végzem el.


```
first_id = 0  
for i in range(len(A)):  
    is_first = True  
    for j in range(len(A)):  
        if A[i][0] == A[j][1]:  
            is_first = False  
    if is_first:  
        first_id = i  
        break
```

Ahogy már említettem, az első (Adattovábbító egység oszlopa) oszlopban lévő adatok közül kell azt megkeresnem, amely nincs benne a második (Adattároló egység oszlopa) oszlopban. A fenti algoritmus a first_id változójába menti el az első elem sorának azonosítóját.

Amennyiben megvan az első elem, fel lehet építeni a sorrendet a következő algoritmus szerint.


```
out_vec = [A[first_id][0]]  
vec_size = len(out_vec)  
out_vec.append(A[first_id][1])  
while len(out_vec) != vec_size:  
    vec_size = len(out_vec)  
    for i in range(len(A)):  
        if out_vec[-1] == A[i][0]:  
            out_vec.append(A[i][1])  
            break
```


A fenti algoritmus az `out_vec` változóba menti el a sorrendet, kiinduló adatnak felhasználva a `first_id` változót az első elem sorára mutató azonosítóként. A bemutatott algoritmusok pythonban íródtak. Az algoritmus kimenete a következőt adja sorrendként.



55. ábra - A példában bemutatott adatstruktúra végleges vagonrendje

A kommunikációs modul és az akkumulátor kiválasztása után, méréseket végeztem egy inerciális szenzorral (MPU9150), amely tartalmaz giroszkópot és gyorsulásmérőt is. A mérések során a gyorsulásmérőt használtam és azt vizsgáltam, milyen jel mérhető a vagonok indulásakor. A következő ábrán szertném bemutatni a mért jelalakot.



56. ábra - Vagon indulási tranziens

A kék görbén látható egy oszcilláció, azért van mert a vagonok nem szoros kötésben vannak és így amikor meghúzza a szerelvényt a mozdony, beleng a vagonosor, amíg nem indul meg. A vörös színű görbe a sebesség, amelyet a kék gyorsulás adatokból integráltam ki numerikus úton. A mérés célja az, hogy meghatározzam azt a küszöbértéket, amely felett a gyorsulásmérő megszakítást küld és felkelti a vagonokra szerelt eszközt. A mérések alapján ezt 1 m/s^2 -re választottam meg. Amennyiben ezt meghaladja a gyorsulás értéke, a vagonokon lévő eszköz felkel és elkezd mérni a sebességet, ha a sebesség

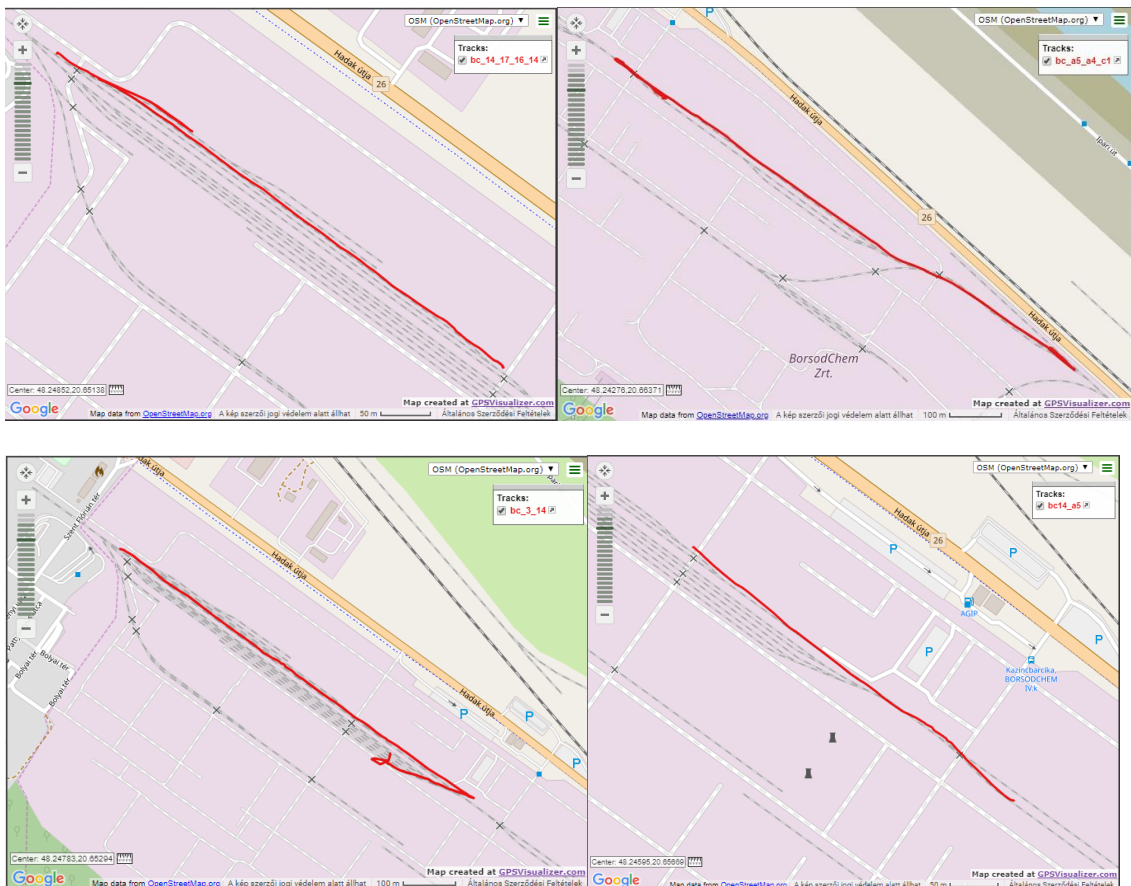
meghaladja az 1 km/h-t, elkezd kommunikálni. A sebesség mérésre azért volt szükség, mert van olyan, hogy a mozdony csatlakozáskor megnyomja a vagonkort és ilyenkor a gyorsulásmérők felkelhetnek az egyes eszözöket. A sebességméréssel ki tudom szűrni azokat a vagonokat, amelyeket ténylegesen felakasztottak a vagonorból és el is indultak.

