

ÓBUDAI EGYETEM
OBUDA UNIVERSITY

PhD értekezés

Nagy mennyiségű multidimenzionális adatok feldolgozása feladatorientált speciális módszerekkel

Domozi Zsolt

Témavezető: Prof. Dr. Molnár András

Alkalmazott Informatikai és Alkalmazott Matematikai Doktori Iskola
Óbudai Egyetem

Budapest, 2025.

NYILATKOZAT A MUNKA ÖNÁLLÓSÁGÁRÓL, IRODALMI FORRÁSOK MEGFELELŐ MÓDON TÖRTÉNT IDÉZÉSÉRŐL

Nyilatkozat

Alulírott Domozi Zsolt kijelentem, hogy ez a doktori értekezés a saját munkámat mutatja be, és a saját eredeti kutatásom eredménye. Csak a hivatkozásokban felsorolt forrásokat használtam fel, minden más munkából származó rész, a szó szerinti, vagy az eredeti jelentést megtartó átiratok egyértelműen jelölve, és forráshivatkozva lettek.

Declaration

I, the undersigned, Zsolt Domozi, hereby state and declare that this Ph.D. thesis represents my own work and is the result of my own original research. I only used the sources listed in the references. All parts taken from other works, either as word-for-word citation or rewritten while retaining the original meaning, have been unambiguously marked, and reference to the source was included.

Domozi Zsolt

Tartalomjegyzék

Ábrák jegyzéke	iv
Táblázatok jegyzéke	viii
Algoritmusok jegyzéke	ix
1. Bevezetés	1
1.1. Célkitűzések	3
1.2. A kutatás tudományos módszerei	4
1.3. Disszertáció rövid összefoglalója	5
2. Multidimenziós adatok és fúziójuk	6
2.1. Képfeldolgozási lehetőségek: objektumok keresése, azonosítása	7
2.2. Képfeldolgozási lehetőségek: minőségi jellemzők javítása, többletinformáció bemutatása	10
2.3. Sugárzási és légszennyezettségi eredmények feldolgozása	12
3. Objektumok keresése adatfúziós módszerekkel	13
3.1. Neurális hálózatok	14
3.1.1. Aktivációs függvények	17
3.1.2. Aktivációs függvények kategorizálása	17
3.2. Neurális hálózatok és problémáik	21
3.3. Medencék detektálásának fontossága és lehetséges módszerei	25
3.4. Medencék jellemzői légifotók alapján	27
3.5. Konvolúciós neurális hálózat tanítása és eredménye	29

3.6.	Klasszikus képelemzési módszerek	31
3.6.1.	Hue Saturation and Value színtartomány	32
3.6.2.	Fuzzy következtetési rendszer	37
3.6.3.	Szegmentáció Fuzzy következtetési rendszer segítségével	40
3.7.	Fuzionálás, utófeldolgozás több lépésben	48
3.8.	Fuzionálás, utófeldolgozás háromváltozós többségi függvénnyel	50
3.9.	Eredmények	52
4.	Hőkamera és színes kamera adatainak fúziója	54
4.1.	Hőkamerák jellemzői és felhasználásuk	57
4.2.	Fotogrammetria alapú 3D rekonstrukció hősínezéssel	59
4.3.	Fotogrammetria segítségével 3D hőmodell létrehozása	61
4.4.	3D hőmodell élkiemelése	65
4.5.	Eredmények	67
5.	3D pozíciókban mért 5D légszennyezettségi adatok feldolgozása	71
5.1.	A mérő egység felépítése	76
5.2.	Mért adatok kiegészítése	77
5.3.	Szennyezési térkép	81
5.4.	Eredmények	83
6.	Kültéri gamma-dóziseloszlás mérése multikopterrel	85
6.1.	Mérési adatok feldolgozása, megjelenítése	87
6.1.1.	Megállás nélküli, pásztázó mérési eljárás	91
6.1.2.	Diszkrét pontokban történő mérési eljárás	92
6.1.3.	Részeredmények	93
6.2.	Sugárforrás lokalizálása modell alapú megközelítéssel	94
6.3.	A kísérletekhez használt eszközök	97
6.4.	Mérési eredmények	99
6.4.1.	A mérések kivitelezése	100
6.5.	Eredmények	105

7. Tézisek	107
8. Szemléleti összefoglaló	110
Irodalomjegyzék	113

Ábrák jegyzéke

1.1. Adatok feldolgozásának folyamata, amivel információt állíthatok elő	2
3.1. Konvolúciós neurális hálózat (Convolutional Neural Network (CNN) felépülésének sematikus rajza	15
3.2. Konvolúciós neurális hálózat konvolúciós rétegének paraméterszám-csökkentése MaxPooling és AveragePooling technikákkal	16
3.3. Bináris (más néven léptető) aktivációs függvény	18
3.4. Lineáris aktivációs függvény	18
3.5. Sigmoid aktivációs függvény	19
3.6. Hiperbolikus tangens függvény	20
3.7. ReLu aktivációs függvény	20
3.8. Légifotó, melyen a medencéket kell detektálni, különböző formai és színjellemzőik mellett	28
3.9. Konvolúciós neurális hálózat segítségével detektált medencék false-positive és false-negative eredményekkel	29
3.10. Konvolúciós Neurális hálózat hibás detektálása: piros téglalap a false- positive eredményt, míg a kék téglalap false-negative eredményt jelöli . . .	30
3.11. HSV színtartomány reprezentációja, amennyiben $S_{hsv} = 1$	32
3.12. Azon HSV tartomány, melyben a keresett objektum színe megtalálható. .	33
3.13. HSV színtartomány alapú medencekeresés eredményeként előállt bináris detektálási maszk, ahol a kék színnek megfelelő pixelek fehérrel jelöltek . .	35
3.14. HSV színtartomány alapú medencekeresés eredményeként előállt bináris detektálási maszk eredménye median filterrel szűrve	36

3.15. RGB színskála szerinti kép egyes színcsatornáinak hisztogramja	41
3.16. RGB színskála szerinti kép színcsatornánként definiált tagsági függvényei - (a) piros színcsatorna tagsági függvénye; (b) zöld színcsatorna tagsági függvénye; (c) kék színcsatorna tagsági függvénye	44
3.17. Minden definiált tagsági függvény Matlab Fuzzy Toolbox rendszerben - (a) piros színcsatorna tagsági függvénye; (b) zöld színcsatorna tagsági függvénye; (c) kék színcsatorna tagsági függvénye	45
3.18. RGB színskála szerinti képen, Fuzzy következtetési rendszer kimeneti függvénye annak eldöntésére, hogy az adott pixel medence lehet vagy sem .	46
3.19. Fuzzy következtetési rendszer irányítási területének reprezentációja a tagsági függvények és a színcsatornák összefüggései tekintetében - (a) piros-kék színcsatornákra vonatkoztatva; (b) piros-zöld színcsatornákra vonatkoztatva; (c) zöld-kék színcsatornákra vonatkoztatva	46
3.20. RGB színskála szerinti képen, Fuzzy következtetési rendszer kimeneti függvénye alapján létrehozott bináris maszk az objektum detektálására . .	47
3.21. Alsó réteg: eredeti légifotó, Második réteg: HSV és Fuzzy detektálások fúziója, Harmadik réteg: CNN által detektált medencék, Negyedik réteg: Sikeresen detektált medencék elhelyezkedése	50
3.22. A létrehozott komplex rendszer folyamatábrája	51
4.1. Színes RGB kép 9x8 pixeles felbontásban - (a) ahogyan láthatjuk; (b) ahogyan felépül elemi szinten pixelekből	61
4.2. Színes RGB kép 9x8pixeles felbontásban - (a) ahogyan felépül elemi szinten pixelekből; (b) ahogyan az egyes elemi részek (pixelek) reprezentálhatóak adatszerkezeti szinten: R+G+B csatornák	61
4.3. Színes és hőkép valamint feldolgozás során jelentkező szinkronitási hiba . .	65
4.4. Bemenetek és kimenet tagsági függvénye	66
4.5. Fuzzy alapú éldetektálással előállított, kontúrozott hőkép	67
4.6. Szürkeárnyaltos (bal oldalon) és 3D hőkép (jobb oldalon) rekonstrukciója a vizsgált családi háznak	68

4.7. Faház 3D hőkép rekonstrukciója és élkemelt változata a modellnek	69
5.1. CO koncentrációs értékek városi közlekedés során - (a) városi útvonal térképre helyezve és a mért értékeknek megfelelő magasságú 3D vonaldiagram; (b) mért értékek GPS pozíciókhoz rendelve	72
5.2. CO koncentrációs értékek a teszt teljes ideje alatt, idősoros diagramon ábrázolva	74
5.3. CO koncentrációs értékek a teszt teljes ideje alatt, idősoros diagramon ábrázolva	75
5.4. Idősoros szennyezési térkép - (a) első felmérés; (b) második felmérés; (c) harmadik felmérés	82
5.5. A CO kibocsátás átlagértékei. Szennyezési forrás nyíllal jelölt	83
6.1. Terület felosztása cellákra	88
6.2. Mérési nyomvonal, ahol a pontok a mért koordináták, a színes részletek pedig azok a mérési pontok ahol a mért sugárzás szignifikánsan nagyobb a többi mérési ponton mért értéknél	89
6.3. $1m \times 1m$ -es és $4m \times 4m$ cellákra felosztott területekhez rendelt gamma-sugárzási értékek ábrázolása	90
6.4. Egy folyamatos mérés eredménye - (a) mérést végző eszköz; (b) a repülés nyomvonala; (c) a feldolgozást követő szignifikáns sugárforrás helye; (d) a területről készült ortofotóra vetített sugárforrás	91
6.5. Diszkrét mérési pontokkal történő mérés - (a) repülési nyomvonal illesztése látható a mérési terület felett; (b) a feldolgozott detektor adatok alapján létrehozott dóziseloszlás kép; (c) a mérési terület ortofotójára vetített dóziseloszlás kép a kimért sugárforrással	92
6.6. A matematikai modell gondolatának sematikus ábrája. A szondával mért intenzitás fordítottan arányos az ismeretlen forrásponttól való távolsággal, így a megfigyelt és a modellezett intenzitásmérések közötti különbség minimalizálásával meghatározható a forráspont koordinátái.	97

6.7.	A drónokra szerelt terepi dóziseloszlás-mérést szolgáló kísérleti eszközök - (a) Inspire I egy GM-csőves detektorral (b) Inspire I négy GM-csőves detektorral; (c) Mavic Pro egy kisméretű szcintillációs detektorral; (d) Inspire I szcintillációs detektorral, amely gyors spektrumelemzésre alkalmas	98
6.8.	A tesztterületen, folyamatos pásztázó repüléssel végzett GM csöves mérés natív adatainak kiértékelése	100
6.9.	A tesztterületen, folyamatos pásztázó repüléssel végzett szcintillációs detek- toros mérés natív adatainak kiértékelése	101
6.10.	A tesztterületen, folyamatos pásztázó repüléssel végzett szcintillációs detek- toros mérés kiugró zajoktól megtisztított adatainak kiértékelése	102
6.11.	Statikus mérés a vizsgált minta speciális spektrumának meghatározásához	103
6.12.	A tesztterületen, folyamatos pásztázó repüléssel végzett szcintillációs detek- toros mérés energia-szelektív natív adatainak kiértékelése	104

Táblázatok jegyzéke

1.1. Adattípus kategóriák és lehetséges elemeik	1
3.1. Neurális hálózatok - Osztályozási eredmények kategóriái	24
3.2. RGB színtartomány által definiált lehetséges "kék" színek	37
3.3. Háromváltozós többségi Boole-függvény igazságtáblája	51

Algoritmusok jegyzéke

1.	CNN alapú képklasszifikáció MATLAB-ban	31
2.	Klasszikus számítási mód arra, hogy az adott pixel kék színű vagy sem . .	37
3.	Optimalizált Fuzzy Logika alapú detektálási maszk előállítása	48
4.	Színes kép és hőkép egybevágósági feltételeinek létrehozása	62
5.	Színes kép és hőkép fúziójának algoritmus	63

1. fejezet

Bevezetés


A valós világ objektumai reprezentálhatók virtuális térben. Reprezentációjuk jellemzően nagy mennyiségű adattal valósítható meg, amelyek további feldolgozásra is alkalmassá teszi azokat. Az adat a valós világ valamely szempont szerinti nyers tényeinek összessége. A tény lehet szám, szó, mérési eredmény, megfigyelés, esetleg szabad leírata a valóságnak. Az adat típusa szerint több kategóriába sorolható, melyeket az alábbi, 1. táblázat foglal össze.

1.1. táblázat. Adattípus kategóriák és lehetséges elemeik	
Adat	Lehetséges elemek
Alfanumerikus	számok, betűk, egyéb karakterek
Képi	grafikai elemek, fotók
Audió	hangok, zörejek
Videó	mozgó grafikai elemek, fotók összessége

A fenti adat-típusok mindegyike visszavezethető az alfanumerikus kategóriában látható alapelemekre, így egy kép, video vagy hanganyag vizsgálata során végeredményül számokat kaphatunk. Általánosan elmondható, hogy a nyers adatnak jelentéstartalma alacsony, mindaddig, amíg el nem kezdjük rendszerezni, az adathalmazt vizsgálni. Valamilyen előre meghatározott szempont szerint feldolgozott adatból már információk nyerhetők ki. Az információ valamely szemléleti mód, vizsgálati cél szerint összegzett, csoportosított vagy redukált nyers adatok halmaza, amely a vizsgáló számára már további adatot is hordoz a nyers adathalmazzal szemben. Azt a folyamatot, ahol a nyers adatból információt állítunk elő, adatfeldolgozásnak nevezzük. Az adatfeldolgozás lehet teljesen automatikus, fél-

automatikus és lehet manuális folyamat is, de mindenképpen a nyers adat csoportosítását, rendezését, módosítását, tárolását és ezáltal többlet információ kinyerését értjük alatta. Az adatfeldolgozás három fő fázisra osztható:

1. Bemeneti adatok meghatározása, megszerzése: a valós világ modellezése olyan módon, hogy számítógép számára is érthető adathalmaz jöjjön létre. Az adatfeldolgozás legfontosabb lépése, mivel a bemeneti adatok közvetetten hatással vannak a kimeneti adatokra.
2. Feldolgozás: adatok bizonyos szempontok szerinti feldolgozása, aminek köszönhetően információ áll elő.
3. Kimeneti adatok generálása: a felhasználó számára érthető információ előállítása.
4. Tárolás: a kinyert információk tárolása későbbi, további felhasználásra (pl.: idősoros adatok stb.).



1.1. ábra. Adatok feldolgozásának folyamata, amivel információt állíthatok elő

A feldolgozás során használt eljárások több kategóriába sorolhatók:

1. Osztályozó (classification): amikor az adat különböző osztályokba kerülnek valamilyen jellemzőjük alapján és így minden nyersadat megfelelően kezelhetővé válik.

2. Rendszerező (storing): adatok rendezésével foglalkozó eljárások összessége, mely után a nyers adathalmaz gyorsabban, hatékonyabban dolgozható fel.
3. Számító (calculation): eljárások, melyek a nyers adatokon valamilyen számítást végeznek és esetleg további, származtatott adatot állítanak elő.

Bár nem kapcsolódik szorosan az adatfeldolgozáshoz, de fontos lépés a kinyert információk tárolása is. Az információ tárolásával lehetővé válik, hogy a valós világ újabb reprezentációját adatfeldolgozás után összehasonlítsuk a korábbi felméréssel. Ha az időbeni változást később más szempontok szerint szeretnénk vizsgálni, mint ahogyan eredetileg terveztük, akkor a nyers adatokat érdemes tárolni és a feldolgozó eljárásainkat párhuzamosan futtatni a nagy mennyiségű adatokon.

A párhuzamos feldolgozás jelen esetben nem csak az időben párhuzamos jelentéssel bír, hanem a feldolgozási eljárás azonosságát tekintve is lehet párhuzamos, azaz a különböző időben vagy különböző módszerekkel keletkezett, egyazon objektumot reprezentáló nagy mennyiségű adatot egy vagy több előre meghatározott eljárással dolgozzuk fel. A nyers adat mennyisége sokszorozódik, az alábbiak szerint:

1. Az objektum reprezentálása bemeneti adatokkal egyazon vizsgálati módszer szerint, de időben eltérő pontokban: a megszerzett és feldolgozandó adat az időpontok számával multiplikálódik.
2. Az objektum reprezentálása különböző vizsgálati módszerekkel, de azonos időpontban: a vizsgálati módszerek számával multiplikálódik a feldolgozandó adat.
3. Különböző időpontokban többféle vizsgálati módszerrel reprezentált objektum adatmennyisége az időpontok számosságával és a különböző vizsgálati módszerek számával multiplikálódik.

1.1. Célkitűzések

Kutatási céljaim:

- Olyan képelemzési és képfeldolgozási módszer kialakítása, amely képes a mélytanuló hálózatok és a klasszikus képfeldolgozási módszerek hibáinak felismerésére, javítására, ezzel pedig végül megbízhatóbb eredményeket szolgáltatathat az objektumok azonosításában.
- Olyan 3D objektum építési módszer kidolgozása, mely képes az alacsony felbontású hőképekből nagy felbontású modellt létrehozni, a valós objektum felismerhetőségének rontása nélkül / Olyan 3D objektum építési módszer kidolgozása, mely képes az alacsony felbontású hőképekből, további vizsgálatra, feldolgozásra alkalmas nagy felbontású modellt létrehozni.
- Olyan módszer kialakítása, amely képes nagy mennyiségű, 3D pozíciókhoz rendelt 5D adatok feldolgozására, vizualizációjára, továbbá képes idősoros módon a változásokat kalkulálni, megjeleníteni.
- Olyan módszer kidolgozása, mely az emberi élet veszélyeztetése és a rendelkezésre álló eszközök súlyos degradációja nélkül képes sugárforrást detektálni, kiterjedt területet elemezni és pontos lokációs adatokat adni.

1.2. A kutatás tudományos módszerei

Kutatási módszereim választásakor elsődleges szempontom a céljaimhoz való illeszkedés volt. Az irodalomkutatás mellett kerestem publikus rendszereket is, amelyek hasonló működési elveket fogalmaztak meg önmaguknak és ezen rendszereket elemeztem is.

Részeredményeimet folyamatosan publikáltam nemzetközi és hazai konferenciákon, tudományos folyóiratokban és az itt kapott visszajelzések alapján módszereimet tovább pontosítottam.

A képelemzési és képfeldolgozási feladatokat manapság olyan mélytanuló hálózatok segítségével végzik el, melyek komplex matematikai modellek alapján működnek, jellemzően célfeladatra tervezik és hozzák őket létre, valamint a rendszerben bármely elem módosulása esetén ezen modelleket újra kell ellenőrizni. A klasszikus képelemzési módszerek

matematikai megközelítése egyszerűbb, gyorsabban módosítható egy új feladat, peremfeltétel érkezése esetén.

A 3D objektumok felépítéséhez jellemzően nagy felbontású képeket használnak és célszoftvereket, melyek az átfedő képek segítségével képesek felépíteni a valós tér objektumát. Hőképek készítésére alkalmas eszközök széles tárháza elérhető már, azonban mindegyiknek alacsony a felbontása, valamint az elkészült hőképek kevés egyedi, összekapcsolható jellemzőt tartalmaznak. Az alacsony felbontású, objektumrészleteket nem tartalmazó hőképeken átfedési pontok keresése szinte lehetetlen (természetesen vannak speciális esetek, amikor ez mégis elképzelhető), további feldolgozásra, vizsgálatra alkalmas 3D hőmodell előállítása nem lehetséges. Az általam kidolgozott módszer segítségével lehetőség nyílik a célkitűzés szerinti 3D hőmodell megépítésére.

A nagy mennyiségű 5D adat elemzésére a legtöbb rendszer nem képes. Általában valamilyen egyszerűsítést használnak, mellyel a komplexitást csökkentik, ezzel viszont a további vizsgálatok lehetőségét is csökkentik.

1.3. Disszertáció rövid összefoglalója

A valós világból megszerezhető adatok feldolgozás nélkül csak adatok maradnak. Az adat feldolgozása során juthatunk információhoz. A klasszikus adatfeldolgozási módszerek általában egyetlen adatsort dolgoztak fel, nem biztosítottak lehetőséget az adatok kombinálására, fúziójára. Egy valós objektum vizsgálata során lehetőségünk van több adatsor rögzítésére vagy párhuzamosan több adattípus rögzítésére több szenzor használatával. Az így előálló adathalmaz megfelelő kombinációjával többlet információhoz jutunk. A disszertációban olyan újszerű megközelítésekkel foglalkozok, amelyek adatok fúziójával, multidimenziós adatok kezelésével a valós világról képes részletesebb vagy jobb minőségű információ előállítására. A többlet információ kinyerésére elméleti megközelítés után gyakorlati példákat is mutatok. Algoritmusok bemutatása során Matlab programcsomag függvény tárait használtam, a pseudokód bonyolultabb része ezekre hivatkozhatnak.

2. fejezet

Multidimenziós adatok és fúziójuk

A valós világ objektumairól számtalan módon szerezhethetünk gépi feldolgozásra alkalmas adatot. Egy létező objektumról klasszikus módon készíthetünk videót, fényképet, esetleg készíthetünk fényképsorozatot meghatározott időközönként, mérhetjük fizikai tulajdonságait (magasság, szélesség, mélység, egyéb geometriai információk), speciálisabb esetekben mérhetjük az objektum hőmérsékletét, állagát (szilárd, folyékony, gáz), környezetre gyakorolt hatásait (sugárzás, egyéb szennyezési faktorok).

Látható, hogy az objektumok modellezése már nem feltétlenül a virtuális reprezentációról kell szóljon, hiszen számtalan fontos információval is kiegészíthető egy korábbi egyféle reprezentáció, így például a fizikai megjelenés is felvértethető további adattípusok reprezentációjával. Az egyes módszerekkel gyűjtött adatok feldolgozására évtizedes tapasztalat gyűlt össze a maguk tudományterületén, hiszen mindenki használhatott már videó, kép megjelenítésére alkalmas célszoftvert, sokan munkájuk során használnak dimenzionális adatokat egy objektum reprezentációjára (mérnöki szoftverek), drága hőkamerák használatával egy felületről megállapítható annak hőmérséklete, folyamatos bejövő adat elemzésével és célszenzor alkalmazásával légi, sugárzási jellemzők is feldolgozhatók.

Azonban a fenti célszoftverek korláatosnak tekinthetők abban a tekintetben, hogy csak egy aspektusból vizsgálják a valós objektumot. A különböző adatok összekapcsolására, fúziójára nem láttunk még megoldásokat.

A többdimenziós adatok, más néven többváltozós adatok, olyan adatokra utalnak, amelyeknek a megszokotthoz képest több attribútuma vagy változója van.

A többdimenziós adatok különböző formákban, például mátrixokban, tömbökben vagy táblázatokban ábrázolhatók (RGB kép, hőkép, videó képkockái is kétdimenziós tömbökként értelmezhetőek). A többdimenziós adatok megjelenítésének egyik leggyakoribb módja a többdimenziós tömb, más néven hiperkocka. A hiperkocka egy kétdimenziós táblázat többdimenziós kiterjesztése, ahol minden dimenzió más attribútumot vagy változót jelöl, további információkat tartalmaz az elsődleges tábla adataihoz kapcsolhatóan.

A többdimenziós adatok elemzése az adatok összetettsége és nagy dimenziója miatt kihívást jelenthet és jellemzően célirányos megoldásokkal végezhető el. A célirányos megoldás mindig egy vagy néhány típusú kérdésre keresi a választ és ezzel felfedhető az adatok rejtett mintái és összefüggései. Az olyan technikák, mint az adatbányászat, a gépi tanulás és a statisztikai elemzés, felhasználhatók a többdimenziós adatokból való információk kinyerésére.

A disszertáció fő témaköre a megszerezhető adatok újszerű összekapcsolása, ami az egyes területek eredményeit kiegészíti, az egyes területek megállapításait erősíti vagy gyengítheti, de mindenképpen a cél a valóság pontosabb vagy megbízhatóbb reprezentációja és ezzel többlet információhoz jutás.

2.1. Képfeldolgozási lehetőségek: objektumok keresése, azonosítása

Objektumok felismerésével különálló tudományterületek foglalkoznak. A klasszikus képfeldolgozás a digitális képek manipulálására és elemzésére használt technikák összességét jelenti. Ezek a technikák matematikai és statisztikai módszereken alapulnak, és egy kép vizuális megjelenésének javítására, információk kinyerésére, vagy a kép további elemzésre való előkészítésére szolgálnak. A klasszikus képfeldolgozás egyik fő lépése a képjavítás, amelyet a kép vizuális megjelenésének javítására használnak. A képjavításhoz általában olyan technikákat használnak, mint a hisztogram kiegyenlítés és a kontraszt nyújtás. Ezeket a technikákat a kép pixeleinek intenzitási szintjének beállítására használják, hogy a kép tisztább és részletesebb legyen. A klasszikus képfeldolgozás másik fontos lépése a

kép-visszaállítás, amely a zaj és az egyéb minőség rontó jellemzők eltávolítására szolgál. A kép-visszaállításhoz általában olyan technikákat használnak, mint a mediánszűrés és a Wiener-szűrés. Ezen eljárások célja az, hogy a kép tisztábbnak és pontosabbnak tűnjön. A képszegmentálás a klasszikus képfeldolgozás egyik fontos lépése. Ez a lépés egy kép több szegmensre vagy régióra való felosztására szolgál, amelyek mindegyike a kép egy-egy objektumának vagy jellemzőjének felel meg. A képszegmentáláshoz általában olyan technikákat használnak, mint a küszöbérték és a régiónövelés. A klasszikus módszer szerint valamilyen képi adat elemzésével lehetséges objektumot azonosítani. A képi adat lehet egy pixel vagy pixelcsoport jellemző színe, hozzávetőleges geometriai formája, elhelyezkedése más, azonosítható objektumokhoz képest. Számos megközelítés létezik a fényképen lévő objektumok képfeldolgozással történő felismerésére. A leggyakoribb módszerek közé tartozik:

1. Tulajdonság alapú objektum azonosítás: magában foglalja a jellemzők, például élek, sarkok vagy textúrák kinyerését a képből, és összehasonlítja azokat egy ismert objektumok adatbázisával. A képen lévő objektumot ezután úgy azonosítja a rendszer, hogy megtalálja a legjobb egyezést a kinyert jellemzők és az adatbázisban lévő ismert objektumok jellemzői között.
2. Sablonillesztés: magában foglalja a felismerendő objektum sablonjának létrehozását, majd a sablon összehasonlítását a kép különböző részeivel. Az objektumot akkor ismeri fel a rendszer, ha magas korreláció található a sablon és a kép része között.
3. Gépi tanuláson alapuló objektumfelismerés: magában foglalja a gépi tanulási modell betanítását címkézett képek adathalmazán, ahol minden kép a benne lévő objektummal van felcímkézve. A modell betanítása után új képek osztályozására használható a képen lévő objektum felismerésével.
4. Mély tanuláson alapuló objektumfelismerés: Ez a megközelítés a gépi tanuláson alapuló objektumfelismerés kiterjesztése, ahol mély neurális hálózatot használnak a képek osztályozására. A mély neurális hálózatot a címkézett képek nagy adathalmazán tanítják, és képes felismerni az objektumokat az új képeken azáltal, hogy

megtanulja azonosítani az egyes objektumokra jellemző egyedi mintákat.

Az elmúlt időszakban új eredményeket mutatott fel képfeldolgozási területen a neurális hálózat alapú megközelítés. Ezesetben egy előre tréningelt hálózat a bemenetként kapott képről (jellemzően kisméretű képszelet) megállapíthatja, hogy a tréningmintákhoz hasonlót “lát” vagy sem és ennek megfelelően ad egy kimeneti értéket, általában valószínűségi értékkel együtt. A neurális hálózat alapú objektumazonosítás ígéretes, de nagyon sok problémával küzd, így külön kutatási terület foglalkozik azzal, hogy becslést adjon a neurális hálózat kimenetének hihetőségére. Ekkor jellemzően a tréningmintákat és az aktuálisan elemzendő bemeneti képet hasonlítják össze ismét klasszikus vagy neurális hálózati módszerekkel annak eldöntésére, hogy az objektumfelismerést végző neurális hálózat a tréningje során láthatott-e a bemeneti képhez hasonló mintát.

A többdimenziós adatfeldolgozás a gépi tanulásban a többdimenziós adatok előkészítésének és átalakításának folyamata a gépi tanulási modellben való használatra.

A többdimenziós adatfeldolgozás egyik fő lépése a dimenziócsökkentés. Ezzel a lépéssel csökkenthető az adatokban lévő változók vagy attribútumok száma, miközben a lehető legtöbb releváns információt megőrzi. Az olyan technikákat, mint a főkomponens-elemzés (PCA) és a lineáris diszkriminancia-analízis (LDA) általánosan használják a dimenziócsökkentésre.

A többdimenziós adatfeldolgozás másik fontos lépése a jellemzők kiválasztása. Ez a lépés az eredeti változók vagy attribútumok azon részhalmazának kiválasztására szolgál az adatokban, amelyek a leginkább relevánsak az adott feladat szempontjából. A jellemzők kiválasztásához általában olyan technikákat használnak, mint a kölcsönös információ, a korreláció alapú jellemzőválasztás és a burkoló módszerek. Az adatok normalizálása szintén fontos lépés a többdimenziós adatfeldolgozásban. Ez a lépés az adatok méretezésére szolgál, hogy minden változó vagy attribútum azonos léptékű legyen. Ez azért fontos, mert sok gépi tanulási algoritmus érzékeny a bemeneti adatok léptékére. Az adatok tisztítása és adatimputálása szintén fontos lépés a többdimenziós adatfeldolgozásban. Ez a lépés a hibák, következetlenségek eltávolítására szolgál az adathalmazban. Az adatimputáció az adatokban hiányzó értékek kitöltésére szolgál.

Összefoglalva, a többdimenziós adatfeldolgozás a gépi tanulásban a többdimenziós adatok előkészítésének és átalakításának folyamata a gépi tanulási modellben való használatra. Olyan lépéseket tartalmaz, mint a méretcsökkentés, a jellemzők kiválasztása, az adatok normalizálása, az adatok tisztítása és az adatok imputálása. Ezek a lépések fontosak a gépi tanulási modell teljesítményének javításához, és az adatok megfelelővé tételéhez az adott feladathoz vagy elemzéshez.

Fentiek alapján az egyes megközelítések (klasszikus képfeldolgozás és gépi tanulás) céljai azonosak (objektumok azonosítása egy bemeneti képen), azonban metodikájuk különbözősége és a rájuk külön-külön jellemző nehézségeik miatt egyik módszer sem képes 100%-os biztonságu kimeneti adatot biztosítani.

Mindegyik módszernek megvannak a maga előnyei és hátrányai, és a módszer kiválasztása az alkalmazás speciális követelményeitől, a kép (adat) minőségétől és a rendelkezésre álló számítási erőforrásoktól függ. Érdekes a különböző módszereket párhuzamosítani és a kimeneteiket fuzionálni, ezzel biztosabb információhoz jutni.

2.2. Képfeldolgozási lehetőségek: minőségi jellemzők javítása, többletinformáció bemutatása

A valós objektumokról adatokat több módszerrel szerezhetünk. Ha ezen adatszerzéseket párhuzamosítjuk, akkor elmondhatjuk, hogy az objektum egy pillanatnyi állapotáról különböző szempontok szerinti mérések állnak rendelkezésünkre.

Ha egy objektumról különböző szögekből nagy mennyiségű képet készítünk, akkor többféle elemzésre lehet lehetőségünk. Kereshetünk rajta rész-objektumokat, felépíthetjük virtuális 3D mását az eredetinek vagy a különböző időpontokban készült felvételekből épített 3D objektumokat össze is hasonlíthatjuk.

Ha különböző felépítésű kamerákat alkalmazunk azonos időpillanatokban, akkor az objektumról előállnak különböző adatsorok, melyek különböző szenzorokat használó kamerákból származnak.

Az azonos időpillanatban előálló képeket (adatokat) fuzionálhatjuk is, mely segítségével

többszörös információhoz juthatunk. Jó példa erre az RGB színtartományban működő kamera és egy hőkamera által adott adatok hasonlósága és különbözősége. Hasonlóak, hiszen egy időpillanatban, egy pontból, egy adott objektumról készülhet felvétel, különbözőek, mivel más szenzorral dolgoznak, más célt szolgálnak. Az egy időben, de különböző eszközökkel készült képeket kombinálhatjuk, mellyel új információkhoz juthatunk. Számos módja van a hőkép és az RGB kép kombinálásának. Néhány gyakori módszer:

1. **Overlay (Átfedés):** Ez a megközelítés magában foglalja a hőképet az RGB-kép tetejére helyezve átlátszó vagy félig átlátszó fedőréteg használatával. A perspektivikus torzulást nem kezeli. Ez megtehető képszerkesztő szoftverekkel, például Photoshop vagy GIMP, vagy programozási könyvtárak, például OpenCV használatával megvalósítható.
2. **Color mapping (Színtérkép):** Ez a megközelítés magában foglalja a hőkép színes térképpé alakítását, ahol a különböző hőmérsékleti tartományokat különböző színekkel ábrázolják. A színtérkép ezután kombinálható az RGB képpel képszerkesztő szoftver vagy programkönyvtár segítségével.
3. **Fusion (Fúzió):** Ez a megközelítés magában foglalja a hőkép és az RGB-kép egyetlen képpé történő kombinálását képfeldolgozási technikák, például képfúzió vagy képregisztráció segítségével. Ez megtehető speciális szoftverek vagy programkönyvtárak, például a MATLAB vagy a Python OpenCV könyvtára segítségével.
4. **Annotation (Annotáció):** Ez a megközelítés magában foglalja a megjegyzések vagy címkék hozzáadását az RGB-képhez, amelyek jelzik az objektumok vagy jellemzők helyét a hőképen. Ez megtehető képszerkesztő szoftverrel vagy programkönyvtárak segítségével.

Az RGB kép és a hőkép fuzionálásával előállítható olyan hamis színes képsorozat, melyből 3D hőmodell építhető akkor, ha az eredeti RGB→3D transzformáció lépéseit pontosan megismételjük az előállított hamis színes képeken is. Mivel az objektum teljesen felismerhető 3D modellel reprezentálódik, így a további vizsgálatokra sokkal alkalmasabb, mint a 2D-s hőképek egymás utáni vizsgálata.

2.3. Sugárzási és légszennyezettségi eredmények feldolgozása

A különböző időpillanatokban rögzített egyetlen szenzortól származó adatok idősoros feldolgozása során kinyerhetünk az adott szenzor által érzékelt adatokban lokális minimum, maximum értékeket, vizsgálhatjuk a teljes megfigyelés átlagértékét, további, jól ismert matematika műveletekkel következtethetünk esetleg a mérésen túl várható adatokra.

Ilyen szenzor lehet a légszennyezettségi adatokat rögzítő vagy sugárzási értékeket mérő eszköz. A beérkező adatfolyamban biztosan találhatunk a fentebb sorolt jellemzőket.

Azonban további szenzort vagy szenzorokat alkalmazva fontos többlet információhoz juthatunk. Egyik ilyen szenzor lehet az, amely képes a mérési pont földrajzi koordinátáját rögzíteni.

A bármilyen szenzorhoz kombinált földrajzi koordináta (GPS) az idősoros adatot többlet információval látja el. Az idősoros adat a hozzá kapcsolt földrajzi koordináta birtokában térképszelvényre helyezhető és ezzel többlet információ nyerhető ki. A lokáció ismeretében a több pontban rögzített elsődleges adatsorból már nem csak a lokális értékek határozhatóak meg, hanem a mért jellemző területi eloszlása vagy annak a lokális maximuma, azaz a forrás helye is meghatározható.

3. fejezet

Objektumok keresése adatfúziós módszerekkel

Napjainkban készíthető olyan nagy felbontású légi vagy műhold fotó, mely alkalmas lehet további elemzésekre. A fotó készülhet műhold, repülő, robot repülő vagy multi-kopter segítségével is, azonban elmondható, hogy mindegyik megoldás hasonlóan magas részletességű képeket eredményez. Az elkészült légi fotókon különböző szempontok szerinti vizsgálatok végezhetőek, mely feltételeket a megrendelő vagy a projekt-cél határozhatja meg. A jó minőségű műholdas képek segítségével természetes és mesterséges változásokat követhetünk nyomon vagy akár meghatározott szempont szerinti tárgyakat is detektálhatunk. A légifotók elemzésére a korábbi manuális módszerek helyett algoritmikus megközelítést alkalmaznak, továbbá az utóbbi években lezajlott „gépi tanulási forradalomnak” köszönhetően mélytanulással segített képi klasszifikáció is lehetséges.

Az objektumok azonosítására egyik legkézenfekvőbb, automatizált módszer a neurális hálózat alkalmazása, mely a megfelelően kiválasztott tanítóminták segítségével képes később egy-egy képrészletről eldönteni, hogy van-e azon keresett objektum vagy sem. A nagy számú tanítóminták ellenére előfordulhat, hogy egy neurális hálózat false-positive vagy false-negative eredményt ad az elemzésre átadott képen. További probléma lehet, ha nem szakértő végzi a neurális hálózat tanítását vagy nem áll rendelkezésre minden esetet lefedő minta. Ezen hibák következhetnek abból, hogy a tanítóminták és vizsgált területek fotói

nem azonos évszakban, nem azonos napszakban készültek. Az említett hibákat a hálózat további tanítása, túltanítása helyett klasszikus képelemző módszerekkel eliminálhatjuk oly módon, hogy az egyes eljárások eredményeit fuzionáljuk. Ezzel létrehozható egy olyan rendszer, mely a modern képelemzési technikákat ötvözi a klasszikus képfeldolgozási módszerekkel, megfelelő gyorsasággal működik és a kezdeti beállításokat követően operátori munkával üzemeltethető.

3.1. Neurális hálózatok


Az objektumok azonosítására használhatunk neurális hálózatokat is. Ezen módszer néhány éve kezdett rohamosan terjedni, mivel akkor a grafikus kártyák számítási teljesítménye megfelelő szintre emelkedett. A neurális hálózat alatt érthetünk szoftveres és hardveres megvalósítású hálózatot is. A szoftveres megközelítés volt az utóbbi években a jellemzőbb, míg a hardveres speciális területeken teljesíthet majd jól. Általánosan elmondható, hogy egy neurális hálózat:

- lokális művelet végző elemekből áll (ezeket nevezzük neuronnak),
- a neuronok valamilyen elv vagy követelmény szerint szorosan összekapcsoltak, topológiába rendezettek,
- modernebb változatai a feldolgozáshoz több réteg neuront is használnak, ezek lehetnek rejtettek is,
- tanítható a hálózat (adott bemenetre, adott kimenetet ad válaszként) .

A neurális hálózatok által generált kimeneti adatok szabályzásra nem alkalmasak, általában az emberi érzékelés reprezentációjának tekintjük a neurális hálózatokat. Az érzékelés egyik jellemző és kézenfekvő reprezentációja a képi elemek megkülönböztetése, detektálása. A neurális hálózatok első fontosabb eredményei ezen a területen találhatók. A legelterjedtebb képelemző neurális hálózat a konvolúciós neurális hálózat (convolutional neural network – CNN), melyet objektumok azonosításra, arcfelismerésre használhatunk, valamint eredményeit felhasználják az önvezető járművek fejlesztése során is. A CNN

képes megtalálni és felismerni bizonyos jellemzőket a bemeneti képen, feldolgozni azokat és osztályozni az adatokat. Ezt a folyamatot nevezzük classification-nak. Az alapjait, működését Yann LeCun ismertette 1998-ban, tehát kellő tapasztalat halmozódott fel használatával kapcsolatban.

A CNN alapvetően három rétegből épül fel: bemeneti réteg, konvolúciós réteg, kimeneti réteg.



3.1. ábra. Konvolúciós neurális hálózat (Convolutional Neural Network (CNN) felépülésének sematikus rajza

A bemeneti rétegek konvolúciós rétegekkel vannak összekötve, amelyek számos feladatot ellátnak:


- kitöltés (padding),
- léptetés (striding),
- kernelek futtatása.

Kitöltés: a bemeneti kép felbontása sokszor nem egész számú többszöröse a kernel méretének. Zero-padding akkor, ha 0 értékkel töltjük fel a bemeneti kép hiányzó sorait és oszlopait, Valid-padding akkor, ha bizonyos részeit a képnek elhagyjuk.

Léptetéssel futtatható a kernel a bemeneti adatokon és a futtatás eredményeként előáll a kimeneti adat.

A konvolúciós rétegek között a paraméterek száma csökkenthető relatív kicsi veszteséggel. A

csökkentésnek két jellemző technikája van: maxpooling és average pooling, azaz maximum és átlag szűrés. A szűrés megadott méretű bemeneti területen végezhető, jellemzően 2×2 nagyságúak a szűrők. MaxPooling esetén a 2×2 -es szűrő által lefedett terület legmagasabb értékét helyettesítjük az új részre, AveragePooling esetén pedig a 2×2 -es terület átlag értékét.



3.2. ábra. Konvolúciós neurális hálózat konvolúciós rétegének paraméterszám-csökkentése MaxPooling és AveragePooling technikákkal

Bármely technikát választjuk, a következő konvolúciós rétegnek fele akkora adatmennyiségen kell dolgoznia.

A neurális hálózatok legfontosabb rétege(i) a konvolúciós réteg(ek), ugyanis ezen rétegekben történik a képek lényegi elemeinek kiemelése. Ezeket a kiemelt jellemzőket tanulja meg a hálózat és ezen jellemzők későbbi azonosításával lesz képes arra, hogy az új bemeneti adatokon jelzést adjon a hasonlóságra. A jellemzők kapcsolódhatnak objektumokhoz, azok azonosításához, ezesetben objektum-azonosításról, azaz classification-ról beszélünk.

3.1.1. Aktivációs függvények

A neurális hálózat egyes elemei a neuronok. Ezek aktivitását meg lehet határozni aktivációs függvénnyel. Azaz az egyes neuronok csak akkor tüzelnek, azaz csak akkor generálnak kimenetet, ha az aktivációs bemeneti érték egy bizonyos határérték felett van. Ezzel az aktivációs függvény normalizálja is a kimenetet a $[0, 1]$ tartományba. A használt függvénynek hatékornak kell lennie, ugyanis egy teljes neurális hálózatban több millió neuron is lehet, melyek összes számítási teljesítmény-igénye ezáltal drasztikusan növekedhet. Az aktivációs függvények lényege, hogy a bemenetre nemlineáris transzformáció segítségével adhat kimeneti jelet egy neuron. A teljes hálózat ellenőrzött tanítása során ezek az aktivációs függvények, illetve ezek közül a megfelelő választása erős befolyással bír a hálózat végső megbízhatóságára.