4.3 Helymeghatározás

A helymeghatározásra egy GPS alapú megoldást fejlesztettem, amelyhez több alkalommal végeztem próbaméréseket. A méréshez a GY-NEO6MV2 **Hiba! A hivatkozási forrás nem található.** típusú GPS-t használtam. Ez az egyik legolcsóbb GPS modul volt, ami kapható.

A próbaméréshez a GPS modult belehelyeztük egy IP67-es kötődobozba és felraktuk a mozdony tetejére. Az adatokat a saját laptopommal rögzítettem egy specifikusan erre a célra fejlesztett egyedi szoftverrel, amely feldolgozta a GPS által küldött NMEA üzeneteket.


A következő képeken szertnék szemléltetni egy pár próbamérést



57. ábra – BorsodChem vasúti próbamérések

A mérések alapján úgy gondoltam, hogy alkalmas lehet a műszer a mozdony helymeghatározására, a fejlesztési szakaszban. Amennyiben, a rendszert sikerül beüzemelni, be lehet ruházni egy pontosabb GPS vevőre.

A mérések elvégzése után elkezdtem kidolgozni egy, a mozdony helyének meghatározására szolgáló algoritmust, amely a GPS adatok alapján számol. Az elvárás az volt, hogy a vágány számát adja meg az algoritmus, ahol éppen a mozdony tartózkodik. Az algoritmus az adott vágányok végpontjai alapján számol. A működés szemléltetésének érdekében egy példa tárolóvágány rendszert építettem fel.




58. ábra - Példa tároló vágány hálózat egyenes vonalú sínpályákkal

A fenti ábrán látható pirossal jelölt pontok a vágányok végpontjai. Ezeknek a pontoknak a pontos GPS koordinátáinak ismerete szükséges a helymeghatározáshoz. Ezeket a koordinátákat felvettem a BorsodChem tárolóvágány hálózatán is. A kimérést a projekt során egy vasútüzemi dolgozóval közösen manuálisan végeztük el minden egyes vágányra. A következő táblázatban néhány példaadatot mutatok be.

24. táblázat – Fenti példa térkép végpontjainak koordinátái

Vágány	Déli oldal		Északi oldal	
	Szélesség	Hosszúság	Szélesség	Hosszúság
V.	48,246240	20,655365	48,248115	20,651443
IV.	48,246185	20,655580	48,249200	20,649280
III.	48,246185	20,655710	48,249280	20,649200
II.	48,246240	20,655710	48,249400	20,649100
I.	48,246200	20,655930	48,249455	20,649100


A fenti adatok GPS koordináták, amik a föld középpontjához képesti gömbi koordináta rendszerben vannak felvéve. A hosszúság és a szélesség egy-egy vonalat jelöl meg a gömbfelületen, és a kijelölt pont a kettő metszéspontjában van. A következő képen látható az általam vizsgált vágányrendszer betájolva.



59. ábra - A példa vágányrendszer betájolva

Látható, hogy a sínek az északhoz képest 60°-os szöget zárnak be. A tájolásra azért volt szükség, mert így tudtam például a haladás irányát is meghatározni.

A következő lépés az algoritmus szemléltetése. Tegyük fel, hogy mérünk a GPS-el egy pontot. A következő ábrán látható kék ponttal szemléltetem.



60. ábra - Mérési pont a vágányokon

Ahol,

A türkiz kör a mérési pont.

A sárga vonal a mért pont szélességi koordinátához tartozó kör.

A zöld vonal a mért pont hosszúsági koordinátához tartozó kör.

A lila pontok az interpolált pontok.

A piros pontok a vágány végpontok.

Az algoritmus először megvizsgálja, hogy melyik sínen helyezkedhet el ez a mérési pont. Ez úgy történik, hogy megvizsgálom, a mért pont szélességi és hosszúsági koordinátája az adott vágány végpontjának szélességi és hosszúsági koordinátái közé esnek-e. A képen látható, hogy az I-es vágány végpontjai közé csak a hosszúsági koordináta esik, így ez már nem lesz vizsgálva a továbbiakban. Az is jól látszik továbbá, hogy a VI. vágány végpontjai teljesen kívül esnek a mért pont koordinátáitól.

A fenti példában a II., III., IV. és V. vágányokon lehet a pont. A következő lépés, hogy az adott vágányokra a végpontok és a mérési pont hosszúsági koordinátája alapján interpolálok egy-egy szélességi koordinátát. Az interpoláció a következő képlet alapján történik.

$$LAT_M = LAT_N + \frac{LONG_M - LONG_N}{LONG_S - LONG_N} * (LAT_S - LAT_N) \quad (17)$$

Ahol,

LAT a szélességet,

LONG a hosszúságot,

M a mért pontot jelenti,

S a déli,

N az északi oldala a vágány végpontjának azonosítója.

A fenti összefüggés nem a klasszikus GPS koordináta interpoláció. Az én esetemben ez azért működőképes, mert a sínek végpontjai között maximum egy-két kilométer a távolság és ezen a távolságon a föld görbülete még teljesen elhanyagolható.

A lineáris interpolációt követően, az interpolált pontok hosszúsági koordinátáit kivonom a mért pont hosszúsági koordinátájából, majd veszem ezen különbségek abszolút értékét. Az így kapott értékekből megkeresem melyik a legkisebb, és az ahhoz tartozó vágány lesz a helymeghatározás eredménye.

A következő képen látható az általam fejlesztett C# alkalmazás felhasználói felülete, amely képes beolvasni a vágányok végpontjának GPS koordinátáit egy excel forrásfájlból. Az alkalmazás rendelkezik két soros port bemenettel, amelyre rá lehet kötni egy Bluetooth eszközt, valamint egy GPS-t. A GPS NMEA üzeneteket feldolgozza és a GPS koordinátát, valamint az adat minőségét tartalmazó adatot használja fel a továbbiakban. A hosszúság és szélesség adatból meg tudja becsülni, hogy éppen melyik vágányon van a mozdony.

The screenshot shows a software interface with two main panels: 'GPS control' and 'Node control'. The 'GPS control' panel includes a 'Connect' button and a table of rail data with columns for Rail, Start, End, Latitude, Longitude, and Difference. The 'Node control' panel includes a 'Connect' button and a table of real-time data with columns for Time, GPSLatitude, GPSLongitude, Latitude, Longitude, Rail, Velocity vector, Quality, and LatitudeOffset. The 'Node control' table shows a 'Pillanatnyi helyzet' (Current position) of 1/I., 'Pontoshelyzet helyzet' (Point position) of 1/I., 'Latitude' of 48,247901, 'Longitude' of 20,652471, 'Sebességvektor' (Velocity vector) of -1, 'Adat minősége' (Data quality) of 1, and 'Latitude Offset' of 0,000000.

61. ábra - Az általam fejlesztett vasúti szoftver

Az alkalmazásba, ahogy már említettem, implementálásra került a fent bemutatott helymeghatározó algoritmus, amellyel utána elvégeztem a terepi tesztek is. A tesztek során megállapítottam, hogy az algoritmus működőképes. Az algoritmus pontos helymeghatározásának feltétele a pontos GPS koordináták.

Lehetőség van arra is, hogy tesztelés közben kiválasszuk a pontos vágányt, amellyel tudjuk validálni a mérést.

4.4 Tárolóvágány-hálózat modellje

A következő fejezetben szeretném bemutatni a tárolóvágány környezeti modellt. Ez egy tároló gráfmodell, amely egy egyedi adatstruktúrával rendelkezik a tárolóvágány környezet reprezentálásához. A gráfmodell lehetőséget ad különböző optimalizálási algoritmusok futtatására, amelyekkel hatékonyabb tolatási műveleteket tud végrehajtani a mozdony személyzete. A tárolóvágány hálózatok különböznek a normál vágány-hálózatoktól. Itt több az egymáshoz közel futó vágány, ahol bonyolultabb a helymeghatározás. A lokalizációt a tárolóvágányon belül GPS alapon valósítottam meg. A nagy pontosságú GPS-ek elég pontosak ahhoz, hogy az adatok alapján különbséget tudjunk tenni két, egymással párhuzamosan futó vágány között. Ezek a vágányok általában egymással párhuzamosan egyenes vonalba futnak. Amennyiben a vágány nem egyenes vonalban fut, úgy több, egyenesen futó darabra vágom szét. A tárolóvágányokon tárolt vagonok sorrendjét is tudni kell detektálni. Van, hogy egy adott vágányon a tárolás mellett egyéb műveleteket is elvégeznek:


- Vagonok töltése: Az egyes üzemegységekhez tartoznak egyedi töltőállomások, ahol a megtermelt anyagot tudják betölteni a tanker vagonokba.
- Lefejtő állomás: Az egyes üzemegységekhez kötődnek egyedi lefejtő állomások, ahol a telephelyre érkezett nyersanyagokat tudják lefejteni.
- Vagon tömeg mérő: A vagonokat töltés és lefejtés előtt és után leméri, hogy tudják, mennyi anyagot fejtettek le vagy töltöttek be.

Ezek a speciális vágányok a tárolóvágány környezet részei, ahol adott esetben vagonokat is tárolhatnak.

Találtam további cikkeket, ahol sorokkal (queuek) foglalkoznak [T20]. Ez érdekes volt számomra, mert hasonló modellt mutat be, mint az általam kitalált. Sorok (Queue) segítségével meg tudom határozni a tolatási műveletek bonyolultságát a betárolás és kitárolások száma alapján. A sort olyan módon fogom használni, hogy mindkét végéről tudok hozzáadni és elemeket elvenni, tehát ez nem a klasszikus FIFO elv szerit működő sor. Szeretném kombinálni a gráfmodellt egy-egy sorral, amely tárolja az adott vágányon tartózkodó vagonokat.