3.1.2. Aktivációs függvények kategorizálása


A neurális hálózatokban használt függvények három alapvető csoportba sorolhatóak:

- Bináris/léptető aktivációs függvény
- Lineáris aktivációs függvény
- Nem-lineáris aktivációs függvény

Bináris/léptető aktivációs függvény

Alapvető függvény, amely határérték alapján hoz döntést. Ha az adott határértéknél nagyobb vagy kisebb a bemeneti érték, annak megfelelően aktiválja a neuront vagy sem.

$$f(x) = 1 \text{ ha } x > 0 \quad (3.1)$$




3.3. ábra. Bináris (más néven léptető) aktivációs függvény

A 3.3. ábrán is látható, hogy a 0-nál kisebb értékekre 0 kimenetet ad a függvény, 0-nál nagyobb értékekre 1 értékű a kimenet, tehát aktiválja a neuront.

Lineáris aktivációs függvény

Egyszerű, egyenes függvény, melynek kimenete egyenesen arányos a bemenettel.

$$f(x) = k * x \quad (3.2)$$



3.4. ábra. Lineáris aktivációs függvény


A lineáris aktivációs függvénynek két nagy problémája van. Az egyik, hogy nem definiálható egy adott tartományban, mindenképpen $[-\infty, \infty]$ tartományban értelmezhető. A neurális hálózat rétegeinek számától függetlenül az utolsó réteg mindig az első réteg lineáris függvényeként értelmezhető. Emiatt a neurális hálózat nem alkalmas komplex problémák kezelésére. Másik probléma, hogy a gradiens állandó, nem függ a bemenettől,

így a neurális hálózat nem fog javulni visszacsatolás és további tanítás után sem.

Sigmoid függvény

Olyan nem-lineáris függvény, mely ábrázolásban S alakot képez. Minden Sigmoid függvény monoton növekvő függvény. Azért használatos a neurális hálózatokban, mert nagyon hatékony, deriválható (ez a tanításnál fontos), alapvetően valószínűségi megközelítés a döntéshozatalban, a $[0, 1]$ tartományban mozog a kimenete. Szűk kimeneti tartománya miatt használjuk döntéshozatali helyzetekben, az előrejelzés pontosabb.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.3)$$




3.5. ábra. Sigmoid aktivációs függvény

Problémája, hogy a szűk kimeneti tartomány miatt a nagy bemeneti értékeket is képes eltorzítani, lényegi információkat elveszíteni (vanishing gradient). Ennek kiküszöbölésére ReLU (Rectified Linear Unit) függvény használatos.

Hiperbolikus tangens függvény

Hasonlít a Sigmoid függvényre, azonban kimeneti értéke $[-1, 1]$ tartományban lehet. Hasonlóan az előzőhöz, döntési helyzetekben használatos függvény.

$$\tanh(h) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.4)$$



3.6. ábra. Hiperbolikus tangens függvény


ReLU aktivációs függvény

A ReLU (Rectified Linear Unit) egy aktivációs függvény, amelyet gyakran alkalmaznak neurális hálózatokban, különösen konvolúciós neurális hálózatokban (CNN) és mélytanulási modellekben. A ReLU függvény a következő módon definiálható:

$$f(x) = \max(0, x) \quad (3.5)$$

Ez azt jelenti, hogy:

- Ha $x > 0$, akkor a kimenet x (lineáris rész),
- Ha $x \leq 0$, akkor a kimenet 0 (vágási rész).



3.7. ábra. ReLu aktivációs függvény

A neurális hálózatok szempontjából fontos tulajdonságai a ReLu függvénynek:

- Nemlinearitás: Bár a pozitív tartományban lineáris, mégis nemlineáris függvényként viselkedik, így segíti a mély neurális hálózatokat komplex összefüggések megta-

nulálásában.

- Sparsity (ritkított aktiváció): Csak a pozitív bemenetek aktiválódnak, a negatív bemenetek 0-ra vágódnak, így bizonyos neurális egységek kikapcsolva maradnak.
- Hatékony számítás: A számítási műveletek egyszerűek, ezért gyorsan kiértékelhető a többi aktivációs függvényhez (pl. szigmoid, tanh) képest.
- Gradiensmegőrzés: A ReLU nem szenved a gradiens elhalás (vanishing gradient) problémától, ami a szigmoid és a tanh függvényeknél előfordul.

3.2. Neurális hálózatok és problémáik

A neurális hálózatok képelemzésre is használhatóak. A konvolúciós neurális hálózat egy olyan mesterséges neurális hálózat típus, amelyet képek, videók elemzésére, illetve az ezekben található jellemzők felismerésére használnak.

Egy konvolúciós neurális hálózat (Convolutional Neural Network, CNN) matematikai formalizmussal megadott definíciója az alábbiak szerint írható le:

$$f_\phi : X \rightarrow Y \quad (3.6)$$

ahol:

- X az inputtér (pl. képek halmaza),
- Y az outputtér (pl. osztálycímkek halmaza),
- ϕ a hálózat tanulható paramétereinek halmaza.

A konvolúciós neurális hálózat több rétegből épül fel. Az alábbiakban az egyes rétegek matematikai modelljét adom meg:

A CNN fő építőeleme a konvolúciós réteg, amely egy súlyozott összegzési műveletet végez egy $W \in \mathbb{R}^{k \times k \times c}$ méretű súlymátrix (kernel vagy filter) segítségével. Az egyes feature map-ek kiszámítása a következőképpen történik:

$$z_{i,j}^{(l)} = \sum_{m=1}^k \sum_{n=1}^k \sum_{c=1}^{C_{l-1}} W_{m,n,c}^{(l)} x_{i+m,j+n,c}^{(l-1)} + b^{(l)} \quad (3.7)$$

ahol

- l a réteg indexe,
- (i, j) az adott pozíció a kimeneti képmátrixon,
- $k \times k$ a kernel mérete,
- C_{l-1} az előző réteg csatornáinak száma,
- $W^{(l)}$ a súlyok tenzora,
- $b^{(l)}$ a bias érték,
- $x^{(l-1)}$ az előző réteg kimenete (a bemenet, ha $l = 1$).

Ezt a műveletet diszkrét konvolúciónak nevezzük, amely formálisan így írható fel:

$$(X * W)(i, j) = \sum_{m=1}^k \sum_{n=1}^k W(m, n) X(i - m, j - n) \quad (3.8)$$

ahol $*$ jelöli a konvolúciós műveletet.

Minden konvolúciós réteg után egy nemlinearitás kerül alkalmazásra, tipikusan a ReLU (Rectified Linear Unit), amelyet az alábbi (aktivációs) függvény ír le:

$$\sigma(z) = \max(0, z) \quad (3.9)$$

Ezzel biztosítjuk a hálózat számára a nemlinearitást.

A max pooling egy gyakori réteg, amely a térbeli méretek csökkentésére (mintavételezés csökkentésére) szolgál. Az alábbi formulával definiálható egy pp méretű pooling ablak esetén:

$$y_{i,j}^{(l)} = \max_{(m,n) \in R_{i,j}} x_{m,n}^{(l-1)} \quad (3.10)$$

ahol $R_{i,j}$ az aktuális pooling ablak tartománya.

A teljesen összekapcsolt réteg (FC) egy egyszerű lineáris transzformáció:

$$y^{(l)} = W^{(l)} x^{(l-1)} + b^{(l)} \quad (3.11)$$

ahol $W^{(l)}$ a súlyok mátrixa és $b^{(l)}$ az eltolásvektor.

Ha az utolsó réteg több osztály közül választ, akkor a softmax aktivációt használjuk, ez a

kimeneti osztályozás:

$$p_i = \frac{e^{z_i}}{\sum_j e^{z_j}} \quad (3.12)$$

Ez valószínűségi eloszlást ad a lehetséges osztályokra.

A CNN súlyait egy veszteségfüggvény minimalizálásával tanuljuk meg, tipikusan a keresztentropia veszteséget használva, ez a tanulási fázis:

$$L = - \sum_{i=1}^N y_i \log(\hat{y}_i) \quad (3.13)$$

ahol y_i a valódi címke és $\hat{y}_i$ a modell által becsült valószínűség.

A gradiens módszereket, például az SGD (Stochastic Gradient Descent) vagy az Adam optimalizálót alkalmazzuk:

$$\theta^{(t+1)} = \theta^{(t)} - \eta \nabla L(\theta^{(t)}) \quad (3.14)$$

ahol θ a tanulási ráta.

A neurális hálózatokat sokan univerzális megoldásnak tekintik szinte minden problémára (objektumfelismerés, arcfelismerés, aláírás ellenőrzés, önvezetési döntési helyzetek stb.), azonban ez a vélekedés egyelőre helytelennek bizonyul.

Több hátránya is van a neurális hálózatoknak.

Black Box működési modell: adott bemenetre nem tudjuk, hogy miért azt a kimenetet adta, amit. Azaz szemléletes példánál maradva: egy objektum osztályozásra (classification) tanított hálózatnak egy repülőgép képét mutatva kimenetre adhatja azt, hogy egy autót lát. Ennek eldöntése, visszafejtése, hogy miért ez a kimenet, szinte lehetetlen. Vannak olyan megoldások, amelyek kimenete ember számára sokkal könnyebben visszakövethető, ilyen például a döntési fa, amiben minden egyes lépés érthető és levezethető. Könnyű belátni, hogy a blackbox működés bizonytalanságát nem célszerű az élet minden területén a rendszer részévé tenni, a neurális hálózat kimeneti értékét tényként kezelni.

A fejlesztési idő és költség egy újabb probléma lehet. A neurális hálózatok gyors és egyszerű használatára számtalan könyvtár rendelkezésre áll már, úgy mint a Keras, Tensorflow, Pytorch esetleg Matlab egyes osztályai. Azonban, ha nem az átlagos feladatokra, hanem valamilyen egyedi, bonyolult probléma megoldására szeretnénk használni, akkor a fejlesztés

időben nagyon elhúzódhat, speciális tudású szakembereket kíván (akik bérezése sem alacsony). Felmerülhet az ötlet, hogy talán egyszerűbb a problémára hagyományos, algoritmikus megközelítéssel megoldást találni, amennyiben az lehetséges. Természetesen nem biztos, hogy van megfelelő algoritmus az adott probléma kezelésére, cél elérésére.

A tanításhoz szükséges adatmennyiség kritikus méreteket ölthet. A neurális hálózatok tanításához több ezer, egyes esetekben több százezer, előre felcímkezett bemeneti adatra van szükség. Ezek előállítása és tárolása sem triviális, ráadásul az adott problémát reprezentáló adatból sokkal kevesebb minta is elegendő lehet hagyományos, algoritmikus megközelítést alkalmazva. Egyre több esetben a neurális hálózatok jól tudnak működni kis mennyiségű tanítóminta után, de ez nem mindig volt jellemző.

Számítási teljesítmény igénye is magas a neurális hálózatok előállításának, azaz a tanítási folyamat során. Jól párhuzamosított architektúrát igényelnek, egy hálózat tanítási ideje néhány órától néhány hétig is terjedhet, mely idő alatt az elfogyasztott elektromos energia is jelentős tényezővé válik.

A neurális hálózatok további problémája a jelzéseik megbízhatósága. A TP (true-positive), TN (true-negative), FP (false-positive), FN (false-negative) kifejezések a neurális hálózatok és gépi tanulási modellek teljesítményének értékelésére szolgálnak, különösen bináris osztályozás esetén. Ezek az osztályozási eredmények kategóriái. Egy bináris osztályozási problémában két osztály van, például:

- Pozitív osztály (pl. célobjektum felismerése)
- Negatív osztály (pl. célobjektum hiánya)

Az osztályozási eredmények az alábbi módon kategorizálhatóak:

3.1. táblázat. Neurális hálózatok - Osztályozási eredmények kategóriái			
Eredmény	Modell előrejelzése (true)	Modell előrejelzése (false)	
Valóság: true (pozitív)	TP	FN	
Valóság: false (negatív)	FP	TN	

A neurális hálózatok false-positive és false-negative kimeneti értéket adhatnak, melyek visszaellenőrzése és észlelése külön rendszereket igényelhet. Az egész rendszer-komplexum pedig már azt a nagyságot is elérheti, hogy bizonyos területeken lehetetlenné válik a neurális hálózatok használata.

Használhatók a neurális hálózatok szabályzó elemként, sok esetben az emberi döntési mechanizmust próbálják másolni, de kimeneti hibájukkal számolni érdemes, kezelni szükséges. A kimeneti hibák észleléséhez assurance monitoring rendszer is szükséges lehet, mely kiépítésének költségei, szaktudás igénye, üzemeltetési követelményei és körülményei alapján csak tőkeerős vállalatok, kutatóműhelyek használhatják kiváló eredménnyel a neurális hálózatokat. Az említett problémára nagy egyetemek kutatólaborjai is próbálnak megoldást találni [1].

Neurális hálózatok esetében érdemes tudni, hogy az adott kimeneti értéket milyen tanítóminta után adta a neurális hálózat. Variable Auto Encoder segítségével eldönthető, hogy a bemeneti képhez hasonlót látott-e a hálózat a tanítás során. Ha nem, akkor jelzést ad az így felkészített rendszer és fenntartással kell kezelni a hálózat kimeneti értékét vagy egyenesen eldobandó az adott kimeneti érték, ezzel a mérőszámok javulnak. [2].

Csak néhány alap kérdésre fókuszálva is látható, hogy a neurális hálózatok megbízhatósága magas is lehet, de ezt semmi sem garantálja.

3.3. Medencék detektálásának fontossága és lehetséges módszerei

Földfelszint ábrázoló felülnézeti fotók előállhatnak több forrásból is, mely forrás lehet műhold, repülőgép, robotvezérlésű kisméretű gép vagy akár multikopter (quadkopter, octokopter). A publikusan elérhető műhold fotók kutatási céllal korlátlanul használhatóak, így alkalmasak bármilyen természeti vagy mesterséges felszíni változás észlelésére, vagy időben eltérő felvételek esetén a változás követésére. A légi fotók egyik használati lehetősége a családi házas környezetben, tulajdonosok által épített vagy mobil medencék detektálása, melyek vízfelülete jól detektálható a magasból készült képen. Ezen objektumok megszámlálása manuális módszerrel nehézkes, nagy sűrűségben lakott területen majdnem lehetetlen. A keresés jól automatizálható, megfelelő mennyiségű minta segítségével neurális hálózat tanítható a felismerési és számlálási feladatok elvégzésére [3] [4].

A medencék felmérésére és nyilvántartására több területről érkezhethet igény: az adózásért

felelős állami szervek különadó formájában növelhetik bevételeiket az egyes területeken luxus beruházásnak számító privát medencékre kivetett adóval. Másik szempont lehet a medencék használatának korlátozása, tiltása, mivel szárazság idején ivóvízzel tölteni nagy medencéket tilos, ugyanis jelentős plusz terhet ró ez a tevékenység az ivóvíz hálózat fenntartójára, az ivóvízbázis mértékletes használata nem érvényesülhet. A nem karbantartott medencék fertőzéseket okozhatnak, mivel fertőzéseket terjesztő szúnyogok keltetőhelyévé is válhat. A fertőzések akár a lakosság körében akár a házi kedvencek populációjában lehetségesek, így a felelős medence használatra való figyelmeztetés is egyfajta célja lehet a medencék detektálásának [5].

Medencék detektálásához szükség van nagy területet lefedő, légi fotókat tartalmazó adatbázisra [6]. Ilyen adatbázis építhető saját eszközökkel, a drága, nagy repülőgépes rendszerektől kezdve az egészen olcsó, multikopter-alapú megoldásig. Hasonló adatbázisok az emberlakta területek nagy részére publikusan elérhetőek olyan nagy szolgáltatók portfóliójában, mint a Google. Az általuk biztosított légi fotók az Earth szoftverben vagy a Maps szolgáltatásukban érhetőek el. Jelenleg a Google Maps légi fotóit használom, mellyel a feladat érdemi része az objektum-felismerési és képfeldolgozási elvek kidolgozására redukálódik és nem tartalmazza a légi fotók készítésének megoldásait.

A korábbi kísérletekben, medence-felismerésre tanított neurális hálózatot sokszor használtam sikerrel olyan területeken, ahol hasonló fényviszonyok között készültek a feldolgozandó légi fotók. Azonban amint a tanítómintáktól jelentősen eltérő környezeti és fényviszonyok mellett próbáltam használni, megjelent kis számú false-positive és false-negative eredmény is. Ezeket az eredményeket csak újabb tanítóminták gyűjtésével, tanításával lehetne eliminálni, de ezt sem lehet korlátlanul megtenni. Idővel fennáll a túltanítás veszélye, melynek eredményeként már a tanítómintához nagyon hasonló felismerendő objektumok is kimaradnak a felismertek közül [7].

A neurális hálózat által adott eredményeket érdemes lehet felülvizsgálni, természetesen továbbra sem manuális munkával, ellenőrzéssel, hanem olyan további automatizmusok kidolgozásával, melyek egymás eredményeit erősíthetik, vagy az egyes módszerek gyengeségeiből fakadó hibákat eliminálhatják.

3.4. Medencék jellemzői légifotók alapján

A medencék közös jellemzője, hogy a légifotókon a környezettől jól elkülöníthetőek, mivel jellegzetes formákkal rendelkeznek, felületük a kék különböző színárnyalataiban látszódik. A különböző színárnyalatok egy-egy medencén belül is fellelhetőek, azaz egyetlen medence felszíne több kék színértéket is tartalmaz. Ezt tetézi jónéhány, a kép készítésekor fennálló egyéb körülmény. Egyik ilyen körülmény, hogy melyik évszakban készült a légifotó. Mérsékelt égöv alatt készült fotók esetében számolni kell négy évszakkal, melyek mindegyike más-más környezeti színeket eredményez. Ezt a problémát nem kisebbíti az sem, hogy a medencéket körülvevő épített járda általában a környezettől jól elkülöníthető színű anyaggal burkolt. Azonban a nagyobb kihívás azon kék árnyalatú foltok felismerése, melyek a kék különböző árnyalataiban láthatóak, összefüggő területet alkotnak és vélhetően egy medence felszínét adják. A mediterrán területek nyári időszakban szárazzá váló növényzete és a színekben ehhez hasonló medencei kiegészítő építmények között elmosódik az éles, felismerhető határvonal, így ebben az esetben a kék felszín keresése vezethet eredményre. Másik fontos tényező, akármelyik égövön készült légi fotót elemzünk, hogy az adott évszakon belül is mely napszakban készült a fotó. Számos kiegészítő, mesterséges tereptárgy vagy természetes növényzet fellelhető, amelyek a medencék felülről látható kék felületét árnyékok vetésével módosítják, esetleg tükröződéssel a kék színskála szélére tolják a medencékre általában jellemző kék szint.

További akadály, hogy a medencék klasszikus felülnézeti világoskék színét csak a 1-2m-es mélységgel rendelkező, kék medence térszínnel rendelkező, tisztán tartott egységek adják. A karbantartás elmaradásával [8], a víz szintelensége (ezáltal a medencefenék jellemző világoskék színének átengedő képessége) vagy a vastagabb vízrétegre jellemző világoskék szín drasztikusan változik. A szín egyéb állapotaiból arra lehet következtetni, hogy a vízben különféle oldott és lebegő állapotban levő szennyeződések találhatóak. A víz színeződésének okai lehetnek a kolloid vas vegyületek, huminanyagok, vagy bármilyen életforma miatti elszíneződés. A színek alapján részletesen meg lehet állapítani egy medence állapotát, azonban a légi fotókon az alábbi színárnyalatok is felismerendők.

Zöld, barna színek eltolódás: vas vagy mangánt tartalmaz a víz. Ez kétféle módon

fordulhat elő: házilag szivattyúzott vízből nyerték a feltöltési mennyiséget vagy olyan hálózati vizet használtak, amelynek a továbbító vezetékrendszere korrodált.



3.8. ábra. Légifotó, melyen a medencéket kell detektálni, különböző formai és színjellemzőik mellett

Fekete színek eltolódás: a víz réz vagy bronz oldatot tartalmaz. Vízellátó rendszerek csőidomok korróziója miatt felszabadult réz oxidok vagy hidroxidok kerültek a vízbe. Zöld, vörös, kékesfekete színárnyalatok: a víz algás, ami természetes, azonban túlzott elszaporodásuk a légi fotókon látható színeltolódást eredményez. Látható, hogy egyetlen típusú objektumot keresünk a légi fotókon (medence), azonban meghatározni a keresési feltételeknek megfelelő objektumot, koránt sem egyszerű. Fentieket figyelembe véve a neurális hálózat folyamatos újra tanítása helyett klasszikus képelemzési módszereket is kerestem, melyek képesek lehetnek a medencéket detektálni, eredményeiket pedig fuzionálhatjuk egy konvolúciós neurális hálózat (CNN) alapú detektor eredményével. CNN alapú detektor alkotásához megfelelő számú tanító mintára van szükség és az adott környezetben megfelelő eredmények érhetőek el (3.8 és 3.9 ábrák).



3.9. ábra. Konvolúciós neurális hálózat segítségével detektált medencék false-positive és false-negative eredményekkel

3.5. Konvolúciós neurális hálózat tanítása és eredménye

Természetesen ezek az eredmények legtöbbször nem hibamentesek.

Kísérleteim során a konvolúciós neurális hálózat használata black-box elv mentén történt. Azaz a Matlab 2019b alkalmazáscsomag „Deep Learning toolbox” által adott lehetséges paramétereket, változókat manipuláltam, de a CNN belső működését nem módosítottam. Ennek belső felépítése a Matlab 2019b alkalmazáscsomag dokumentációjában megtalálható. A 3.10. ábrán is látható: false-positive felismerés is előfordul (ház mögötti világoskék takarófólia) valamint a tanított mintáknak nem megfelelő, egészen eltérő színárnyalatú medence sem került detektálásra. Ezen hibák javítására hagyományos képfeldolgozási módszereket is használhatunk. Az eredményt nem befolyásolja az, hogy a légifotó milyen eszközzel készült, hasonló eredményre juthatunk multikopteres felmérés során is [9].