4.4.1 Vágány modell

Találtam egy részletes vágány modellt, amelyet a következő képpel szeretnék szemléltetni. A vágány orientációját felírhatjuk normál derékszögű koordináta rendszerben, valamint amennyiben pontos vágány reprezentációt szeretnénk, használhatjuk az Euler-szögeket a vágánydőlés és a vágány meredekségének megadására.



62 ábra - Vágány modell [T11]

Ez a modell topológiai leképezési megközelítést alkalmaz, amely azt jelenti, hogy a síneket különböző darabokra vágják és interpolálják sokszögvonallal közelítéssel [T11] a következő vektor-paraméterek segítségével.

$$T_{PS} = \left\{ s, \underbrace{lat_s, lon_s, alt_s}_{\text{geo pozíció}}, \underbrace{\phi_s, \theta_s, \psi_s}_{\text{Euler szögek}}, \underbrace{\left(\frac{d\phi_s}{ds}\right) s, \left(\frac{d\theta_s}{ds}\right) s, \left(\frac{d\psi_s}{ds}\right) s}_{\text{görbület}} \right\} \quad (18)$$

Ahol,

s a vágány egy pontja,

ϕ, θ, ψ az Euler-szögek.

A tárolóvágányok modellezéséhez leegyszerűsítettem a fenti bonyolult modellt. A tárolóvágányok többnyire egyenes vonalúak, ezért könnyen modellezhető egyenes szakaszokkal, így a vágányokat a végpontokkal, valamint a töréspontokkal szeretném modellezni. Egy ilyen pontot a következő adatstruktúrával írhatunk le.

$$T = \{lat, lon\} \quad (19)$$

Ahol,

T egy töréspontot,

lat a szélességi koordináta,

lon pedig a hosszúsági koordinátát ír le.

A fenti bonyolult modellből csak a geo adatok közül a szélességi és hosszúsági koordinátákat tartottam meg, a tengerszint feletti magasság nem hordoz olyan információt, amely fontos lenne a tárolóvágányok modellezésében. A vágányt (R) ezen töréspontok listájával fogom reprezentálni.

$$R = \{s, T_1, T_2, \dots, T_n\} \quad (20)$$

Ahol,

s a vágány hosszát leíró változó,

T_n pedig egy töréspont.

A tárolóvágány leírásához további változókat vezetek be a pontos reprezentációja érdekében.

$$S = \{I, c, c_l, R, O_w\} \quad (21)$$

Ahol,

S a tárolóvágány adatsrtuktúrája,

I a vágány azonosító,

c a vágányra betárolható kapacitás,

c_l a betárolt vagonok száma,

O_w a betárolt vagonok azonosítóját tartalmazó sor (queue).

Egy tanker vagon általános hossza 22,5 méter, így a betárolható kapacitást a következő formula alapján tudjuk meghatározni.

$$c = \frac{s}{22,5} \quad (22)$$

Az O_w sor a vagon adatok rendezett listáját tartalmazza. Ez egy olyan különleges sor (queue) amelybe a vagonok rendezett listája található és mind a két oldalról tudunk betárolni és kivenni elemeket.

$$O_w = \{W_1, W_2, \dots, W_n\} \quad (23)$$

Ahol,

W a vagon adatokat tartalmazó adatstruktúra,

n pedig a betárolt vagonok száma.

$$n \in \mathbb{N} \cup \{0\} \mid n \leq c \quad (24)$$

A vagonhoz kötődő adatok a következők

$$W = \{Id, o, p\} \quad (25)$$

Ahol,

Id a vagon azonosítója,

o vagon sorszáma,

p vágányon belüli abszolút pozíció.

A projektben a vagon azonosításra egy 12 bytes HEX azonosítót használtunk.

A tárolóvágány-hálózatot a következő adatstruktúrával tudjuk modellezni.

$$M = \{S_1, S_2, \dots, S_i\} \quad (26)$$

A tárolóvágány szabad kapacitását a következő képlet alapján számíthatjuk ki:

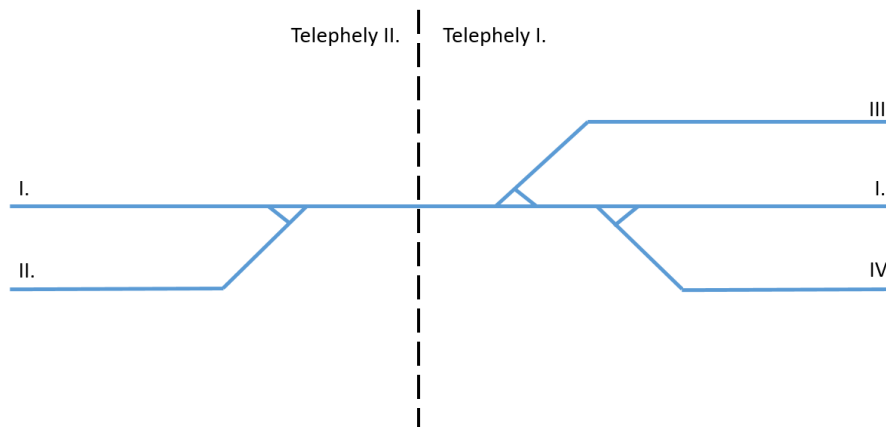
$$c_m = \sum_{k=1}^n c_k - c_{l_k} \quad (27)$$

Ahol,

c_m a tároló vágány hálózat kapacitása és az n a vágányok száma.