3.10. ábra. Konvolúciós Neurális hálózat hibás detektálása: piros téglalap a false-positive eredményt, míg a kék téglalap false-negative eredményt jelöli

A fenti eredményt Matlab 2019b programcsomag Deep Learning Toolbox moduljával értem el. A képklasszifikációhoz konvolúciós neurális hálózatot használtam. A 1 algoritmus kellő részletességgel bemutatja az adatelőkészítés, tanítás és osztályozás lépéseit.

Az adatelőkészítés során a rendelkezésre álló dataset-et 80%-20% arányban tanítási és tesztelési adatokra osztottam. A hálózat egy $32 \times 32 \times 3$ képméretű `imageInputLayer`-ből, konvolúciós rétegekből, és teljesen összekapcsolt rétegekből áll. A tanítási folyamat SGDM optimalizációval történik.

Algoritmus 1 CNN alapú képklasszifikáció MATLAB-ban

```

1: Adatok betöltése
2: Load dataset: poolDataset7_3class.mat
3: Read test image: batchpools.bmp
4: Adatok előkészítése
5: Véletlenszerű keverés:
6:  $idx = \text{randperm}(N)$ 
7:  $numTrain \leftarrow 0.8 \times N$ 
8:  $trainingData \leftarrow \text{poolDataset}(idx(1 : numTrain), :)$ 
9:  $testData \leftarrow \text{poolDataset}(idx(numTrain + 1 : end), :)$ 
10: Neurális hálózat létrehozása
11: Bemeneti réteg:  $32 \times 32 \times 3$ 
12: Konvolúciós rétegek:
13: for  $i = 1$  to 2 do
14:     Convolution  $3 \times 3$ , 32 filters, padding = 1
15:     Batch Normalization
16:     ReLU Activation
17: end for
18: Max Pooling:  $3 \times 3$ , Stride = 2
19: Fully Connected Layer: 128 neuron
20: Fully Connected Layer: osztályok száma
21: Softmax + Classification Layer
22: Tanítási Paraméterek
23: Optimizer: SGDM
24: Initial Learn Rate: 0.001
25: Epochs: 10
26: MiniBatch Size: 16
27: Validation Data:  $testData$ 
28: Tanítás vagy betöltés
29: if doTrainingAndEval = True then
30:     Train network:  $net = \text{trainNetwork}(trainingData, layers, options)$ 
31:     Save model: trainedPoolNet.mat
32: else
33:     Load model: trainedPoolNet.mat
34: end if
35: Tesztelés képen
36: Load image: batchpools.bmp
37: Resize image:  $32 \times 32$ 
38: Classify:  $label, scores = \text{classify}(net, I)$ 
39: Display prediction

```

3.6. Klasszikus képelemzési módszerek

A képfeldolgozási módszerek közül azokat használtam, melyek a kép egésze vagy bizonyos összefüggő része helyett a kép elemi alkotórészei szintjén dönti el a keresett objektumra

jellemző tulajdonságot, így azon eljárásokat használtam, melyek nagy méretű képek esetében is gyors, pixel alapú eredményt adnak. A cél egyfajta szegmentáló eljárás létrehozása, mely szín alapján képes az objektumokat osztályozni [10].


3.6.1. Hue Saturation and Value színtartomány

A Hue Saturation and Value (HSV) színtartomány a Red Green Blue (RGB) színtartománytól eltérő ábrázolási mód. A HSV ábrázolást grafikus kutatók alkották, melynek célja, hogy az emberi szemhez jobban illeszkedő modellel dolgozhassanak. A módszer már más, szín alapján jól megkülönböztethető objektum-detektálásra is használt [11].

A HSV (árnyalat, telítettség, fényerő) színmodell egyes csatornáit az alábbi értékeket vehetik fel:


- H (Hue – árnyalat): $0 - 1$ ($0^\circ - 360^\circ$) közötti érték, amely a szín típusát határozza meg (pl. piros, zöld, kék).
- S (Saturation – telítettség): $0 - 1$ (0–100%) közötti érték, amely azt mutatja, hogy a szín mennyire intenzív vagy fakó.
- V (Value – fényerő): $0 - 1$ (0–100%) közötti érték, amely a szín fényességét határozza meg.

Ez a színmodell gyakran használatos képfeldolgozásban, mivel jobban tükrözi az emberi színérzékelést, és megkönnyíti a színek szeparálását (pl. objektumfelismerésnél).



3.11. ábra. HSV színtartomány reprezentációja, amennyiben $S_{hsv} = 1$

Ha a Hue értéket 0.5 és 0.7 között választom a 0–1 skálán, akkor először ezt a tartományt átváltjuk a 0°–360° színkör skálájára: $0.5 \times 360 = 180$ (cián kék avagy világoskék), valamint $0.7 \times 360 = 252$ (kékes ibolya). A 3.11. ábrán látható, hogy az ábrázolt színtartomány kék területét jelöli meg. A fényerő csökkenésével minden szín eltolódik a fekete irányába, kevésbé látható maga a szín. Ezekre a színekre nincs szükségünk, ezért később a fényerő minimumát 0.5-ben kell meghatároznunk. Ha a telítettség (S) és fényerő (V) magas, akkor élénk cián, kékeszöld, kék és kékesibolya színeket kaphatunk. Ha a Saturation alacsony, akkor ezek a színek tompábbak, pasztellesebbek lesznek. A fentiek alapján a 3.12. ábrán látható a HSV azon tartománya, amelyben a keresett objektumok a színeképük alapján elhelyezkedhetnek.



3.12. ábra. Azon HSV tartomány, melyben a keresett objektum színe megtalálható.

Kísérletem során alapvetően a kék színtartományba eső pixeleket keresem, melyek nagy eséllyel a légi fotók elemzése során megadja, hogy hol lehetnek medencék. Ehhez első lépésként az RGB színtartományú légi fotót HSV színtartományra kell konvertálnom. Az RGB képet pixelenként kell átkonvertálnom, melynek lépései:

1. RGB színtartomány minden csatornájának színértékét (0 – 255) 255-el osztom, így $[0 - 1]$ tartományra redukálom az értékeket.

$$R' = \frac{R}{255} \quad G' = \frac{G}{255} \quad B' = \frac{B}{255} \quad (3.15)$$

2. Megkeresem R' , G' , B' értékek legmagasabb és legalacsonyabb értékét, majd ezek

különbségét képezem.

$$C_{max} = \max(R', G', B') \quad (3.16)$$

$$C_{min} = \min(R', G', B') \quad (3.17)$$

$$C_{diff} = C_{max} - C_{min} \quad (3.18)$$

3. A HSV színtartomány egyes értékeit az alábbiak szerint számolhatjuk:

a. Színárnyalat (Hue) számítása:

$$H = \begin{cases} 0^\circ & \text{ha } C_{diff} = 0 \\ 60^\circ * \left(\frac{G' - B'}{C_{diff}} \bmod 6 \right), & \text{ha } C_{max} = R' \\ 60^\circ * \frac{B' - R'}{C_{diff}} + 2, & \text{ha } C_{max} = G' \\ 60^\circ * \frac{R' - G'}{C_{diff}} + 4 & \text{ha } C_{max} = B' \end{cases} \quad (3.19)$$

b. Telítettség (Saturation) számítása:

$$S = \begin{cases} 0 & \text{ha } C_{max} = 0 \\ \frac{C_{diff}}{C_{max}} & \text{ha } C_{max} \neq 0 \end{cases} \quad (3.20)$$

c. Fényerő (Value) számítása:

$$V = C_{max} \quad (3.21)$$

A HSV színtartományra konvertált képen a kék színtartomány a hue csatorna értékei alapján az alábbiak szerint definiálható:

$$HSV_{bluepixel} = img_H \geq 0.5 \text{ és } img_H \leq 0.7 \quad (3.22)$$

ahol img_h a HSV színcsatornára konvertált bemeneti kép árnyalati (H) komponensét jelenti.

Létrehozható olyan bináris kép (detektálási maszk) [10], mely a HSV képpel azonos

felbontású és magas értékű pixeleket tartalmaz azon pozíciókban, ahol a HSV kép adott pixele megfelel a detektálási feltételnek, a többi pixel értéke pedig alacsony értékű.

Tapasztalataim alapján a fenti tartomány nagyon széles a légifotókon történő medencekereséshez, így sok egyéb olyan objektum is beleeshet a létrehozandó bináris kép aktív elemei közé, melyek megtalálása nem célunk. Így a légifotókon bizonyos fényviszonyok mellett a szürkének gondolt elemek is beleeshetnek a keresett tartományba: ilyen lehet a kezdeti képen látható aszfaltcsík is (3.13. ábra).



3.13. ábra. HSV színtartomány alapú medencekeresés eredményeként előállt bináris detektálási maszk, ahol a kék színnek megfelelő pixelek fehérrel jelöltek

Fentiek alapján, medencék színeképe az alábbi módosított képlettel írható le:

$$HSV_{bluepixelpools} = img_H \geq 0.5 \text{ és } img_H \leq 0.64 \text{ és } img_V > 0.5 \quad (3.23)$$

Mint látható, nem csak az img_H tartományát szűkítettem, hanem az adott pixel fényerejét (img_V) is figyelembe vettem annak eldöntése során, hogy medence része lehet-e az adott pixel vagy sem. Az így módosított HSV elemző algoritmus már jobb eredményt adott, igaz, még mindig zajos a kapott bináris kép, ugyanis elszórtan találhatóak aktív (a

feltételnek megfelelő) pixelek. Ezen szórt pixeleket többszöri medián filter alkalmazásával tudjuk eliminálni. Első körben 3×3 , majd két körben 11×11 szűrőt alkalmaztam, amely szükségesnek tűnt a kellő eredmény eléréséhez. Az előállt medence-kereső maszk a 3.14. ábrán látható.



3.14. ábra. HSV színtartomány alapú medencekeresés eredményeként előállt bináris detektálási maszk eredménye median filterrel szűrve

Fenti ábra alapján a medencék megkeresésében hatékony alternatíva tud lenni a megfelelő színkódolás és algoritmus megválasztásával alkotott megoldás. Azonban természetesen vannak gyengeségei is a HSV alapú, pixel szintű döntésnek. Egyrészt az eredmény zajos lesz, szinte nincs is olyan légi fotó, ahol elszórtan ne lehetne találni a definiált skálába tartozó pixeleket. Másrészt a természeti adottságokat képtelen szűrni ez az eljárás. A fenti képen is látható egy tengerparti szakasz, amely természetesen kék színű, a színskálája ezáltal beleesik a keresett értékekbe. Ezen a problémán a medián filter sem tud segíteni, vagy csak olyan sokadik futtatásra, amikor a valós medencéket már egy sokkal korábbi feldolgozási menetben eltüntette. Azaz a feldolgozás eredménye lényegében egy fekete kép lenne.

3.2. táblázat. RGB színtartomány által definiált lehetséges "kék" színek

Red	Green	Blue
104	199	253
90	239	255
78	231	252
118	254	253
137	251	253
88	206	244

3.6.2. Fuzzy következtetési rendszer

A hagyományosnak tekinthető RGB színkódolású képeken is lehetséges kék színt keresni. Az RGB színkódolás jellemzője, hogy minden használt alapszínt (piros, zöld, kék) külön-külön értékként kezeli és tárolja. Ezen három érték együttese határozza meg egyetlen képi elem, pixel színét. Az ilyen színkódolású képen a medence keresés elsősorban manuális feladatot jelenthetne, ugyanis a kék színként látható pixelek és azok által alkotott formák nem jelentik azt, hogy színkódjuk $RGB(0, 0, 255)$. Azaz a kék, nem tisztán kék színként látható egy légifotón (ahogy a természetben sem), hanem a kék szín mindenféle árnyalata az RGB egyes szín csatornáinak keverékeként állnak elő, ahogy a 3.2. táblázatban néhány példa is látható.

Ilyen színkódoláson dolgozva az automatizáció bonyolult, ugyanis az emberi érzékelés "olyan, mintha kék lenne" valamint a "világos kék", "tenger kék", "tengerész kék", "ég kék", "medence kék" állítását kell valamilyen módon algoritmizálható formába ültetni. Az RGB szín kódolás jellemzője miatt, ez szinte végtelen "if..then.." sorokat jelentene egy klasszikus algoritmusban, ugyanis pl. R színcsatorna egyedi értékei meghatározzák, hogy a kék színárnyalat eléréséhez a G és B csatornák milyen további értékeket vehetnek fel.

Algoritmus 2 Klasszikus számítási mód arra, hogy az adott pixel kék színű vagy sem

Require: $255 \geq R \geq 0$ $255 \geq G \geq 0$ $255 \geq B \geq 0$

```

if  $R = 104$  then
  if  $G = 199$  then
    if  $B = 253$  then
       $pixelIsInThePool \leftarrow 1$ 
    end if
  end if
end if

```

Az algoritmussal kapcsolatos megjegyzések és magyarázatok:

- R, G, B : a vizsgálandó képi elem (pixel) három színcsatornája
- $pixelIsInThePool$: logikai változó, értéke 1, ha az adott képi elem megfelel a keresési feltételeknek

Látható, hogy az összes eset nyers algoritmussal (2. algoritmus) való megközelítése nem lehetséges, így más módszert kell alkalmazni.

Egyik lehetséges megközelítés a Fuzzy következtetési rendszer építése, mely képes lehet az emberi, megfogalmazható, azonban nehezen algoritmizálható véleményeket modellezni. Fuzzy rendszer alapú megoldások számtalan területen fellelhetők, legyen az navigáció, gazdasági döntés előkészítés vagy akár képfeldolgozás [12]. Ahhoz, hogy jól működő Fuzzy következtetési rendszert definiáljak, mely képes a medencék detektálására, több fázison keresztül kell azt felépíteni. Első lépésként a légi fotók halmazából választottam néhány referencia fotót. Eerre azért van szükség, mert a referencia fotókat egyfajta input adatként kezelem. Két egyenlő részre osztva a Fuzzy rendszer definiálásához szükséges minta adatokat és vissza ellenőrző (backcheck) adatokat is kaphatunk. Érdekes a választott fotókat 50 – 50%-os halmazokra bontani, így kellő ismeretet lehet kinyerni a következtetési rendszer felépítéséhez és még mindig marad behatárolható légi fotó a rendszer tesztjéhez. Második lépés a back-testek elvégzése és az eredmények alapján esetleges finomhangolása a szabályrendszernek. A Fuzzy következtetési rendszer jellemzője, hogy egy vagy több bemeneti adatra bizonyos kimeneti értékekkel válaszol. A bemeneti és kimeneti érték vagy értékek közötti kapcsolatot szabályrendszerrel írja le. A szabályrendszer mondatszerű állításokból épül fel, mely az emberi döntéshozatalhoz hasonló működést eredményez.

A Fuzzy logikai rendszerekben a hagyományos, bináris logikától eltérően a valóságos problémák bizonytalan adatokat tartalmaznak. A Fuzzy következtetési rendszerek az ilyen típusú problémák megoldására szolgálnak.

A fuzzy logikai rendszerek alapja a fuzzy halmazok elmélete. Egy A fuzzy halmaz egy olyan halmaz, amely az elemekhez egy tagadottságot (fuzzy membership function/fuzzy tagsági függvény) rendel, amely a $[0, 1]$ intervallumban egy valós számot ad vissza:

$$\tilde{A} : X \rightarrow [0, 1] \quad (3.24)$$

ahol X az elemek halmaza (például valós számok), és $\tilde{A}(x)$ az x elemhez rendelt tagsági fok, amely a fuzzy halmazhoz való tartozás mértékét jelenti.

A fuzzy következtetési rendszerek kulcsfontosságú összetevői a fuzzy szabályok, amelyek az alábbi formában jelennek meg:

HA A AKKOR B

ahol A és B fuzzy halmazok.

Például:

”HA a hőmérséklet magas, akkor a ventilátor sebessége magas”

Egy fuzzy szabály tehát a bemenetek és a kimenetek közötti kapcsolatot írja le, ahol mindkettő fuzzy értékekkel van reprezentálva. A fuzzy következtetési folyamat a szabályok alkalmazásával történik. A fuzzy következtetés három lépésből áll:

- Fuzzyfikálás: Az éles (precíz) bemeneteket fuzzy értékekre alakítjuk át. Ha x egy bemeneti adat, és A egy fuzzy halmaz, akkor a tagsági fok:

$$\hat{A}(x) \quad (3.25)$$

- Szabályalkalmazás: Minden egyes fuzzy szabályra alkalmazzuk a következő logikai operációt: HA A AKKOR B

A fuzzy szabály következtetése a következő módon történik, ahol a következtetés által kapott fuzzy halmaz $\tilde{B}$ tagsági fokait az A tagsági fokok alapján meghatározzuk:

$$\tilde{B}(x) = \min(\tilde{A}(x), \tilde{R}(x)) \quad (3.26)$$

- Defuzzyfikálás: A következtetési folyamat végén a fuzzy eredményeket egy éles értékre kell visszaalakítani. A defuzzyfikálás során a következő formulát alkalmazzuk a kimenet (output) éles értékének meghatározására:

$$y = \frac{\sum_i y_i \cdot \mu_B(y_i)}{\sum_i \mu_B(y_i)} \quad (3.27)$$

Fentieket figyelembe véve a fuzzy következtetési rendszer matematikai modellje a szabályok

összességét tekintve:

$$\tilde{y} = \bigcup_i \min(\tilde{A}_i, \tilde{B}_i) \quad (3.28)$$

ahol:

- $\tilde{A}_i$ az i -edik bemeneti fuzzy halmaz,
- $\tilde{B}_i$ az i -edik kimeneti fuzzy halmaz.

Az aggregált eredményből a defuzzyfikálás segítségével egy éles y értéket számolunk:

$$y = \frac{\sum_i y_i \cdot \mu_{\tilde{B}_i}(y_i)}{\sum_i \mu_{\tilde{B}_i}(y_i)} \quad (3.29)$$


3.6.3. Szegmentáció Fuzzy következtetési rendszer segítségével

Célom egy olyan pixel alapú szegmentációs eljárás, szabályrendszer definiálása, amely a bemenetként kapott képeken képes medencéket detektálni. Természetesen nem minden detektált régió tartalmaz majd medencét. Ennek oka, hogy a szín alapú detektálás eredményezhet false-positive eredményeket, találatokat is: egy medence pixelére jellemző RGB csatornák korrelációja előállhat más objektumok részeként is: takarófoliákon, természetes vízfelületeken stb. A rendszer képes bármilyen méretű bemeneti kép feldolgozására, a méret csupán a feldolgozási időt befolyásolja.

$$T_{total} = I_w * I_h * T_{pixel} \quad (3.30)$$

Ahol T_{total} a teljes feldolgozási idő, I_w és I_h rendre a bemeneti kép szélessége és magassága pixelben kifejezve, T_{pixel} a kép egy pixelének feldolgozási ideje. A bemeneti képből bináris kimeneti képet állítottam elő, melyhez az alábbi szabályt definiáltam: Legyen I egy bemeneti kép, melynek mérete $S = w * h$, ahol w és h rendre a bemeneti kép szélessége és magassága. A medence-detektor függvény, mely a bináris O (output) képet előállítja I bemeneti RGB képből:

$$O_{i,j} = \begin{cases} 1 & \text{ha } I_{i,j} \in medence \\ 0 & \text{ha } I_{i,j} \notin medence \end{cases} \quad (3.31)$$



3.15. ábra. RGB színskála szerinti kép egyes színcsatornáinak hisztogramja

ahol i és j a bemeneti és kimeneti képek pixeleinek koordinátái.

A detektálás fő szabálya a fenti, azonban nem elégséges feltétele. Annak eldöntése, hogy az I_{ij} pixel medencéhez tartozik-e vagy sem, egy előzetes vizsgálat és az abból születő eredmények függvénné alakítása előzi meg. A vizsgálat során az adott terület néhány részét manuálisan ellenőriztem és kerestem meg a potenciális medencéket.

A medencék különböző kék színárnyalatban láthatóak, mely függ a kép készítésének napon belüli időpontjától, környezet fényességétől, egyéb időjárási körülményektől. Ezen RGB alapú, kék színeket, illetve a kék szín R, G, B csatornáit tagsági függvényekkel detektálhatjuk.

A tagsági függvények a tanításhoz felhasznált képek releváns részeinek csatornánkénti hisztogramjából (???. ábra) alkothatóak.

A színcsatornánkénti hisztogram megadja, hogy milyen módon kell definiálni a tagsági

függvényeket az egyes csatornák esetében, azaz milyen bemeneti értékekre fog tüzelni a szabályrendszer.

A hisztogramok alapján megállapítható, hogy a kék és zöld csatornákra a legérzékenyebb az RGB kép kék árnyalatai, míg a piros csatorna szélesebb tartományban értelmezhető.