4.4.2 Környezet modell

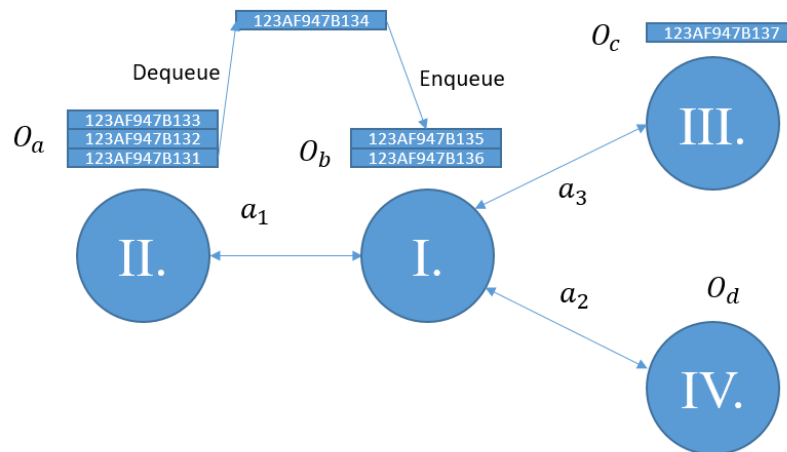
Ebben a fejezetben bemutatom a környezet gárf modellt, amely a tároló vágány hálózatot reprezentálja. A következő példán keresztül szeretném bemutatni a modellt. A következő képen egy vasúti térkép látható:



63. ábra - Tárolóvágány hálózat példa

A fenti ábrán a vágányokat a kék vonalak szemléltetik, a számok pedig a vágányok azonosítói.

A fenti példában feltüntetett térképen a mozgások kötöttek. Tételezzük fel, hogy a mozdony az I. vágányon áll az I. telephelyen és a II. telephely felé megy. A II. telephelyen az I-es és II-es vágányokra mehet tovább. Ezeket a mozgásokat szeretném a gráfmodellel követni. A vágányokon tárolt vagonokat és a vágányok közötti mozgásokat sorral (queue) műveletekkel lehet modellezni. A következő képen látható a fenti példában leírt vágányhálózat modellje.



64. ábra - Példa hálózat gráfmodellje

A gráfnak négy csúcsa van, amelyek a vágányokat szimbolizálják a fent 63. ábrán bemutatott példa alapján. A csúcsok közötti élek az egyes vágányok közötti átmeneteket, összeköttetéseket jelentik. A példában minden él két irányú, amely azt jelenti, hogy az I. vágányról a mozdony mehet a II-ra és fordítva is.

Az ábrán egy vagon átvitele egyik vágányról a másikra a következő módon történik. Az adott csúcsához tartozó vagonazonosítókat tartalmazó sorból ki kell szedni az utolsó elemet és átrakni egy másik, egy másik csúcsához tartozó sorba. Egy adott vagon csak akkor rakható át két csúcs között, ha van köztük él. A modelltől általánosan elmondható, hogy minden él kétirányú lesz.

A következő képlet szemlélteti a gráf adatstruktúráját.

$$G = \begin{cases} V = I., II., III., IV. \\ E = a_1, a_2, a_3 \\ c \end{cases} \quad (28)$$

Ahol,

V a csúcsok vektora,

E az élek vektora,

c a súlyfüggvény.

A csúcsokhoz a következő adatok tartoznak.

$$I. = \{Id, S\} \quad (29)$$

Ahol

I. Egy adott vágány,

Id A vágány azonosító,

S a tárolóvány adatállomány.

Egy adott él súlyfüggvénye a következő formulával számolható ki:

$$c(a, b) = \begin{cases} s_b * c_{lb} & , ha a menetirány a \rightarrow b \\ s_a * c_{la} & , ha a menetirány b \rightarrow a \end{cases} \quad (30)$$

Ahol,

a és *b* két csúcs,

s a sín hossza,

c_l a betárolt vagonok száma,

c(a, b) a gráf súlyfüggvénye.

Amikor a mozdony bármilyen rendezési folyamatot végez a tárolóvágány rendszerben, frissíteni kell minden súlyt ezzel a függvénnyel.

Létrehoztam egy adatmodellt a vágányok modellezésére, valamint egy környezet modellt. Az általam kidolgozott vágány modell előnye a már létező modellekkel [T11] szemben az, hogy nem tartalmaz redundáns adatokat, így kisebb számítási igényeket támaszt. Mivel a modell működéséhez kevesebb adat szükséges, akár beágyazott környezetben is futtatható (IoT alapú eszközökön is futtatható).

A környezet modell egy súlyozott gráf, így használhatjuk a legrövidebb út algoritmust a tolatási műveletek optimalizálására. Ez az algoritmus megadhatja a legrövidebb utat a mozdony számára egy nagy területen, ahol sok vágány található. Az élek súlya pozitív szám, így sok optimalizációs algoritmust alkalmazhatunk a gráfmodellen. A fejlesztés jövőbeli szakaszában több algoritmust is tesztelni terveztem, beleértve a Bellman-Ford algoritmust és a Dijkstra algoritmust.