A tagsági függvények az alábbiak szerint definiálhatók: Legyen adott egy P pixel, ami a bemeneti I kép egy elemi egységét reprezentálja RGB színcsatorna kódolásával. Ekkor M_r , M_g , M_b Fuzzy trapéz tagsági függvények (3.16. ábra) az alábbiak szerint definiálhatók:

$$\mu_{Mr}(x) = \begin{cases} 0, & x \leq 92 \\ \frac{x-92}{112-92}, & 92 < x \leq 112 \\ 1, & 112 < x \leq 196 \\ \frac{210-x}{210-196}, & 196 < x \leq 210 \\ 0, & x > 210 \end{cases} \quad (3.32)$$

ahol

- x a színes kép aktuális pixelének R (piros) csatorna értéke,
- alsó küszöb: 92,
- alsó plató: 112,
- felső plató: 196,
- felső küszöb: 210.

$$\mu_{Mg}(x) = \begin{cases} 0, & x \leq 178 \\ \frac{x-178}{198-178}, & 178 < x \leq 198 \\ 1, & 198 < x \leq 243 \\ \frac{250-x}{250-243}, & 243 < x \leq 250 \\ 0, & x > 250 \end{cases} \quad (3.33)$$

ahol


- x a színes kép aktuális pixelének G (zöld) csatorna értéke,
- alsó küszöb: 178,

- alsó plató: 198,
- felső plató: 243,
- felső küszöb: 250.

$$\mu_{Mb}(x) = \begin{cases} 0, & x \leq 178 \\ \frac{x-178}{198-178}, & 178 < x \leq 198 \\ 1, & 198 < x \leq 250 \\ \frac{255-x}{255-250}, & 250 < x \leq 255 \\ 0, & x > 255 \end{cases} \quad (3.34)$$


ahol

- x a színes kép aktuális pixelének B (kék) csatorna értéke,
- alsó küszöb: 178,
- alsó plató: 198,
- felső plató: 250,
- felső küszöb: 255.



3.16. ábra. RGB színskála szerinti kép színcsatornánként definiált tagsági függvényei - (a) piros színcsatorna tagsági függvénye; (b) zöld színcsatorna tagsági függvénye; (c) kék színcsatorna tagsági függvénye

Az így előálló tagsági függvények azok, amelyek lefedik azokat az értékeket a lehetséges $[0,255]$ tartományban, amelyek a három színcsatornát összekeverve kék látható színt eredményezhetnek a vizsgált RGB képen. Matlab Fuzzy toolbox rendszerben definiált minden tagsági függvény a 3.17. ábrán látható.



3.17. ábra. Minden definiált tagsági függvény Matlab Fuzzy Toolbox rendszerben - (a) piros színcsatorna tagsági függvénye; (b) zöld színcsatorna tagsági függvénye; (c) kék színcsatorna tagsági függvénye


A Mamdani fuzzy rendszerben a szabályokat a tagsági értékek alapján hozom létre.

Például az alábbi lehet egy Fuzzy szabály:


”Ha $\mu_{Mr}(x)$ megfelelotartomanybaesik és $\mu_{Mg}(x)$ megfelelotartomanybaesik, akkor $\mu_Y(x)$ medence.”

A kimeneti függvény lényegében két állapotot adhat, azaz a szabályok szerint a vizsgált kép adott pixele lehet egy medence része vagy a háttér (egyéb tereptárgyak, más objektumok) része. Jelen esetben minden olyan RGB szín, mely nem köthető medencéhez, háttérként kezelendő. Ehhez Mamdani szabályrendszert fogalmaztam meg, amely kimenetként ”hatter” és ”medence” értékeket adhat (3.18. ábra). Az így összeálló következtetési rendszer


irányítási területét 3.19. ábrán mutatom be.



3.18. ábra. RGB színskála szerinti képen, Fuzzy következtetési rendszer kimeneti függvénye annak eldöntésére, hogy az adott pixel medence lehet vagy sem



3.19. ábra. Fuzzy következtetési rendszer irányítási területének reprezentációja a tagsági függvények és a színcsatornák összefüggései tekintetében - (a) piros-kék színcsatornákra vonatkoztatva; (b) piros-zöld színcsatornákra vonatkoztatva; (c) zöld-kék színcsatornákra vonatkoztatva



3.20. ábra. RGB színskála szerinti képen, Fuzzy következtetési rendszer kimeneti függvénye alapján létrehozott bináris maszk az objektum detektálására

A vizsgált bemeneti kép egyes pixelei alapján a Fuzzy szabályrendszert alkalmazva előállítható egy bináris kép, mely a feltételezett medencéket jelöli. A 3.20. ábrán ez a bináris detektor maszk látható, pirossal festve azokat a területeket, ahol feltételezhető a keresett objektum. Természetesen itt is látható false-pozitív találat.

A detektálási maszkot Matlab alkalmazáscsomag segítségével állítottam elő. Annak eldöntésére, hogy az egyes képi elemek megfelelhetnek-e egy keresett objektumot alkotó elemi építőelemnek, azaz megfelelő színértékekkel rendelkező pixelnek, Fuzzy következtetési rendszert használtam.

A szabályrendszer definiálását követően előállítható egy következtetési rendszer. Az elemi szabályok meghatározzák, hogy az egyes csatornák mely értéke esetén tekinthető a bemeneti érték RGB színskálán értelmezett kék színeként. Ezt a szabályrendszert futtathatjuk a bemeneti adaton és segítségével előáll egy kimeneti érték, ami az adott pixelnek pozíciójának megfelelő detektálási maszkon értelmezett pixel lesz. A kimenet kétféle értéket vehet fel: fekete és ettől eltérő bármely színt.

Az algoritmussal kapcsolatos megjegyzések és magyarázatok:

Algoritmus 3 Optimalizált Fuzzy Logika alapú detektálási maszk előállítás

```

1: Begin
2: Irgb  $\leftarrow$  imread('targetedAerialPhoto.jpg')
3: (x, y, z)  $\leftarrow$  size(Irgb)
4: fis  $\leftarrow$  readfis('fuzzyRGBbasedbatch')
5: RGBmatrix  $\leftarrow$  double(reshape(Irgb, [], 3))
6: outputVector  $\leftarrow$  evalfis(fis, RGBmatrix)
7: mask  $\leftarrow$  (outputVector > 0.5)
8: imageMaskResult  $\leftarrow$  zeros(x, y, 3, 'uint8')
9: imageMaskResult(repmat(mask, [1, 1, 3]))  $\leftarrow$  repmat(reshape([255, 0, 0], [1, 1, 3]),
    sum(mask(:)), 1)
10: imwrite(imageMaskResult, 'justmask.jpg')
11: End

```

- *Irgb*: az eljárás bemenete a feldolgozandó légifotó, amelyen előre meghatározott feltételeknek megfelelő objektumokat keresek
- (x, y, z) : meghatározom a bemeneti kép méretét
- *fis*: az előre betanított Fuzzy következtetési rendszer betöltése
- *outputVector*: fuzzy logikai kiértékelés
- *mask*: létrehozott bináris detektálási maszk

Ahogy a 3.20. ábrán látható, hasonlóan jó eredmény érhető el Fuzzy alapú megközelítéssel, mint HSV színcsatornára kódolt kép feldolgozása során. A szabályok megfogalmazása egyszerű, mindenki számára érthető a megközelítés logikája. Az elkészült alkalmazás bármely bemeneti adaton képes a Fuzzy következtetési rendszert futtatni, ahogy az a 3. algoritmusnál is látható.


3.7. Fuzionálás, utófeldolgozás több lépésben

Az egyes feldolgozási módok eredményei már önmagukban is ígéretesek. A legenerált maszkok megfelelően jelölik a légifotón fellelhető medencéket. Mind HSV, mind Fuzzy logika alapú megközelítésben az RGB színkódolású képen nagy biztonsággal képesek vagyunk medencékre jellemző színeket detektálni. Nagy különbséget mutat a detektálás módjában a neurális-hálózat alapú megközelítéshez képest, ugyanis ezen esetben a tanító minták minősége, fényviszonyok jelentősen befolyásolják a detektálás eredményességét. A három különböző megközelítési mód együttesen képes lehet nagyobb biztonsággal detektálni a

medencéket, hiszen eltérő módon közelítik meg a problémát. A megfelelő eredmények elérése érdekében a HSV és Fuzzy alapú detektálás során előálló bináris maszkokat fuzionálni szükséges. A fuzionálást követően egy olyan medence-detektáló maszkot kapunk, mely a kétféle megközelítés eredményeinek együttesét adja. A bináris képek esetében, két maszk együttesét az alábbi bináris maszk adja. Legyen I_{hsv} és I_{fuzzy} két bemeneti bináris maszk, i és j ezen maszkok pixeleinek koordinátái. $O_{i,j}$ kimeneti maszk előáll az alábbi szabályok szerint:

$$O_{i,j} = \begin{cases} 1 & \text{ha } I_{hsv_{i,j}} \vee I_{fuzzy_{i,j}} = 1 \\ 0 & \text{ha } I_{hsv_{i,j}} \wedge I_{fuzzy_{i,j}} = 0 \end{cases} \quad (3.35)$$

Az így kapott fuzionált detektálási maszk a két módszer együttes eredményét tartalmazza, azaz olyan területeket fed le, ahol valószínűleg található medence. Az egyes módszerek eredményei jól láthatóak az alábbi, több rétegből felépülő 3.21 ábrán. Az első réteg a feldolgozandó területet tartalmazó légifotó. A második réteg a HSV és Fuzzy alapú medencedetektálás feldolgozási eredményeinek fuzionáltja, szűrő eljárásokkal finomított változata. A harmadik réteg a neurális hálózat által felismert medencék. A negyedik réteg mutatja azt az eredményt, mely a második és harmadik réteg eredményeit összegzi. Ez a réteg egyúttal a helyes medencedetektálás is, hiszen a neurális hálózat false-positive eredménye eliminálva lett a HSV és Fuzzy fuzionálttal, valamint a tengerpart nagy területe szintén kizárásra került a neurális hálózat eredményei alapján. Azaz a három különböző megközelítés eredményeként megfelelő, megbízható detektálási eljárást kaptunk.



3.21. ábra. Alsó réteg: eredeti légifotó, Második réteg: HSV és Fuzzy detektálások fúziója, Harmadik réteg: CNN által detektált medencék, Negyedik réteg: Sikeresen detektált medencék elhelyezkedése

3.8. Fuzionálás, utófeldolgozás háromváltozós többségi függvénynel

Háromváltozós többségi Boole-függvény segítségével az egyes képfeldolgozási eredmények fuzionálhatóak és egy végleges detektálási maszk (M_{det}) készíthető. A háromváltozós többségi Boole-függvény megköveteli, hogy a három bemeneti érték közül legalább két érték igaz legyen. Másként fogalmazva az R eredmény értéke 1, ha a bemeneti értékek többsége 1 értékű vagy az eredmény 0 ha a bemeneti értékek többsége 0.

$$R(M_{det}) = f(I_{hsvmask}, I_{fuzzymask}, I_{cnn}) \quad (3.36)$$


Részletesen a következő igazságtábla tartalmazza az egyes bemeneti értékekre adott

kimeneteket.

3.3. táblázat. Háromváltozós többségi Boole-függvény igazságtáblája

$I_{hsvmask}$	$I_{fuzzymask}$	I_{CNN}	M_{det}
0	0	0	0
0	0	1	0
0	1	0	0
0	1	1	1
1	0	0	0
1	0	1	1
1	1	0	1
1	1	1	1

A végleges detektálási maszk (M_{det}) egy olyan detektálási maszk, mely minden egyes pontjában a háromváltozós többségi függvény szabályai szerinti detektálási pontok (pixelek) szerepelnek. A három bemeneti detektálási maszk sorban: neurális hálózat által előállított detektálási maszk (I_{cnn}), RGB szintéren alapuló Fuzzy logika alapján definiált detektálási maszk (I_{rgb}) és HSV szintéren előállított detektálási maszk (I_{hsv}). Az ilyen módon elkészült maszk alkalmas a keresett objektumok detektálására, nagyobb bizonyossággal találja meg a szempontoknak megfelelő objektumokat. A teljes, több átalakítást és detektálást is magába foglaló folyamatot a 3.22. ábra szemlélteti.



3.22. ábra. A létrehozott komplex rendszer folyamatábrája

3.9. Eredmények

A konvolúciós neurális hálózatok azon ígéretét, miszerint hamarosan minden képelemzési feladatra, objektumok keresésére, azonosítására (classification) univerzálisan alkalmasak lehetnek, még nem értük el. A neurális hálózatok működését és a velük szemben támasztott elvárások elérését sok tényező befolyásolja. Több kutatási terület is foglalkozik neurális hálózatok használatával, azonban átütő sikert sem a gépjármű vagy vízalatti jármű önvezetés, sem az akadálydetektálás területén nem értek még el. Ezen kutatások egyik nagy kérdése, hogy mikorra lehet olyan hardver és szoftver kombinációt fejleszteni, ami képes megbízható válaszokat adni az elvárásokra. Amíg ez nem valósul meg és az egyes használati célterületeken nem áll rendelkezésre megfelelő erőforrás, addig köztes megoldások használatával is jó eredmények érhetőek el. Ilyen megoldás lehet a több, specializált neurális hálózat használata egy cél érdekében (pl. akadályfelismerés) vagy a neurális hálózatok eredményeit validálhatjuk, kiegészíthetjük klasszikus képfeldolgozási módszerekkel. A gyakorlatban az utóbbi módszer megfelelő eredményt adott, sikeres a kiértékelő és végleges eredményt előállító algoritmus implementációja is. A neurális hálózat természetesen false-positive kimeneteit sikeresen elimináltam két további, klasszikus képfeldolgozási módszer használatával és ezzel egy olyan új eljárást valósítottam meg, mely összességében jobb eredményt ad, mint bármely tárgyalt módszer egyedül.

1. Tézis

Kidolgoztam és kísérleti eredményekkel igazoltam egy olyan komplex algoritmust, mellyel kisméretű robotrepülőgépek által készített légi felvételekből előálló nagy mennyiségű, több dimenziós adatot az előre, szabadon definiálható tartalmi feltételek mentén elemeztem. Az algoritmus több, egymástól függetlenül is értelmezhető eljárást tartalmaz, melyek mindegyike értékelhető eredményt ad, azonban az egyes vizsgált adatpontokra jobb eredményt értem el az eljárások fuzionálásával. Az általam kidolgozott és megvalósított megoldás a következő jellemzőkkel rendelkezik:

- 1. a komplex eljárás minden eleme önálló és egyenértékű, melyek között nincs előre definiált hierarchikus sorrend,*
- 2. az eljárás egésze nagy mennyiségű adat elemzését teszi lehetővé,*

3. *alkalmas objektumok azonosítására úgy, hogy az egyes részmegoldások hamis-pozitív és hamis-negatív eredményeit eliminálja a végleges eredményből,*
4. *jobb eredményt szolgáltat, mint amit a felhasznált eljárások önállóan adnak.*

Tézishez kapcsolódó tudományos közlemények: [T1][T2]

4. fejezet

Hőkamera és színes kamera adatainak fúziója

Az színes képek színei a valós világot reprezentálják, a színskála segítségével a tárgyak, textúrák, színek a szabad szemmel láthatókkal megegyező a képen is. Elterjedt színskála az RGB színskála, amely három csatornát (piros, kék, zöld) használ a valós látvány reprezentációjára. A hőkamera képe egy tetszőlegesen előre meghatározott színskálán mozog, melynek a valós világ színeihez nincs köze. Helyette az adott pixel színe az adott pontban mérhető hőmérsékletet reprezentálja. A hőképek készítése egyre több területen lehet indokolt, épület-hőtechnikai vizsgálatok, gépjármű hibakeresések, környezeti szennyezések detektálásának lehet alapja. Azonban a hőképek készítésével több probléma is jelentkezik. Az elsődleges az, hogy nagyon pontosan kezelni kell az adott kép készítésének helyét és irányát mivel a fotózott területek utólag nem biztos, hogy felismerhetőek lesznek a hamis színskála és hőérték reprezentáció alapján. Másik probléma, hogy a felismerést segítő nagy felbontású hőkamerák jelenlegi ára nagyon magas, az alacsony felbontású változatok által készített képek nem alkalmasak objektumok felismerésére. A nagy felbontású színes képek és az olcsó hőkamera által adott alacsony felbontású képek kombinálásával (fúziójával) olyan kép állítható elő, amelyen a tárgyak továbbra is felismerhetőek maradnak és költséghatékonyan hőmérsékleti értékek is hozzárendelhetők az egyes területekhez.

A hőkép és az RGB kép egyesítésének számos előnye van:

1. Megnövelt információtartalom: A hőkép és az RGB kép kombinálásával több információ nyerhető ki a kombinált képből, mint bármelyik képről önmagában. Például a hőképek a hőmérsékletről, míg az RGB képek a színről és a textúráról adhatnak információt.
2. Továbbfejlesztett megjelenítés: A hőkép és az RGB kép egyesítése megkönnyítheti a képen lévő információk megjelenítését és értelmezését. Például egy hőkép és egy RGB kép összeolvasztásával lehetőség nyílik egy objektum hőmérséklet-eloszlásának megtekintésére színben, így könnyebben azonosítható a meleg és hideg pont.
3. Továbbfejlesztett jellemzőfelismerés: A hőkép és az RGB kép összekapcsolása javíthatja a jellemzők észlelését, mivel a két képről kiegészítő információkat szolgáltat. Például egy RGB-kép egy tárgy alakjáról, míg a hőkép az objektum hőmérsékletéről adhat információt.
4. Jobb teljesítmény: Egyes esetekben a hőkép és az RGB kép egyesítése jobb teljesítményt eredményezhet olyan feladatokban, mint például az objektumfelismerés vagy a követés, mivel több információt biztosít az algoritmus számára.
5. Megnövelt robusztusság: Több információforrás egyesítésével a rendszer robusztusabb lehet a zajokkal, a fényváltozásokkal és más környezeti tényezőkkel szemben, amelyek befolyásolhatják a hőkép vagy önmagában az RGB kép teljesítményét.
6. Megnövelt kontextus: A hőkép és az RGB kép kombinálása több kontextust biztosíthat a jelenetnek, lehetővé téve a tárgyak és környezetük kapcsolatának jobb megértését.

Míg a hőkép és az RGB kép egyesítésének számos előnye van, néhány hátrányt is érdemes figyelembe venni.

1. Megnövekedett összetettség: A hőkép és az RGB kép egyesítése növelheti a képfeldolgozási folyamat bonyolultságát, és speciális szoftverre vagy programkönyvtárra lehet szükség a megvalósításhoz.
2. Megnövekedett számítási erőforrások: A hőkép és az RGB kép egyesítése növelheti a kép feldolgozásához szükséges számítási erőforrásokat is, ami egyes alkalmazásoknál

korlátot jelenthet.

3. Szinkronizálási problémák: A hőkép és az RGB kép egyesítéséhez a két kép egy időben, azonos nézőponttal, de nem azonos felbontással készül. Nehéz lehet a két kép helyes igazítása, ami regisztrációs hibákhoz vezethet.
4. Felbontásvesztés: Egyes esetekben a hőkép és az RGB kép egyesítése a végső kép felbontásának csökkenéséhez vezethet, különösen, ha a képek eltérő felbontásúak, vagy ha a képeket átméretezzük az igazítás érdekében.
5. Információvesztés: A hőkép és az RGB kép egyesítése információvesztéshez vezethet, különösen, ha a képek nincsenek megfelelően igazítva, vagy ha a képek tömörítettek.
6. Értelmezési nehézségek: A hőkép és az RGB kép összeolvasztása is megnehezítheti a kép értelmezését

A képfeldolgozás során többféle képfúziós technika létezik. Néhány gyakori módszer:

1. Pixelszintű összevonás (pixel-level): Ez a módszer több kép pixelértékeit kombinálja egyetlen összeolvasztott kép létrehozásához. Egy egyszerű példa erre két vagy több kép pixelértékének átlagolása.
2. Funkciósztű összevonás (feature-level): Ez a módszer több képből von ki elemeket, például éleket vagy textúrákat, és egyesíti őket egyetlen összeolvasztott kép létrehozására.
3. Döntési szintű fúzió (decision level): Ez a módszer egy döntéshozatali algoritmus használatával kombinál több képet, azok egyéni jellemzői vagy a jelenet kontextusa alapján.
4. Hibrid módszerek: Ez a módszer több technikát kombinál, például pixelszintű, jellemző szintű és döntési szintű fúziót, hogy egyetlen összeolvasztott képet hozzon létre.

A módszer megválasztása az egyesítendő képek típusától és a fúzió kívánt eredményétől függ. Fontos megjegyezni azt is, hogy a fúzió minőségét befolyásolhatja a képek regisztrációja, ami a képek helyes igazításának folyamata. Azaz a különböző kamerákkal készült képeket megfelelően kell párba állítani és azonos tájolással kell rajtuk szerepeljen a felvételezett tárgy. A pixelszintű fúzió több kép kombinálásának módszere az egyes képek pixelértékeinek átlagolásával vagy súlyozásával. Az alapötlet az, hogy matematikai műveletekkel több kép

pixelértékeit egyetlen képpé egyesítik.

A pixel-szintű fúzió több fajtája ismert:

1. Átlagos összeolvadás: Ez a módszer több kép pixelértékének átlagát veszi fel egyetlen összeolvasztott kép létrehozásához. Ez egy egyszerű és egyértelmű módszer, de a finom részletek elvesztéséhez vezethet, és elmosódott képet eredményezhet.
2. Maximális összeolvadás: Ez a módszer több kép pixelértékének maximális értékét veszi fel egyetlen összeolvasztott kép létrehozásához. Ez a módszer megőrzi a legmagasabb intenzitásértékeket minden egyes képről, de más képek információinak elvesztéséhez vezethet.
3. Minimális összeolvadás: Ez a módszer több kép pixelértékének minimális értékét veszi figyelembe egyetlen összeolvasztott kép létrehozásához. Ez a módszer megőrzi az egyes képek legalacsonyabb intenzitási értékeit, de más képek információinak elvesztéséhez vezethet.
4. Súlyozott átlagos összeolvadás: Ez a módszer több kép pixelértékének súlyozott átlagát veszi fel egyetlen összeolvasztott kép létrehozásához. Minden kép súlyt kap, amely a fontosságát vagy relevanciáját jelzi, és az átlagolás előtt az egyes képek pixelértékeit megszorozzák a súlyukkal.