4.5 Tézisek

4.5.1 Tézis IV.

Kidolgoztam egy eljárást vasúti szerelvényeken lévő vagonok sorrend meghatározására. [S13]

4.5.2 Tézis V.

Megalkottam egy helymeghatározó algoritmust, amellyel egymástól akár 5 méteres távolságra lévő egyenes vonalú egymással párhuzamosan futó vágányokon GPS koordináták alapján meghatározható a vasúti kocsi/mozdony tartózkodási helye.

4.5.3 Tézis VI.

Megalkottam egy adatmodellt a tárolóvágányok modellezésére, valamint egy gráf alapú környezet gráfmodellt, amellyel követni lehet a tároló vágányon történő vagon mozgásokat. [S10]

5 Összefoglalás

Az értekezésemben részletesen bemutattam a két tématerületen elért kutatási eredményeket, valamint fejlesztéseket. Úgy gondolom a kitűzött célokat sikerült elérni és a témakörök kidolgozása során rengeteg szakmai tapasztalatot szereztem.

Kidolgoztam a kiválasztott Plantower PMS7003 szállópor koncentráció mérő szenzor adatainak kalibrációjára használható eljárást. Több különböző módszert hasonlítottam össze és végül kiválasztottam azt, amelyik a validációs szempontjaim szerint a legjobb eredményeket produkálta. Mégépítettem és megterveztem egy mérőhálózatot, amely képes adatokat szolgáltatni a szállópor koncentráció spektrális megjelenítéséhez. Megvizsgáltam a mérőhálózatba beépített egységek környezetterhelését, ezáltal környezetbarát alapanyagokat fogunk tudni kiválasztani az akár több 100 egységből álló mérőhálózat kiépítése esetén. Úgy gondolom, hogy ez egy aktívan kutatott tématerület, amellyel a jövőben is szeretnék még foglalkozni. További terveim között szerepel, hogy a szenzor szezonális kalibrációjával lehet-e tovább javítani a rendszer pontosságát.

A vagon lokalizációs rendszer kapcsán sikerült kifejleszteni egy olyan vagon-sorrend meghatározási eljárást, amelyből megépült a prototípus is és sikeresen teszteltem a BorsodChem vasútüzeménél. A sorrend meghatározásból egy szabadalmi bejelentés beadásra került, amely átment az újdonság kutatáson és az egyetem fenntartja a szabadalmi jogot. Várható a megadás és a lajstromozás 2024-ben. Kidolgoztam továbbá egy egyenes vonalú vágányokon alkalmazható lokalizációs algoritmust, amely képes a meghatározni a mozdony helyzetét a GPS koordinátákból. Részletesen megfigyeltem a vasútüzem munkáját és működését, majd az itt szerzett tapasztalatok alapján megalkottam egy adatmodellt a tárolóvágányok modellezésére, valamint egy gráf alapú környezet gráfmodellt, amellyel követni lehet a tároló vágányon történő vagon mozgásokat. A modell alkalmas arra, hogy optimalizációs eljárásokat futtassunk rajta. A további terveim közé tartozik, hogy különböző optimalizálási eljárásokkal csökkentsem a tolatási műveleteket.

6 Summary

In my dissertation, I have detailed the research findings and developments achieved in the two thematic areas. I believe the set goals have been successfully achieved, and I have gained a great deal of professional experience while working on these topics.

I developed a procedure for calibrating the data from the selected Plantower PMS7003 particulate matter concentration sensor. I compared several different methods and ultimately selected the one that produced the best results according to my validation criteria. I also designed and constructed a measurement network capable of providing data for the spectral representation of particulate matter concentration. I examined the environmental impact of the units incorporated into the measurement network, which will allow us to select environmentally friendly materials for constructing a network of potentially hundreds of units. I believe this is an actively researched area that I would like to continue working on in the future. My further plans include investigating whether the seasonal calibration of the sensor can improve the system's accuracy.

Regarding the wagon localization system, I successfully developed a wagon sequence determination procedure, which resulted in a prototype that I successfully tested at BorsodChem's railway operation. A patent application has been filed for the sequence determination, which has passed the novelty search, and the university retains the patent rights. The grant and registration are expected in 2024. Additionally, I developed a localization algorithm applicable to straight railway tracks, capable of determining the locomotive's position from GPS coordinates. I thoroughly observed the railway operation and its functioning, and based on the experiences gained, I created a data model for modeling storage tracks and a graph-based environment graph model to track wagon movements on the storage tracks. The model is suitable for running optimization procedures on it. My further plans include reducing shunting operations through various optimization procedures.

Az értekezés témakörében készített saját publikációk

Folyóiratcikkek

- [S1] Kiss, M. L., Szita, K. T., Pintér, J. M., Kósa, B., & Veres, L. (2024). Lifecycle Analysis of an Air Quality Sensor. *Acta Polytechnica Hungarica*, 21(8), 67-85. DOI: 10.12700/APH.21.8.2024.8.4
- [S2] Márton, L. K., Mária, P. J., Levente, R., & Laura, V. (2023). Levegőminőség mérése és mért adatok alkalmazhatósága a városüzemeltetésben. *Multidiszciplináris Tudományok*, 13(1), 306-323. DOI: 10.35925/j.multi.2023.1.22
- [S3] Márton, L. K., Judit, P. M., & Laura, V. (2022). Légminőség hosszú távú mérése különböző szenzorokkal. *Multidiszciplináris Tudományok*, 12(2), 261-268. DOI: 10.35925/j.multi.2022.2.23
- [S4] Márton, L. K., & Mária, P. J. (2020). Érzelemfelismerő interfész koncepcionális tervezése okosotthon rendszerhez. *Multidiszciplináris Tudományok*, 10(4), 219-226. DOI: 10.35925/j.multi.2020.4.26
- [S5] Márton L. K.; Csongor B.; Attila T.;Árpád Bence P. (2018). Szállópor koncentráció mérő műszer páratartalom kalibrációja. *Villamosmérnöki Tudományok*, I.(2) 138-145.
- [S6] Márton L. K.; Attila T. (2018). Ipar 4.0 alapú vagon helymeghatározó rendszer fejlesztése. *Villamosmérnöki Tudományok*, I.(2) 128-137.
- [S7] M. L. Kiss A. Trohák (2018): IoT eszköz energiafelvételének becslése. *Villamosmérnöki Tudományok*, Vol. 1 (1), , pp. 163-166
- [S8] Márton L. K.; Judit Maria P., Balázs K., Balázs M., Laura V., Calibration on particle sensor with neural network algorithm. *Polac Periodica* (2024) **Elfogadva! megjelenés alatt!**

Konferenciaközlemények

- [S9] M. L. Kiss; A. Trohak; IoT eszköt energiafelvételének becslése; Számítástechnikai és Oktatási konferencia; Nagyvárad(2017)

- [S10] M. L. Kiss, J. M. Pintér, L. Veres and A. Trohák, Modeling of Storage Rail Environment. In 2021 22nd International Carpathian Control Conference (ICCC), (pp. 1-4). IEEE DOI: *10.1109/ICCC51557.2021.9454602*
- [S11] Kiss, M. L., Pintér, J. M., Trohák, A., & Veres, L. (2022, May). Long term measurement with PMS7003. In 2022 23rd International Carpathian Control Conference (ICCC) (pp. 343-347). IEEE. DOI: *10.1109/ICCC54292.2022.9805926*
- [S12] Márton L. K.; Csongor B.; Attila T.;Árpád Bence P. (2018). Szállópor koncentráció mérő szenzorok összehasonlító elemzése. Számítástechnikai Oktatási konferencia; Tusnádfürdő(2018)

Szabadalom

- [S13] L Kiss Márton, Trohák Attila: Vagonsorrend meghatározó berendezés, ügyszám: P2100222 [<http://epub.hpo.hu/e-kutatas/?lang=HU>]

Tudományos irodalomjegyzék

- [T1] Hojaiji, H., Kalantarian, H., Bui, A. A., King, C. E., & Sarrafzadeh, M. (2017, March). Temperature and humidity calibration of a low-cost wireless dust sensor for real-time monitoring. In *2017 IEEE sensors applications symposium (SAS)* (pp. 1-6). IEEE.
- [T2] Caya, M. V. C., Babila, A. P., Bais, A. M. M., Im, S. J. V., & Maramba, R. (2017, December). Air pollution and particulate matter detector using raspberry Pi with IoT based notification. In *2017 IEEE 9th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM)* (pp. 1-4). IEEE.
- [T3] Liu, D., Zhang, Q., Jiang, J., & Chen, D. R. (2017). Performance calibration of low-cost and portable particulate matter (PM) sensors. *Journal of Aerosol Science*, *112*, 1-10.
- [T4] Betancourt, R. M., Galvis, B., Balachandran, S., Ramos-Bonilla, J. P., Sarmiento, O. L., Gallo-Murcia, S. M., & Contreras, Y. (2017). Exposure to fine particulate, black carbon, and particle number concentration in transportation microenvironments. *Atmospheric environment*, *157*, 135-145.
- [T5] István, F. (2013). Neurális hálózatok.
- [T6] Péter, V. (2023). Mesterséges Intelligencia kiválasztása és felhasználási lehetőségei a logisztika területén. *Multidiszciplináris Tudományok*, *13*(1), 32-41.
- [T7] Tóth L., Grósz T. (2017): Mesterséges Neuronhálók és alkalmazásaik. Szegedi Tudományegyetem, Szeged
- [T8] Di Antonio, A., Popoola, O. A., Ouyang, B., Saffell, J., & Jones, R. L. (2018). Developing a relative humidity correction for low-cost sensors measuring ambient particulate matter. *Sensors*, *18*(9), 2790.
- [T9] Siebler, B., Heirich, O., & Sand, S. (2018, April). Relative train localization with magnetic field measurements. In *2018 IEEE/ION Position, Location and Navigation Symposium (PLANS)* (pp. 1228-1233). IEEE.
- [T10] Heirich, O., Lehner, A., Robertson, P., & Strang, T. (2011, October). Measurement and analysis of train motion and railway track characteristics with