4.1. Hőkamerák jellemzői és felhasználásuk

A hőkamerák ipari felhasználása egyre szerteágazóbb minőségi jellemzőik fejlődésének köszönhetően. A FLIR LEPTON megjelenésével már nem csak kézi mérőeszközökkel lehetett akár radiometriás hőképet készíteni, hanem már apró, Gopro méretű kamerával, vagy akár mobiltelefonba integrált eszközzel. Ezeket a szenzorokat többen használták fel radiometrikus kutatási célra, és eljárásokat dolgoztak ki a pontosságának a javítására [13]. Természetesen ezeknek a kameráknak a felbontása elmarad a professzionális eszközökétől (melyek nagyjából 1 megapixel felbontással rendelkeznek), de cserébe sokkal kisebbek, és az áruk is jóval kedvezőbb. Ennek köszönhetően kis méretű merev vagy forgószárnyas repülőgéppel is könnyedén, és viszonylag kis anyagi kockázat mellett lehet légi felméréseket végezni velük, mely kifejezetten alkalmassá teszi kisméretű légi kutató és mentő (search

and rescue) célú felhasználásra [14].

Ilyen komplett szenzor a FLIR DUO R kamera is, mely mérete $41 \times 59 \times 29.6 \text{ mm}$, tömege pedig 65 g . A hőkép felbontása 160×120 pixel, ami önmagában nagyon alacsony, de rendelkezik egy 1920×1080 pixel felbontású RGB szenzorral is. A készülék olyan hybrid kimeneti képet képes előállítani, amelyben az alacsony felbontású képet összefűzi az RGB képből kinyert élekkel, mely segítségével árnyaltabb kimenetet kapunk, könnyedén azonosíthatóak az észlelt objektumok. Természetesen ez nem teljes értékű eredmény, nem helyettesíti a nagyobb felbontású kamerák teljesítményét.

Mivel a mikrobolométer mellett rendelkezik az eszköz RGB szenzorral is, és képes egy időben a két képet egymástól függetlenül, módosítás nélküli RAW formátumban elmenteni, így azok utófeldolgozással alkalmasak megnövelt felbontású, több bemeneti képből álló összetett hőkép megalkotására.

Leginkább a robotrepülőgépes multispektrális térképészet esetében használnak hasonló technológiát, amikor is az elkészített 2D/3D RGB kép mellé UV és/vagy NIR tartományú információt is rendelnek a mérés érdekében [15] vagy éppen a látható és hő tartományú infra sugárzás segítségével vizsgálják a napelemeket, hamis színes RGB-T (RGB-Thermal infrared) 3D pontfelhőket építve róluk [16].

A szenzort a mérete és felbontása miatt jellemzően különféle kisebb berendezések hűtésének, hőeloszlásának vizsgálatára, illetve épületek szigetelésének ellenőrzésére, hőhidak detektálására alkalmazzák. Működési tartománya jellemzően $1\text{-}50 \text{ m}$, melyet a fix optika határoz meg. Ebből következik az egyetlen méréssel feltérképezhető terület nagysága is. Ennél nagyobb terület esetében nem ad megfelelő felbontású eredményt.

RGB szenzorok esetében, mivel egy átlagos kézi kamera is $16\text{-}20$ megapixel felbontással rendelkezik, elterjedt megoldás nagyobb területű objektumok felmérésére a fotogrammetria, mivel ekkora méretű képen a különböző jellemző (feature) detektorok, illetve jellemző kereső (feature matching) algoritmusok megbízhatóan és kis hibával dolgoznak. A megfelelő hardveres erőforrások birtokában rövid utófeldolgozással nagy felbontású, nagy méretű 2D és 3D rekonstrukciót lehet végezni az így bemutatott módon [17] [18].

Sajnos a hőkamera felbontása és a kép részletességének hiánya miatt önmagában az alapján

nem lehet 2D/3D fotogrammetriai illesztést alkalmazni, mivel a 160x120 szürkeárnyaltos képen nem lehet megfelelő számú és minőségű feature pontot detektálni.

Egy olyan új eljárást dolgoztam ki, mellyel a FLIR DUO-hoz hasonló RGB + Hőkamerával rendelkező eszközök esetében mégis jó minőségű, fotogrammetria alapú 3D rekonstrukciót lehet végrehajtani.

4.2. Fotogrammetria alapú 3D rekonstrukció hőszínezéssel

A pontos rekonstrukcióhoz a mérés során több dolgot kell figyelembe venni. A pontos végeredményhez a két szenzort egyazon pontba kellene helyezni. Ez csak akkor kivitelezhető, ha két független eszköz áll a rendelkezésre, és a felmérést időben elkülönítve végzem. A gyakorlatban azonban, mivel e szenzorokat általában robotrepülőgépes hordozón, vagy kézi szkennerként alkalmazom, a szenzorok egymástól egy minimális távolságra vannak elhelyezve. Ez közeli objektum felmérésekor okoz gondot, így számolni kell vele. Szerencsére az általam alkalmazott szenzor esetében az RGB kép a hőkameránál nagyobb területet fed le, így ez a kamera origo hiba kiküszöbölhető az RGB kép elmozgatásával. A két kamera képét a kamera paraméterek alapján kalibrálni szükséges, ami annyit tesz, hogy a torzítást kompenzálni kell, illetve meg kell oldani, hogy a hő és a látható tartományú kép pontosan átfedésben legyen, azaz ugyanazt az objektumot tartalmazza.

Ez azt jelenti, hogy miután a kamera torzítás kompenzálásra került, az RGB kép azon tartományát, amelyet a hőkép nem tartalmaz, le kell vágni. Ezt követően a következő lépés, hogy az alacsony felbontású hőképet felnagyítsuk az RGB-vel azonos méretűre. Az alacsony felbontás miatt az átméretezést super-resolution technikával ötvözve tovább emelhető a létrejövő 3D hőkép termikus felbontása.

Az eljárás alkalmazásához az alábbi peremfeltételek teljesülése szükséges:

- Biztosítani kell a felvételek készítése során az RGB és az IR kamerák (Optikák és érzékelők együttes rendszere) változatlan geometriai és optikai paramétereit. Ez azt jelenti, hogy egy felvételsorozat alatt nem változtatható nagyítás és a kamerák egymáshoz viszonyított pozíciója. Ez a feltétel általában egyszerűen teljesül, mivel éppen az olcsó IR kamerák esetében egy vázba épített, fix fókuszu optikákkal ellátott

szenzorokat lehet megvásárolni.


- Az RGB és az IR képnek azonos területet kell ábrázolnia. Ez a feltétel általában csak utólagos képmanipulációkkal biztosítható. Általában igaz az, hogy az RGB kamera a nagy felbontás mellett némiképp nagyobb területet képez le mint a mellé épített IR kamera. Ennek megfelelően az IR kamera által lefedett területet kell kivágni az RGB képből. Így előállítható olyan RGB-IR képpár melyek ugyanazt a képi tartalmat ábrázolják. Fontos azt látni, hogy azonos tartalom mellett az RGB kép lényegesen részletesebb, azaz nagyobb felbontású kell, hogy legyen mint a hozzá tartozó IR kép.

A fenti feltételek teljesülése esetén létrejött képpárok alkalmasak lehetnek 3D pontfelhő létrehozására. A fotogrammetriai eljárást az RGB képeken alkalmazom, ami által létre jön a hagyományosnak tekinthető 3D pontfelhő, illetve az abból generálható 3D felületmodell. Ezt követően a 3D pontfelhő minden egyes voxeléhez meg kell keresni az RGB síkfotókon a hozzá tartozó pixeleket, ami a voxel színét fogja meghatározni. A voxel színezéséhez azonban nem az RGB képen található színinformációt, hanem az ahhoz a képponthoz tartozó IR képen található pixel színét kell rendelni. Amennyiben az IR kép radiometriás adatokat is tartalmaz (hőmérsékleti adatok is tartoznak az adott IR pixelekhöz), akkor a 3D pontfelhő színezése során a szín információ arányos a vizsgált test adott pontján mért sugárzási hőmérsékletével.


Mivel az eljáráshoz felhasznált képek ugyanarról a tárgyponttól több sík képen is tárolnak adatokat, a fenti módszert ki lehet terjeszteni. Kihasználva azt a tényt, hogy a képeken található azonos tárgypontok kis mértékben egymástól eltérnek (más helyen képződtek le a szenzorokon, illetve kissé eltérő pozícióból képződik le a szenzoron), az azonos tárgyponthoz tartozó pixelek sokasága többlet információt hordoz az egy képen található pixel által hordozott információhoz képest. Ebből következik, hogy a létrehozott 3D modell részletessége elvileg meghaladhatja az egy kép által biztosított részletességet. A szuperrezolúció tehát nem csupán nagyobb pixel, illetve voxelszámot jelent, mint egy egyszerű nagyítás esetében, hanem részletgazdagabb képet, illetve 3D hőmodellt eredményez.

4.3. Fotogrammetria segítségével 3D hőmodell létrehozása

Az RGB képek adatszerkezetét egy háromdimenziós mátrixként reprezentálhatjuk. A szemmel látható kép egy kétdimenziós mátrix, melynek van magassága és szélessége, ahogyan a 4.1. ábrán is látható. A harmadik dimenziót a minden pixelhez rögzített RGB színcsatorna (vektor) adja (4.2).



4.1. ábra. Színes RGB kép 9x8 pixeles felbontásban - (a) ahogyan láthatjuk; (b) ahogyan felépül elemi szinten pixelekből



4.2. ábra. Színes RGB kép 9x8pixeles felbontásban - (a) ahogyan felépül elemi szinten pixelekből; (b) ahogyan az egyes elemi részek (pixelek) reprezentálhatóak adatszerkezeti szinten: R+G+B csatornák

A színes képpel szemben a hőkamera infravörös képe csak egy kétdimenziós mátrix, amelynek van szélessége és magassága, valamint minden egyes pixelén vagy egy 8 bites vagy

16 bites számérték. Ezen számértékek reprezentálják az adott pontban mért hőmérsékleti értékeket.

Az általam készített eljárás alapja az, hogy kihasználom az RGB és az IR kép kapcsolatát. A fotogrammetriai eljárást az RGB képen végzem el, de az eljárás során kiszámított transzformációkat az IR képen is elvégzem. Ez csak akkor lehetséges, ha a két kép egybevágó, azaz ugyanazt a területet tartalmazza [19]. Ebben a fázisban, ahol IR és RGB képek ugyanazokat a területeket reprezentálják, a képek két különböző adatforrásnak tekinthetők [20]. Mivel az RGB és IR képek egybevágósága nem biztosított, az eljárásom első eleme ennek létrehozása [21], [22]. Tekintettel arra, hogy az IR kép kisebb területet tartalmaz, mint az RGB kép, azaz az IR kép tartalma részhalmaza az RGB képnek, az egybevágósági transzformációkat az IR kép paramétereire alapján végzem. Az eljárás során kihasználom a két kamera egymáshoz viszonyított rögzített pozícióját. Ez azt jelenti, hogy nem képi tartalom, hanem előzetes mérések során meghatározott értékek szerinti nagyításokat hajtunk végre az IR képen majd hasonló módon előre meghatározott csonkolásokat végzünk az RGB képen (4. algoritmus)

Algoritmus 4 Színes kép és hőkép egybevágósági feltételeinek létrehozása

```

1: Begin
2: buildingDir ← 'imagestiffimagergb'
3: buildingScene ← imageDatastore(buildingDir)
4: numImages ← CountFiles(buildingScene.Files)
5: for i ← 1 to numImages do
6:   Print('Scaling image ' + ConvertToString(i))
7:   im ← ReadImage(ConvertToString(buildingScene.Files[i]))
8:   temp ← ResizeImage(im, 9, 'METHOD', 'lanczos3')
9:   name ← ConvertToString(buildingScene.Files[i])
10:  WriteImage(temp, name, 'png')
11: end for
12: End

```

Az eljárások eredményeképp létrejönnek pixel méretben és tartalomban is megegyező RGB-IR képpárok. Az IR képen további konverziót hajtunk végre. Az eredeti IR kép 14 bites, amit a konverzió során 8 bitesre alakítok. Ez az átalakítás adatvesztéssel jár. Amennyiben a cél az, hogy a relatív hőmérsékleti viszonyokat jelenítsük meg az ortofotón vagy a 3D modellen, akkor ez az adatvesztés nem okoz lényegi hibát. Természetesen

a radiometriai adatok is elvesznek, ami azt jelenti, hogy a feldolgozott végeredményen hőmérsékletmérésre nem lesz lehetőség. Amennyiben az adatvesztést el kívánjuk kerülni, lehetőség van a 14 bites hőkép 16 bitesre történő kiegészítésére (28 bit). A 2x8 bites hőképi információkat ebben az esetben a fuzionált kép zöld (G) és kék (B) színcsatornáján tároljuk el.

Második lépésben az RGB képet szürkeárnyaltos, de színes képpé alakítom. Ez azt jelent, hogy a színes kép mindhárom színcsatornája azonos pixelinformációkat tartalmaz. Az így előállított szürke kép kék (B) színcsatornájának adatait lecserélem az IR kép adataira. Eredményül létrejön egy fuzionált kép melynek egyik színcsatornája (R) a szürke képet, a másik színcsatornája (B) a hőképet tartalmazza. A zöld színcsatornát (G) nem használom [23]. A szürkeárnyaltos RGB kép (B) színcsatornáján a hőadatok elhelyezését a 5. algoritmus mutatja be.

Algoritmus 5 Színes kép és hőkép fúziójának algoritmus

```

1: Begin
2: numImages  $\leftarrow$  CountFiles(buildingScene.Files)
3: firstFile  $\leftarrow$  ConvertToString(buildingScene.Files[1])
4: for  $i \leftarrow 1$  to numImages do
5:   rgbImage  $\leftarrow$  ReadImage(ConvertToString(buildingScene.Files[i]))
6:   grayImage  $\leftarrow$  ConvertToGray(rgbImage)
7:   flirImage  $\leftarrow$  ReadImage(ConvertToString(buildingScene2.Files[i]))
8:   tempImage  $\leftarrow$  grayImage
9:   tempImage[3]  $\leftarrow$  flirImage
10:  name  $\leftarrow$  ConvertToString(buildingScene.Files[i])
11:  name  $\leftarrow$  Substring(name, 1, Length(name) - 4)
12:  name  $\leftarrow$  Concatenate(name, '.png')
13:  name  $\leftarrow$  ReplaceSubstring(name, 'imagesrgbimage', 'imagesgrayflirfusion')
14:  WriteImage(tempImage, name, 'png')
15: end for
16: End

```

Az algoritmussal kapcsolatos megjegyzések és magyarázatok:

- *rgbImage*: cikluson belül az aktuális színes képet tartalmazza
- *grayImage*: aktuális színes kép szürkeárnyaltos megfelelője
- *flirImage*: adott pozícióban a hőkép értékét tartalmazza

Az általam megalkotott hőszínezés radiometrikus (termometrikus) minőségű, azaz az egyes pontjai pontosan reprezentálják az ott mért hőmérsékleti értékeket. Hivatkozott

irodalomkutatásaim során talált megoldásokban olyan átalakításokat végeztek a bemeneti adatokon, melyek a radiometrikus adatok elvesztéséhez vezettek, innentől kezdve már csak egy egyszerű hamis színes 3D hőmodellről beszélhetünk. Fontos kiemelni, hogy a hőszínezés radiometrikus minőségben nem azonos a hamis színes eljárásokkal.

A speciálisan létrehozott fuzionált kép alkalmas fotogrammetriai feldolgozásra. Kísérleteim során az Agisoft Photoscan szoftvert használtam. Az elkészült 3D modelleket vagy ortofotókat egy utófeldolgozásnak vetettem alá.

Az utófeldolgozás során az általam létrehozott szoftverrel a 3D modell esetén a textúra képeket, ortofotó esetén magát az ortofotót alakítottam át. Ennek lényege, hogy a kék színcsatorna alapján (mivel ez tartalmazza az adott pixel hőmérsékleti információját) a kép teljes színét lecseréltem. Így létrejön egy mesterségesen színezett hőkép, ahol a pixel színe arányos az eredeti felület sugárzási hőmérsékletével. Az átszínező program lehetőséget biztosít a jobb vizuális élmény biztosítása érdekében a hőkép hisztogramjának módosítására. A hisztogram módosításával jobb kontraszt biztosítható, illetve a szem számára láthatóvá tehetők a kis mértékű hőmérséklet-különbségek is. Igaz ugyan, hogy az utófeldolgozás ezen eleme többlet információt nem szolgáltat, az eredmény vizuális élménye jelentősen javul.

A látható (RGB) és hőkamera (IR) képeinek transzformációi során forgatást nem alkalmazok. Ennek oka, hogy feltételezem a két kamera azonos időben bekövetkező expozícióját és azok egymáshoz viszonyított rögzített pozícióját. Lassan mozgó kamerarendszer esetében ez a feltétel általában teljesül. Gyors mozgásoknál (főként kamera elfordulása idején) azonban a hőkamera és a látható tartományú kamera szinkronjának hibája komoly eltéréseket eredményez a rögzített képpárok tartalmát illetően.



4.3. ábra. Színes és hőkép valamint feldolgozás során jelentkező szinkronitási hiba

A 4.3. ábra egy időben “elcsúszott” képpárt és annak fuzionált eredményét szemlélteti. Az ábra bal alsó képe a szürke árnyalatban megjelenített hőképet, a bal felső kép ugyanannak a területnek a színes képét szemlélteti. A 4.3. ábra nagy képe pedig a fent szemléltetett képpár fuzionált képe. Az eredeti képpáron is jól látható, hogy képi tartalmak nem egyeznek. Ennek eredménye a fuzionált képen is jól megfigyelhető. Mivel a fuzionált kép kék színcsatornája tartalmazza a hőkép információit, a forrás és a patak kék színű “szellemképe” jelenik meg. A felvétel éppen a kamera elfordulása idején történt ezért nem csak translációs hanem rotációs eltérés is megfigyelhető. A feldolgozásból az ilyen képeket ki kell zárni.

4.4. 3D hőmodell élkiemelése

A vizuális élmény javítása érdekében a már elkészült hő-színezésű modelleket (3D modell vagy ortofotó) élkiemeléssel javítottam. Az éleket a modelleken fehér színnel jelenítettem meg. Ez jól elkülönül a hőmérsékleti információt tartalmazó színektől és markáns kontúrokkal jobban értelmezhető vizuális élményt biztosít. Az élek detektálása, kiemelése gradiens alapú Mamdani fuzzy következtetési rendszer felhasználásával történt [24]. Első lépésként az éldetektáló algoritmusoknál megszokott módon a szürkeárnyaltos kép gradiens vektora (4.1) került meghatározásra:

$$\nabla f = \left[\frac{\partial f}{\partial x} \frac{\partial f}{\partial y} \right]^T \quad (4.1)$$


Digitális képek esetén a parciális deriváltakat véges differenciával lehet közelíteni:

$$\frac{\partial f}{\partial x} = \lim_{\Delta x \rightarrow 0} \left(\frac{f(x + \epsilon, y) - f(x, y)}{\epsilon} \right) \cong \frac{f(x_{n+1}, y) - f(x_n, y)}{\Delta x} \quad (4.2)$$

A deriváltak konvolúciós maszk alkalmazásával x és y irányban meghatározható. Konvolúciós maszkra számos lehetőség létezik. A szabálybázis kialakítása a következő két GMP (Generalized Modus Ponens) következtetés szerint történt, mely két antecedensből és egy konzekvensből áll:


- Ha I_x értéke zero ÉS I_y értéke zero, akkor az I_{out} legyen fehér,
- Ha I_x értéke nem zero ÉS I_y értéke nem zero, akkor az I_{out} legyen fekete,

ahol I_x az x tengelyhez tartozó gradiens, az I_y pedig az y tengelyhez tartozó gradiens értéke. A kimeneti tagsági függvények folytonos, trapéz alakú függvények, ahogyan a 4.4. ábrán látható. Az eredményként kapott következtetés fuzzy halmaz defuzzifikálására súlypontkeresés módszert használtam (Center of Gravity).



4.4. ábra. Bemenetek és kimenet tagsági függvénye

Az élkimelés után kapott kép és a palettázott hőkép egyesítésének az eredménye a 22. ábrán látható:




4.5. ábra. Fuzzy alapú éldetektálással előállított, kontúrozott hőkép

4.5. Eredmények

A tárgyról készült szín- és hőkép kapcsolatának kihasználásával lehetővé vált a fényképek jó minőségben történő összekapcsolása fotogrammetriai módszerrel. Az eljárás során a hőképekkel azonos tartalmú kivágásokat készítettem, amelyeket a következő fázisban szürkeárnyaltos képekké alakítottam át. A megfelelő hőképet az egyik színcsatorna segítségével a szürkeárnyaltos képhez kapcsoltam, így a fotogrammetriai módszert speciálisan készített, összevont képeken végezték el. A folyamat végén hőképek alapján textúrázást végeztem [25]. A 4.6. ábrán egy családi ház 3D-s modellje látható, amelyet fotogrammetriával készítettem. A textúrához szürkeárnyaltos képeket használtam. Az eljárás alapjául 1920x1080 pixel felbontású képek szolgálnak. A textúrázás a 3D modell adatai alapján történt, hőkamerával, amely a fent leírt eljárással készült. Ennek


eredményeként egy kiváló minőségű 3D termikus modell készült. A hőkamera képeinek felbontása összesen 160x120 pixel. Ezeken a képeken nem lehet elegendő számú jó minőségű jellemzőpontot kimutatni, így fotogrammetriai módszerrel nem kapcsolhatók össze.