- inertial sensors. In *2011 14th international IEEE conference on intelligent transportation systems (ITSC)* (pp. 1995-2000). IEEE.
- [T11] Heirich, O., Robertson, P., & Strang, T. (2013, May). RailSLAM-Localization of rail vehicles and mapping of geometric railway tracks. In *2013 IEEE International Conference on Robotics and Automation* (pp. 5212-5219). IEEE.
- [T12] Heirich, O., Robertson, P., Garcia, A. C., & Strang, T. (2012, July). Bayesian train localization method extended by 3D geometric railway track observations from inertial sensors. In *2012 15th International Conference on Information Fusion* (pp. 416-423). IEEE.
- [T13] Heirich, O., Robertson, P., García, A. C., Strang, T., & Lehner, A. (2012, June). Probabilistic localization method for trains. In *2012 IEEE Intelligent Vehicles Symposium* (pp. 482-487). IEEE.
- [T14] Lu, D., & Schnieder, E. (2014). Performance evaluation of GNSS for train localization. *IEEE transactions on intelligent transportation systems*, *16*(2), 1054-1059.
- [T15] Liu, D., Jiang, W., Cai, B., Heirich, O., Wang, J., & Shanguan, W. (2023). Robust train localisation method based on advanced map matching measurement-augmented tightly-coupled GNSS/INS with error-state UKF. *The Journal of Navigation*, *76*(2-3), 316-339.
- [T16] Berlin, E., & Van Laerhoven, K. (2013, May). Sensor networks for railway monitoring: Detecting trains from their distributed vibration footprints. In *2013 IEEE International Conference on Distributed Computing in Sensor Systems* (pp. 80-87). IEEE.
- [T17] Allotta, B., D'Adamio, P., Faralli, D., Papini, S., & Pugi, L. (2015, May). An innovative method of train integrity monitoring through wireless sensor network. In *2015 IEEE International Instrumentation and Measurement Technology Conference (I2MTC) Proceedings* (pp. 278-283). IEEE.
- [T18] Haifeng, Z., Xiaowei, L., Jialu, T., & Ang, L. (2011, October). An implementation of wireless sensor network for detection of runaway trains. In *2011 Academic International Symposium on Optoelectronics and Microelectronics Technology* (pp. 287-291). IEEE.

- [T19] Siebler, B., Heirich, O., & Sand, S. (2018, April). Relative train localization with magnetic field measurements. In *2018 IEEE/ION Position, Location and Navigation Symposium (PLANS)* (pp. 1228-1233). IEEE.
- [T20] Karush, W. (1957). A queuing model for an inventory problem. *Operations research*, 5(5), 693-703.
- [T21] Rosendo, M., & Granjal, J. (2022). Energy-aware security adaptation for low-power iot applications. *Network*, 2(1), 36-52.
- [T22] Basford, P. J., Bulot, F. M., Apetroaie-Cristea, M., Cox, S. J., & Ossont, S. J. (2020). LoRaWAN for smart city IoT deployments: A long term evaluation. *Sensors*, 20(3), 648.
- [T23] Lu, C. Y., Chen, F. H., Hsu, W. C., Yang, Y. Q., & Su, T. J. (2020). Constructing Home Monitoring System with Node-RED. *Sensors & Materials*, 32.
- [T24] Bonvoisin, J., Lelah, A., Mathieux, F., & Brissaud, D. (2012). An environmental assessment method for wireless sensor networks. *Journal of Cleaner Production*, 33, 145-154.
- [T25] Andrae, A. S., & Andersen, O. (2010). Life cycle assessments of consumer electronics—are they consistent?. *The International Journal of Life Cycle Assessment*, 15, 827-836.
- [T26] Loerincik, Y. (2006). *Environmental impacts and benefits of information and communication technology infrastructure and services, using process and input-output life cycle assessment* (No. 3540). EPFL.
- [T27] Son, N. N., & Vinh, Luu The. (2022). Parameter estimation of photovoltaic model, using balancing composite motion optimization. *Acta Polytechnica Hungarica*, 19(11), 27-46.
- [T28] Badura, M., Batog, P., Drzeniecka-Osiadacz, A., & Modzel, P. (2018). Evaluation of low-cost sensors for ambient PM2.5 monitoring. *Journal of Sensors*, 2018(1), 5096540.
- [T29] Jozsef T., Márton L. K. (2018). Vagon meghatározó rendszer hardverének fejlesztése. *Villamosmérnöki Tudományok*, I.(2) 161-165.

- [T30] Badura, M., Batog, P., Drzeniecka-Osiadacz, A., & Modzel, P. (2019). Regression methods in the calibration of low-cost sensors for ambient particulate matter measurements. *SN Applied Sciences*, 1(6), 622.
- [T31] Macías-Hernández, B. A., Tello-Leal, E., Barrios, O., Leiva-Guzmán, M. A., & Toro, R. (2023). Effect of environmental conditions on the performance of a low-cost atmospheric particulate matter sensor. *Urban Climate*, 52, 101753.
- [T32] Aix, M. L., Schmitz, S., & Bicout, D. J. (2023). Calibration methodology of low-cost sensors for high-quality monitoring of fine particulate matter. *Science of The Total Environment*, 889, 164063.

Egyéb hivatkozások

- [1] Levegőminőség-index skála és színmagyarázat [<https://aqicn.org/scale/hu/>]
- [2] PMS7003 szenzor gyártói weboldal
[https://plantower.com/en/products_33/76.html]
- [3] Miskolc Hejőcsaba 2017 január 26. [<https://cdn.cms.mtv.hu/wp-content/uploads/sites/7/2017/02/Varga-Attila-Miskolc-1024x682.jpg>]
- [4] Air Quality Monitoring [<https://ge3s.org/aqm>]
- [5] ISO 14040/14044 (2006): Environmental management — Life cycle assessment — Principles and framework / Requirements and guidelines