4.6. ábra. Szürkeárnyaltos (bal oldalon) és 3D hőkép (jobb oldalon) rekonstrukciója a vizsgált családi háznak

Az épület fotózása során a környezet hőmérséklete -5°C volt. Mivel a fotózás ideje alatt az azt megelőző néhány órában napos volt az idő, a kamera nemcsak a ház hőmérsékletvesztéséből adódó sugárzást, hanem a napsugárzásból eredő visszaverődést is érzékelte, valamint elnyelt energiájának kisugárzása hősugárzás formájában a hőképen megjelent [26]. Ez jól látható az épület előtti fekete tárgyakon (4.6. ábra). A hőképen (4.6. ábra) ezek melegek, bár ezek nem fűtött tárgyak, csak fekete fóliával borított kerti bútorok védik őket az időjárástól.

Egy faház színes modellje a 4.7. ábrán látható. A modellalkotás a 4.5. ábrán bemutatott kőházhoz hasonló módon történt. A képen észrevehető, hogy a kontúrok elmosódnak; a vizuális élményt tekintve a kép meglehetősen zavaró a szem számára. Mivel a megfigyelt faház nem volt fűtve, ezért hőképe a külső sugárzás elnyeléséből származó hősugárzásból, valamint a közvetlen hősugárzás visszaverődéséből adódik. Ezért a falak melegebbek, mint a ház ablakai. A 4.7. ábrán a faház 3D modelljét az utófeldolgozás során kontúrokkal láttam el. A fehér színnel kiemelt élek kevés további információt hordoznak. Ebben az esetben a házra tervezett napelemek a kontúrok felhordása során válnak láthatóvá.



4.7. ábra. Faház 3D hőkép rekonstrukciója és élkiemelt változata a modellnek

A kontúrokkal ellátott modell azonban kontrasztosabbnak tűnik: kellemesebb látványt nyújt a szemnek. Az éljavítás alkalmazása ezért könnyebben értelmezhető eredményt ad a 3D hőképeknél. Fuzzy éljavítást alkalmaztam, mert a Matlab alkalmazáscsomag használata során az adatok vizuális élményének javítására ez volt a legjobb eljárás [27] [28].

Az objektumról készített hő- és RGB-képek kapcsolata alapján a képek összekapcsolása fotogrammetria segítségével lehetővé vált. Az eljárás RGB-képekből a hőképek méretével megegyező vágásokat hozott létre, majd ezeket a képeket szürkeárnyalatossá alakította. Az eljárás a szürkeárnyaltos kép egyik csatornáját használta fel a hőkép megjelenítésére, így láthatóvá váltak az objektum egyes területeinek részletei és hőinformációi. Az ilyen képeken most már azonosításra alkalmas részek találhatók, amelyek alapján az összeillesztés megtörtént, akár fotogrammetriai módszerrel is.

Az eljárás hatékonyságát épület és személyautó 3D-s modelljén is vizsgáltam. A hatékonyság tesztelésének alapjaként 1920x1080px felbontású képeket használtam. A fent részletezett eljárással az elkészített képekkel textúrázás történt, így egy nagy felbontású 3D modell készült, melynek hőinformációit kis felbontású képekből nyertem, mivel a hőkamera felbontása 160x120px. A kidolgozott eljárás minden eleme a Matlab programmal valósult meg.

2. Tézis

Megalkottam egy eljárást, mely segítségével költséghatékonyan és nagy felbontással lehet valós objektumok hőmodelljét létrehozni. Az eljárás bemenetét alacsony felbontású, 7.5-13.5

μm tartományban készült, rossz minőségű hőképek alkotják, melyekből képes voltam a szenzor eredeti felbontását magasan meghaladó felbontású, 3D-ben értelmezhető kimenetet prezentálni. A fúziós algoritmus a bemeneti 160x120 pixel felbontású képnél kb. 10-szer nagyobb felbontású kimeneti képet állított elő úgy, hogy az infravörös tartományban dolgozó alacsony felbontású kép egyes elemi részeit megfeleltette egy nagy felbontású, színes, RGB csatornákkal rendelkező kép bizonyos tartományainak. Az így létrejött kimeneti képekből már létrehozható a valós objektumot/tárgyat a virtuális térben reprezentáló megfelelője. Az általam kidolgozott és megvalósított eljárás a következő jellemzőkkel rendelkezik:

1. a fúziós algoritmus működéséhez szükség van a nagy felbontású színes képre és az alacsony felbontású hőképre, melyek páronként azonos nézőpontból készültek,
2. a kimenetként előálló képek alkalmasak 3D objektum építésére,
3. a- a módszer lehetővé teszi, hogy alacsony költségvetéssel nagy felbontású hőképek vagy térmodellek készüljenek.

Tézishez kapcsolódó tudományos közlemények: [T3][T4][T5]

5. fejezet

3D pozíciókban mért 5D

légszennyezettségi adatok feldolgozása

A települések légszennyezése rohamosan növekvő problémát jelent. Mindaddig, míg egy adott településen a szennyezés mértéke és összetétele számszerűen nem ismert, nem lehet hatékony ellenintézkedéseket tenni. A légszennyezés nem statikus, azaz időben nagy mértékben változó. A kísérleti eljárással ki lehet mutatni egy település légszennyezőinek térbeli és időbeli eloszlását, valamint annak kémiai összetételét.


A légszennyezők alkotórészei megmutatják, hogy egy adott területen milyen jellegű a károsanyag kibocsájtás. Mivel a károsanyag forrása lehet üzemi emisszió vagy lakossági fűtésből származó emisszió, esetleg gépjárművek okozta károsanyag kibocsájtás, a védekezés vagy a károsanyagok mennyiségének csökkentése érdekében meghozandó intézkedések is a források jellegétől függően változhatnak.

Amennyiben a károsanyagok összetevői a lakossági fűtésből származó jellemzőkre utalnak, úgy a fűtésre használt anyagok szabályozásában keresendő megoldás. Nagyon sok –főként gazdaságilag elmaradott– településre jellemző, hogy a lakosság fűtésre meg nem engedett hulladékot –PET palack, gumi, rongy stb.– használnak. Ennek a ténynek számszerű kimutatása jogi intézkedések alapját képezheti.

Üzemi szennyezettségre utaló jelek esetén természetesen a szennyező üzem technológiai paramétereinek betartatása vagy szigorítása jelent eredményt. Mivel ezek súlyos anyagi

terhet jelentenek az adott üzemre nézve annak kikényszerítése is csak megalapozott mérési eredmények birtokában lehetséges.

A járműforgalom korlátozásának is csak akkor van társadalmilag elfogadható eredménye, ha a légszennyezés jellege alapján egyértelműen igazolható a forrás. Kutatásom elején szennyezési értékek mérésével foglalkoztam, amelyhez hasonlókat mutat be a 5.1. ábra [29].



5.1. ábra. CO koncentrációs értékek városi közlekedés során - (a) városi útvonal térképre helyezve és a mért értékeknek megfelelő magasságú 3D vonaldiagram; (b) mért értékek GPS pozíciókhoz rendelt

A kidolgozott mérési eljárás alkalmas pontos térbeli és időbeli mérésekre különféle szennyező komponensek esetében. A kísérlet során jellemzően CO, CO₂, NO, NO₂, O₂, O₃ mérések végzése történt. Minden mérési ponthoz térbeli koordináta és időbélyeg is tartozik. Az eredmények offline feldolgozással a méréseket követően lettek feldolgozva. A térbeli eloszlás a források pontos lokalizációját is lehetővé teszi. A módszer alkalmas egy-egy időszak szennyezettségének archiválására is, így utólag is lehetőség van az adott időszakra vonatkozó megállapítások, esetleges felelősségre vonások megtételére.


A sűrűn lakott települések légszennyezése elleni küzdelem hatékonyságát a szennyező anyagok minőségi jellemzőinek és azok térbeli és időbeli eloszlásának pontos meghatározásával hatékonyan lehet növelni [30] [31]. A hagyományos mérési módszerek általában ad-hoc jellegűek. Ez azt jelenti, hogy erős szennyezés gyanúja esetén hordozható eszközökkel kivo-

nuló csapatok végzik el egy szűkebb területen –sok esetben egyetlen helyszínen– a mérést, aminek eredményét aztán általános érvénnyel igyekeznek felhasználni. Fejlettebb területeken előfordulnak telepített mérő műszerek, melyek folyamatosan mérnek és adataikat rendre értékelik a szakemberek. Ezekkel a műszerekkel már lehet idősoros adatokat nyerni és mivel helyzetük is ismert az adatokhoz koordináta is rendelhető. Így lehetővé válik a szennyezők időbeli és térbeli eloszlásának mérése, de sok esetben a mérőhelyek csekély száma nem tesz lehetővé pontos térbeli elemzést, így a szennyező anyagok forrásának pontos lokalizációját sem.

Számos nagy városban a telepített mérőállomások adatai alapján rendelnek el szmogriadót vagy forgalmi korlátozást, amely jellemzően általános érvényű az adott településre nézve. Természetesen ezen módszerek alapján meghozott rendelkezéseknek van pozitív hatása, de a hatás mértéke, illetve a módszer hatékonysága megkérdőjelezhető. Könnyen elképzelhető, hogy részleges forgalmi korlátozásokkal –például a nagyobb teherforgalmat bonyolító útszakaszok lezárásával, egyes területeken csak a nehézgépjárművek korlátozásával vagy más, nem mindenkit érintő tiltásokkal– is elérhető az általános tiltásokkal egyenértékű javulás vagy akár azoktól nagyobb mértékű pozitív hatás is. Ehhez azonban jól kell ismerni a szennyező anyagok forrását és minőségi jellemzőit, valamint a szennyezés időbeli eloszlását.


A megfelelő területi eloszlás méréséhez nagyon sok telepített mérőállomásra lenne szükség, melyek kialakítása igen költséges lenne. További hátránya a sűrűn telepített mérőállomásoknak karbantartása, így ez az út jelen technológiai szint mellett nem járható.

Egy komplex járműre telepített mérőmodul karbantartása és üzemeltetése csupán egyetlen egységnyi folyamatos karbantartási költséget jelent. Amennyiben megoldható, hogy a jármű kellő sűrűséggel és időben végig járja az adott települést, akkor egy vagy esetleg néhány ilyen mozgó mérőállomás elegendő lehet nagy sűrűségű mérési adatok előállításához. A megfelelő sűrűség és idő pontos meghatározásához a Magyarországon szabadalmaztatott [31], robotrepülőgépekhez kifejlesztett [32] egységet vettem alapul.



5.2. ábra. CO koncentrációs értékek a teszt teljes ideje alatt, idősoros diagramon ábrázolva

A modulban alkalmazott elektrokémiai szenzorok beállási ideje átlagosan 60 másodperc. Feltételezve, hogy az emisszió egy adott időszakban (1 órán belül) közel állandó, a mérő jármű vagy járművek bejárási idejére támasztott követelmény is 1 óra. Ez azt jelent, hogy a teljes vizsgált területről egy órán belül rendelkezésre álló mérési adatokat egy időegységhez rendeltnek tekintjük. Természetesen a mérések során az adatokhoz rendelt időbélyegek a pontos mérési időpontokat tartalmazzák. A szenzorok átlagos mérési ideje korlátozza a mérő jármű sebességét. Az elméleti megfontolások és a mérési tapasztalatok alapján [33] a jármű sebessége $10\text{--}15\text{ m/s}$ között, közel állandó kell, hogy legyen. A modul mérési sebessége (a mérések ismétlési frekvenciája) 1 Hz , ami 10 m/s haladási sebesség mellett 10 méteres raszterben történő mérést eredményez. Természetesen földi jármű esetében az egyenletes 10 méteres raszter nem valósítható meg. A közlekedésre alkalmas utak geográfiai elhelyezkedései adják a mérések átlagos sűrűségét, de az egyes útszakaszokon a mérések távolsága 10 méter lesz.



5.3. ábra. CO koncentrációs értékek a teszt teljes ideje alatt, idősoros diagramon ábrázolva

A fenti mérési eredményeket a mérés pontos körülményeivel (sebesség, koordináta) korrigálom majd eloszlástérképet állítok elő. Minden korrigált mérési adat további, a mért szenzor beállási jellemzői alapján további korrekcióra kerül, majd az így kapott adatokból mért jellemzők szerint külön-külön egy eloszlásra jellemző pontfelhő készül. A szennyezettség mértékével arányos pontfelhők (minden mért összetevőnek saját pontfelhője van) a terület 3D modelljére vetítve kerülnek megjelenítésre. Az így létrehozott vizuális adathalmaz segít a szennyezők eloszlásának pontos feltérképezésében, a források településhez viszonyított lokalizációjában és a megelőző vagy kárcsökkentő intézkedések meghozatalában.

A mérések időszakosan ismételhetők és az így előállított 3D modellek idősoros lejátszásával a szennyezők aktuális terjedése, feloszlása, esetleges sűrűsödése (megrekedése valamely szélről védett területen) megfigyelhetővé válik. Az idősoros elemzések –amennyiben 0-24 órás megfigyeléseket végzünk– a szennyezők napszak szerinti változásaira is rámutatnak. Ez az információ további segítséget jelenthet a hatékony és a lakosságot érintő legkisebb szükséges megszorítási intézkedések meghozatalához.

5.1. A mérő egység felépítése

A mérő egység tervezése során kiemelt szempont volt, hogy kellően rugalmasan lehessen szenzorokat cserélni vagy további szenzorokkal bővíteni. Ez a bővítési, cserélési lehetőség biztosítja, hogy a modul akár ipari környezetben (vegyi vagy más légköri szennyezőket kibocsájtó üzemek) vagy urbánus környezetben egyaránt alkalmazható legyen. A szenzorok gyártó által kalibrált és hitelesített egységek melyeket a gyártó által előírt periódusokban újra hitelesíteni, illetve cserélni kell. Így a szenzorok adatai azonnal hitelesnek tekinthetők [34]. A szenzorok által szolgáltatott adatokat egy mikrokontroller fogadja és rögzíti egy hozzá csatlakoztatott memóriakártyára. A modul további bemenetét képezi egy GPS, amely 10Hz adatismétlési frekvenciával szolgáltatja az eszköz pillanatnyi pozícióját.

A 10Hz -es adatfrekvencia meghatározza a szenzormodul legnagyobb sebességét, ami mellett még rögzíthető a mért szennyezők térbeli helyzete. A mikrokontroller a gázszenzorok adataihoz automatikusan hozzárendeli a méréshez legközelebbi időpontban kapott GPS koordinátát. A modul rendelkezik egy valós idejű órával is, amely a mérési adatok időbélyegét biztosítja. Így egy mérési pontot egy 5 elemű tömb ír le, amely tartalmazza a mért szennyező koncentrációját, a mérés idejét és a mérés térbeli koordinátáit.

A teljes mérő egység egy nyomtatott áramköri lapon lett elhelyezve. Ez az alaplapp tartalmazza a mikrokontrollert, a memóriakártyát és a valós idejű órát. A szenzorok modulárisan csatlakoztathatók az alaplaphoz. A mérő egység rendelkezik két soros porttal is, amely közül az egyik lehetőséget biztosít további egységekkel történő kommunikációra így például a tesztelések idejére egy PC-re kötve azonnal megjeleníthető az összes mért adat. A második soros port a GPS modul csatlakoztatását teszi lehetővé.

A mérő egység a hozzá kapcsolt GPS modullal soros porton keresztül, szabványos NMEA mondatokkal kommunikál. Így néhány nem túl erős megkötés betartása mellett számos GPS készülék alkalmazására nyílik lehetőség. Fontos, hogy a kiválasztott GPS készülék városi környezetben is biztosítson legalább 3 méteres pontosságot, valamint legalább 10Hz -es adatismétlési sebességet. Az alacsonyabb adatfrekvenciával rendelkező GPS készülékek esetében a jármű haladási sebességét csökkenteni kell, hogy a mért adatok kellő pontosságú koordinátával legyenek ellátva. A lokalizációs pontosság jelentős romlása

esetén a szennyezők eloszlását reprezentáló pontfelhő torzul. Ez a torzulás elsősorban az emisszió forrásának pontos lokalizációját hiúsítja meg és csak másodsorban van érdemi kihatással a teljes területre vonatkoztatott szennyezettségi térképre.

A mérőegység beépítése során ügyelni kell arra, hogy a szenzorokat a mérés időtartama alatt mindig szabad levegő érje. Fosszilis energiahordozóval hajtott jármű (például benzin, gázolaj) esetén ügyelni kell arra, hogy a mérést a jármű saját emissziója ne zavarja meg. Ezt alapvetően úgy lehet biztosítani, hogy a mérő egységet a kipufogó kivezetésétől a legtávolabb úgy helyezzük el, hogy a friss levegő először a szenzorokat érje és a kipufogó rendszerhez csak ezt követően érkezen. Természetesen itt is fontos a jármű folyamatos előre haladása. Tartós állás vagy tolatás során rögzített adatokat ki kell zárni a későbbi feldolgozásból, mert azok értéke nem összemérhetők a normál mérési körülmények során rögzített adatokkal.

5.2. Mért adatok kiegészítése

A számomra elvárt eredmény eléréséhez nem elegendőek önmagukban a mért értékek az adott koordináta pontokban, azokat a térben elhelyezve, illetve a domborzathoz viszonyítva kell vizsgálnunk, melyhez elengedhetetlen a megfelelő interpolációs eljárás alkalmazása [35]. Az interpoláció egy jól ismert matematikai módszer, mely a függvény nem ismert értékeire az ismert értékek alapján ad közelítést. Általánosan értelmezve a függvény két számhalmaz között fennálló kapcsolatra ad megoldást. A kapcsolatrendszer megadásához a két leggyakoribb módszer a képlet és a grafikon. A függvény alapján az értelmezési tartomány bármely értékéhez egyértelműen hozzárendelhető az értékkészlet egy-egy eleme. Vannak esetek, melyek során a két számhalmaz közötti kapcsolatot csak sejtjük, de nem ismerjük a kapcsolatot végtelen számú elemre definiáló függvényt. Ez esetben a véges számú megfeleltetés alapján feltételezzük, hogy bármely más, az értelmezési tartományba eső, de nem definiált értékre is az ismert megfeleltetés használható. A legtöbbször a valós függvények ábrázolásakor is ezt a metódust követjük, ugyanis az értelmezési tartomány és az érték készlet közötti megfeleltetések gyakorlati szempontból csupán mintavételezésnek tekinthetők. A mintavételezett értékek közé eső további értékek megfeleltetése csak

interpoláció segítségével lehetséges.

A gyakorlati mintavételezési esetekben az interpoláció két célra is használható. Egyrészt, ha az értelmezési tartomány olyan értékét választjuk, melyhez nem tartozik gyakorlati mérés, akkor ehhez az értékhez a hasonló értékekhez mért adatok alapján becsülünk mérési eredményt. A másik cél az lehet, hogy adjunk egy általános modellfüggvényt, mely pontosan illeszkedik a mért értékekhez és a feltételezés szerint kellően követi a valóságban létező, de még nem mért értékek vonalát. Ha a modellfüggvény egy szűkebb tartományát egyértelműsíteni szeretnénk, akkor azon tartományon további mérésre lehet szükség. Fontos, hogy az értelmezési tartományon belüli mért értékekre adott modell az interpoláció, míg a függvény értelmezési tartományon kívüli kiterjesztése az extrapoláció.

Matematikai értelemben interpoláció során célunk az $f(x)$ függvény alakjának egy $i(x)$ függvénnyel való minél pontosabb megközelítése úgy, hogy a közelítő függvény biztosan áthaladjon az ismert pontokon, azaz elégítse ki az $y_i = i(x_i)$ feltételt.

Az interpolációs módszerek több osztályba sorolhatók. A közelítési függvény típusa alapján lehet:

- Polinomiális: amikor a közelítő függvények polinomok. Interpoláció segítségével n különböző számpárra illeszthető $(n - 1)$ fokú polinom, amely átmegy a mért pontokon [36].
- Trigonometrikusak: amikor a szinuszos és koszinuszos függvények segítségével interpolálunk.
- Racionális: két polinom arányával [37].

Attól függően, hogy milyen más tulajdonságokkal szeretnénk felruházni a közelítő függvényt, az interpoláció lehet:

- Lokális: ha az $i(x)$ közelítőfüggvény meghatározásakor az x közelében fellelhető néhány pontot vesszük figyelembe.
- Globális: ha az összes rendelkezésre álló (x_i, y_i) pontot felhasználjuk.
- Spline: ha elvárjuk a közelítő függvény folytonosságát. Lokális módszer, mely globális simaságot biztosít a közelítőfüggvénynek.

A jelenlegi értekezésemben használt MATLAB szoftveres eszköz több interpolációs módszert

is ismer.

Lineáris interpoláció

A lineáris interpoláció a legegyszerűbb interpolációs módszer. Lényege, hogy az egymás után következő pontokat egyenessel kötjük össze, tehát elsőrendű polinomokat használunk. Egyszerű módszer, végrehajtási időt tekintve gyors. Az általa adott megközelítés durva, így nagy eltéréseket eredményezhet az utólagos mérésekkel összehasonlítva, de bizonyos felhasználásnál jó minőségű kimenet érhető el vele [38]. Amennyiben a mintavételezés kellően sűrű, akkor jól használható módszernek tekintem.

Polinom-görbe interpoláció

Ha a függvény értéke bizonyos pontokban adott, akkor ezzel a módszerrel az értékek megőrzése mellett sima futású függvény illeszthető rájuk. A spline függvény több szakaszból van összeállítva úgy, hogy a szakaszok határait a megadott pontok határozzák meg [39].

Legközelebbi szomszéd interpoláció

A legközelebbi szomszéd interpoláció szintén egyszerű módszer. Minden ismeretlen ponthoz a hozzá legközelebb eső, ismert pont értékét rendeli. Végrehajtási időt tekintve gyors. Az általa adott értékek nagy eltéréseket fognak tartalmazni az utólagos mérésekkel összehasonlítva. Nem generál új értékkészlet adatokat.

Természetes szomszéd interpoláció

Jelen értekezésben a fenti interpolációs technikáktól különböző módszert alkalmaztam a nagy mennyiségű adat interpolálásához. Ezen módszer során a mért adatpontok Thiessen-polygonhálóját (avagy Voronoi cellák) kell meghatározni. Ezután meg kell vizsgálni, hogy a kérdéses adatpont hozzáadásával hogyan módosulnak a polygonok. Az interpoláció során

minden szomszédos adatpont értéke számít, a hozzájuk tartozó súlytényezők arányosak az értékükkel. Az eljárás enyhén rászteres, de nagy vonalakban reális interpolációt tesz lehetővé. Fő előnye az egyszerűsége és a gyorsasága, melynek köszönhetően sima felületi rekonstrukciót (leképezést) lehet elérni [40], így számomra a leginkább alkalmas számítási igényes nagy adathalmazok esetén.

Voronoi-diagram

Legyenek adott a térben az

$$P = \{p_1, p_2, \dots, p_n\} \quad (5.1)$$

ismert pontok. A Voronoi-diagram egy olyan tesszeláció, amely minden pontnak egy egyedi Voronoi-cellát rendel hozzá. Egy pont p_i Voronoi-cellája így definiálható:

$$V(p_i) = \{x \in R^d \mid d(x, p_i) \leq d(x, p_j), \forall j \neq i\} \quad (5.2)$$

ahol $d(x, p)$ az euklideszi távolság két pont között.

Az interpolációs formula az alábbiak szerint írható le: Legyen p^* az új pont, amelyre az interpolációt szeretnénk elvégezni.

- Hozzáadjuk az új pontot a Voronoi-diagramhoz és új cellák jönnek létre
- A szomszédos ismert pontok p_i Voronoi-cellái módosulnak, és kiszámítjuk a változások területeit vagy térfogatait.

Definiáljuk a súlyokat:

$$w_i = \frac{V_i}{\sum_j V_j} \quad (5.3)$$

ahol:

- V_i az eredeti pont p_i Voronoi-cellájának változása, amikor p^* -t beillesztjük
- $\sum_j V_j$ az összes érintett szomszédos pont cellaváltozásainak összege.

A becsült érték pedig:

$$f(p^*) = \sum_{i \in S} w_i f(p_i) \quad (5.4)$$

ahol:

- $f(p^*)$ az új pont interpolált értéke
- S a természetes szomszédok halmaza
- w_i az előbb definiált súly.
- $f(p_i)$ az ismert pontok értékei.


5.3. Szennyezési térkép

A káros anyag kibocsájtás térbeli detektálásához több mérést végeztem. Egy adott magyarországi kisközségben hajtottam végre több felmérést. A mérőmodult felszereltem egy jármű tetejére, majd a településen egy rögzített útvonalon egymás után három kört mentem. A felmérés nagyjából állandó, $10m/s$ sebességgel történt. A mért adatok CO, NO, NO₂, O₂ és O₃ volt, hasonlóan mint [41] és [42] értekezésekben.

A mérés alatt a környezeti hőmérséklet $1,5-2^\circ C$. A felmérést naplemente után végeztem, amikor jellemzően a lakosok már fűtenek otthonaikban. A községben a fűtés jellemzően gáz, illetve szilárd tüzelésű kazánokkal történik. A szilárd tüzelésű kazánokban nagyrészt fával fűtenek, elvétve feketeszénnel vagy egyéb anyagokkal.

A problémát a szilárd tüzelésű kályhák esetében a tűzre juttatott hulladékok jelentik (szeméttégetés), amely e nélkül is, csupán a szilárd tüzelés miatt nagy mértékű légszennyezést eredményez, mint ahogyan azt [43–45] is bemutatták. A méréseknek köszönhetően térképen vizualizálhatóak a különböző mért értékek, így amennyiben a mérés alatt kimutatható jelentős ugrás az értékek közül, így a szennyezőanyag forrása lokalizálható.

A mérések 1mp-ként történtek, így nagyjából egy $10m$ -es rasztert alkotnak a mérési pontok az úthálózatnak megfelelő helyeken. Ahhoz, hogy megfelelő részletességű szennyezettségi térképet kapjak, a mért pontokat össze kell vetni, amelyhez natural neighbour alapú interpolációt alkalmaztam. Ezzel az eljárással, amennyiben a felmérés során több párhuzamos, és egymásra merőleges utcán is végig tudunk haladni, megfelelően részletes és pontos szennyezőanyag eloszlás térképet (5.4. ábra) tudunk készíteni.




5.4. ábra. Idősoros szennyezési térkép - (a) első felmérés; (b) második felmérés; (c) harmadik felmérés

Mivel a méréseket egymás után szüneteket közbeiktatva végeztem el, így kimutatható a szennyezés időbeni változása is, nem csak a pillanatnyi érték. Így kiküszöbölhető pl. a forgalomból adódó hiba is. A szenzort hordozó jármű előtt amennyiben pl. egy kevésbé környezetbarát jármű halad, úgy az képes a mérést érdemben befolyásolni. Az idősoros adatokat vizsgálva kimutatható, hogy mely helyen magas folyamatosan egy adott szennyezőanyag, tehát nem csak a begyűjtés során fellépő elégtelen égéskor keletkező szennyezőanyagot mutattam ki, hanem folyamatos szennyezőanyag légkörbe juttatásról (szándékos környezetszennyezésről) van szó. A szennyezőanyagokat nem csak 2D-ben tudjuk vizsgálni, hanem a domborzati viszonyokat is figyelembe lehet venni. A Shuttle Radar Topography Mission (SRTM) [46] NASA mission eredményeinek köszönhetően többek között Magyarország digitális domborzatmodellje (DEM) is ingyenesen elérhető 3 *arc second* felbontással $1 \times 1^\circ$ -os rasterben [47].

A felmért terület határait kiszámítva a szeletből ki lehet emelni a releváns domborzati koordinátákat. Sajnos ez a 3 *arc second* felbontás a kis méretű ($1\text{-}2\text{ km}^2$) területek esetében túl alacsony.

Ahhoz, hogy a szennyezőanyagok eloszlását érdemben lehessen összevetni a domborzati viszonyokkal, így a Digitális Magassági Modellt (Digital Elevation Model – DEM) is interpolálni szükséges. Ehhez a művelethez a legalkalmasabb natural neighbor és cubic interpolation, amelyik a legjobb eloszlást adja esetünkben [48]. Ezek után a szennyezettségi térkép és a domborzati viszonyok összevethetők.



5.5. ábra. A CO kibocsátás átlagértékei. Szennyezési forrás nyíllal jelölt

Ahhoz, hogy a szennyezőanyagok eloszlását érdemben lehessen összevetni a domborzati viszonyokkal, így a Digitális Magassági Modellt (Digital Elevation Model – DEM) is interpolálni szükséges. Ehhez a művelethez a legalkalmasabb natural neighbor és cubic interpolation, amelyik a legjobb eloszlást adja esetünkben [48] Ezek után a szennyezettségi térkép és a domborzati viszonyok összevethetők.

5.4. Eredmények

A szennyezettségi térkép vizsgálata egyértelműen kimutatta az idősoros vizsgálatok alapján, hogy a felmért terület bal alsó régióján (5.5. ábra) található a légköri szennyezés lokális gócpontja. Ez alapján feltételezhető (mivel minden felmérésen szignifikánsan kiugró értéket mutatott a szenzor az adott koordinátánál), hogy az ott lakók tiltott szennyező anyagokkal fűtenek. A vizsgálatomban megalkotott eljárás felhasználható egyértelműen a szennyezőanyagok forrásának beazonosításakor, és az alapja lehet egy büntető eljárásnak. Jelen értekezésben bemutatott eljárással képes vagyok kimutatni, hogy a légszennyezés nem statikus, azaz pillanatnyi mérések nem megfelelően szolgálják a környezetvédelmi célokat. A légszennyezés térben és időben is változik, ezért a hagyományos, telepített légszennyezési mérőpontok fals eredményeket adhatnak a valósággal szemben. A légszennyezés egyes kémiai összetevői szintén nagy változatosságot mutatnak a szennyező forrásoktól való távolság alapján. A szennyező anyagok kémiai összetétele alapján következtetni tudok

a szennyezés jellegére. Kimutattam, hogy a vizsgált település mely részén használnak téli fűtésre olyan anyagokat, melyek alapvetően nem legális fűtési módszerekre engednek következtetni. A mérések időbélyeggel és pontos koordinátákkal lettek ellátva. Ezen adatok alapján volt lehetőség az időben és térben is változó szennyezés meghatározására, melyet kizárólag az uralkodó széljárás módosíthatott az egyes felmérési ciklusok között. Utóbbi természetesen a mérés alapvetéseit nem módosította, így az értékek a mérnöki számítások elvégzésére alkalmasak voltak. A számításokat követően olyan 2D szennyezettségi térképet állítottam elő, mely látványosan reprezentálja az adott terület szennyezettségét.

3. Tézis

Megalkottam egy olyan eljárást, melynek segítségével lokális légszennyezettség mérése lehetséges alacsony tömegű, nagy érzékenységű, UAV-ra szerelhető szenzorok segítségével. A felmérni kívánt területet lefedő útvonal valós időben adaptívan tervezhető. Az eljárás eredményeként a 3D pozíciókhoz nagy mennyiségű 5D adat rendelhető. Az általam kidolgozott és megvalósított eljárás a következő jellemzőkkel rendelkezik:

- 1. az eljárás képes a szennyezés forrásának detektálására,*
- 2. a rendelkezésre álló 3D pozíció adatok segítségével a felmért terület légi jellemzőinek vizualizációja lehetséges,*
- 3. többszöri felmérést követően a szennyezés szóródása, terjedése kimutatható az idő függvényében.*

Tézishez kapcsolódó tudományos közlemények: [T6]

6. fejezet

Kültéri gamma-dózisoszlás mérése multikopterrel

Térinformatikai módszerek alkalmazásával lehetőség nyílik a hagyományos értelemben véve képet nem alkotó detektorok segítségével egy meghatározott területről dóziseloszlás képet készíteni. A terület síkbeli dóziseloszlás fedvényének előállításához szükség van a terület felett egyenletes raszterben diszkrét sugárásmérésekre és ezen mért értékekhez a síkbeli koordináták hozzárendelésére. Feltételezve, hogy a mért sugárzás nem mutat a mérési helyek között ugrásszerű változást, a mért értékek interpolációjával elkészíthető a kívánt dóziseloszlás fedvény. A fedvény kalibrációjához a mérési pontok koordinátáit lehet felhasználni. A kalibrált és georeferált fedvény alkalmas egy területen elrejtett vagy elvesztett sugárforrás detektálására és lokalizálására. A kidolgozott eljárás előnye, hogy kisméretű multikopterrel elvégezhető a mérés, így az költséghatékonyan és széles körben alkalmazható. A kisméretű multikopterek repülési ideje erősen korlátozott, így különösen fontos a mérés hatékonyságának növelése. A kísérletek során a mérési eljárás vonatkozásában történt több módszer gyakorlati összehasonlítása. Hasonló módon a mérési tapasztalatok alapján három fő lépésben történt a detektorrendszer továbbfejlesztése és tesztelése. A fejlesztések során sikerült egy olyan detektorrendszert kialakítanom, amely összes tömege *500gramm* beleértve a detektort legalább 120 percen át működtetni képes akkumulátort. Az eszköz átlagosan 30 esemény/*perc* detektálására képes *0,8ms*

háttérsugárzás esetén. Kísérletekkel sikerült igazolni, hogy a rendszer 10m terepszint feletti pásztázó repüléssel szignifikánsan képes kimutatni $300\mu Sv h$ aktivitású forrást.

A gyakorlatban fontos és hasznos egy adott terület sugárzáseloszlásának ismerete. Ilyen terület például egy átmeneti nukleáris hulladéktározó, ahol pontosan és gyorsan szükséges kimutatni az esetleges szivárgást, vagy olyan laboratóriumok szellőzői és azok környéke, ahol izotópos preparátumokkal folynak munkák és valamilyen előre nem látott hiba okán a preparátum elszennyezi a szellőzőt. Ekkor szintén nagy jelentőséggel bír a szennyezés mértékét és pontos helyét kimutatni képes rendszer. Hasonlóképpen hatékony ellenőrzést tesz lehetővé egy balesetet szenvedett nukleáris létesítmény monitorozásában az adott területről időközönként készített sugáreloszlási térkép.

Drónokra szerelt sugárzás érzékelőkkel kísérletek számos esetben történtek. Az [49] irodalomban közzétett értekezés szerint szcintillációs detektort alkalmazva gamma spektrumot készítettek a kutatók, így lehetőség nyílt a sugárforrás anyagának meghatározására is. A kísérlet során szűk (80 x 40m) területet vizsgáltak 1m/s sebességű repüléssel, több magasságon.

Egy másik kutatás eredménye szerint [50] látható tartományú kameraképpel kombinált sugárzási képet készítettek, így a sugárforrás helye a képre vetítve jelent meg ami nagymértékben megkönnyítette a felfedezett forrás megtalálását. A sugárzás detektálására itt is szcintillációs detektor került beépítésre, amivel a kísérleti minta felett 1,5 méterre kellett repülni.

Egy feltételezett katasztrófát szimulálva készítettek kutatók robotrepülő (UAV) és földi robotjármű (UGV) kooperációjával kialakított sugárforrás felderítő rendszert [51]. A projekt lényege, hogy a repülő eszközzel leszűkítik a fellelt sugárforrás helyét majd az adatokat átadva a földi járműnek az pontosan lokalizálja azt. A kísérletek során szintén szcintillációs detektorral történt a sugárzás kimutatása.

Számos további kutatási eredmény ismert melyek során robotrepülőgépre szerelt sugárzás érzékelővel egy adott területről sugárzási képet készítettek [52–54]. Ezen kísérletek során jellemző módon szcintillációs detektor vagy félvezető alapú sugárdetektort alkalmaztak. A szcintillációs detektorok relatíve nagy tömegűek, így az értékes repülési időt jelentős


mértékben csökkentik. A félvezető alapú detektorok ugyan könnyűek, de magas áruk mellett érzékenységük nem haladja meg a hagyományos (szcintillációs vagy gázionizációs) detektorok érzékenységét.

A kisméretű robotrepülőgépekkel végzett felmérések egyik jelentős problémája magának az eszköznek a korlátozott repülési ideje. A fellelt irodalmak rendre szűk kísérleti területeket jelölnek meg ami megfelel az alkalmazott hordozó repülési idejének. Természetesen nagyobb területek is felmérhetők, de ezeket csak több felszállással, azaz akkumulátor cserével lehet megoldani. Ezt támasztják alá a témában végzett saját kísérleteink is [55].

Mivel hasonló elvű, de nem sugázmérő rendszer kidolgozása során már elértem levegő szennyezettségét mérő robotrepülőgépes felmérésekkel akár 60 *perces* felmérési időt is [56] [57], célul tűztam ki a multikopteres, sugázmérő eljárás felmérési idejének növelését és ezáltal a felmért terület kiterjesztését.

6.1. Mérési adatok feldolgozása, megjelenítése

A mérő modulon a hordozó rendszerétől független GPS egység található. Ez a GPS másodpercenként szolgáltat friss helyadatot. Az 6.1. ábrán látható egy kísérleti repülés nyomvonala. A nyomvonalon található pontok a mért pozícióadatok, melyek interpolációval összekötve adják a repülési utat. Minden egyes GPS mérési ponthoz tartozik a detektor által összegyűjtött „beütésszám”. Ez azt jelent, hogy egy-egy ponton 1 másodperces mérések adatai kerülnek rögzítésre. Az első kísérletek során alkalmazott Geiger-Müller detektor esetében ez 1-2 beütés háttérsugárzás esetén. A javított 4 csöves detektorrendszer esetében ez az érték 5-8 beütés. Kísérleteket végeztünk szcintillációs detektorral is ahol a beütésszám másodpercenként 25-30. A szcintillációs detektor esetében csak az esemény került rögzítésre, detektált gamma foton energiája nem került meghatározásra. A 6.1. ábrán színes szakaszok jelölik azokat a mérési helyeket, [58] ahol a detektor adatai jól azonosítható módon emelkedett sugárzásértéket mutattak. A nyers adatok feldolgozásának alapját tehát a GPS mérési pontokhoz rendelt detektor adatok szolgáltatják, amit az 6.1. ábra szemléltet.




6.1. ábra. Terület felosztása cellákra

Mivel a gamma sugárzás mérése egy saját építésű rendszerrel történt, adatait a hordozó szenzoraitól (jelen esetben a hordozó GPS moduljától) függetlenül lehet kezelni. A rendszer úgy lett megépítve, hogy akár egy kis méretű quadrocopteren is elhelyezhető. Repülés során minden méréshez egy GPS koordináta tartozik melyet a mérőmodul saját GPS egysége szolgáltat. A használt GPS modul pontatlansága 4-5m. A pontosságot több tényező is befolyásolja:

- műholdak elhelyezkedéséből adódó hiba (DOP - Dilution of Precision),
- a troposzféra hatása,
- tereptárgyak által okozott visszaverődések,
- óra hiba stb.

A pontatlanság kiküszöbölése érdekében nem a ponthoz, hanem területhez rendelt gamma értékeket ábrázoló térképet készítettem. A térkép előállításához szükséges szoftver MATLAB környezetben készült. Az első lépésben a mérési terület felosztása az alábbi, 6.2. ábrán látható módon történt:



6.2. ábra. Mérési nyomvonal, ahol a pontok a mért koordináták, a színes részletek pedig azok a mérési pontok ahol a mért sugárzás szignifikánsan nagyobb a többi mérési ponton mért értéknél

Legyen $\Omega_{i,j} \subset R^2$ $X_{\min}$ -től $X_{\max}$ -ig és $Y_{\min}$ -től $Y_{\max}$ -ig tartó befoglaló téglalap alakú terület, ahol

$$X_{\min} = \min_{p \in P} p_x \quad (6.1)$$

$$X_{\max} = \max_{p \in P} p_x \quad (6.2)$$

valamint

$$Y_{\min} = \min_{p \in P} p_y \quad (6.3)$$

$$Y_{\max} = \max_{p \in P} p_y \quad (6.4)$$

ahol p egy mérési pont GPS koordinátája ($p_x, p_y \in R$), továbbá P az összes pontot tartalmazó halmaz. Az $n \times m$ felosztású befoglaló téglalapot az alábbiak szerint képezzük:

$$\Omega_{ij} = \begin{cases} [x^i, x^{i+1}] \times [y^j, y^{j+1}], & \text{ha } i \in [0, n, \dots, n-2] \text{ és } j \in [0, m, \dots, m-2] \\ [x^i, x^{i+1}] \times [y^j, y^{j+1}], & \text{ha } i = n-1 \text{ és } j \in [0, m, \dots, m-2] \\ [x^i, x^{i+1}] \times [y^j, y^{j+1}], & \text{ha } i \in [0, n, \dots, n-2] \text{ és } j = m-1 \\ [x^i, x^{i+1}] \times [y^j, y^{j+1}], & \text{ha } i = n-1 \text{ és } j = m-1 \end{cases} \quad (6.5)$$

ahol

$$x^k = x_{min} + k * dx \quad (6.6)$$


és

$$y^k = y_{min} + k * dy \quad (6.7)$$

A fentiek alapján meghatározunk egy $f(p)$ függvényt, amely megadja p pont értékét. Az (i, j) -edik cellához tartozó érték a következő összefüggés segítségével határozható meg:

$$\bar{p}\Omega_{i,j} = \frac{\sum_{p \in \Omega_{i,j}} f(p)}{|\{p : p \in \Omega_{i,j}\}|} \quad (6.8)$$

Az átlagolást végző függvény helyettesíthető bármilyen más függvénnyel, pl. medián használatával. Tehát a mérési terület előre megadott paraméterek alapján kerül felosztásra. Az összes mérési pont egy adott cellához fog tartozni. Egy cella értékét a mért gamma-sugárzások átlaga adja.




6.3. ábra. $1m \times 1m$ -es és $4m \times 4m$ cellákra felosztott területekhez rendelt gamma-sugárzási értékek ábrázolása

A 6.3. ábrán látható térkép ugyan arról a területről készített gamma-sugárzás mérést mutatja be. A különbség a terület felosztásában látható. A bal oldali ábrán $1m \times 1m$ a jobb oldali ábrán pedig $4m \times 4m$ -es cellákra lett felosztva. A mérési pontok sűrűsége és a GPS pontatlansága miatt nem érdemes kis felbontást alkalmazni. Nagyobb pl. 4×4 -es terület esetén az eredmény sokkal jobban leolvasható.

6.1.1. Megállás nélküli, pásztázó mérési eljárás

A kísérlet során izotóp mintát helyeztem el a célterületen. Ennek a mintának a hatását kerestem a terület pásztázása során gyűjtött sugárzási adatokban. A repülés a minta felett 9 méter magasan ($\pm 0.1m$) történt. A repülés sebessége $2m/s$ ($\pm 0.1m/s$) volt. A vizsgált terület megközelítőleg 80×80 méter, azaz $6400m^2$. Az ábrán látható pont sűrűsödés a fel- és leszállás helye, ahol a drón már nem egyenletes sebességgel haladt. Ezen a ponton gyűjtött mérési adatokat a feldolgozás során nem vettem figyelembe. Az adatok mennyiségének növelése érdekében a területet az eszköz kétszer pásztázta végig úgy, hogy a repülés második szakaszában a nyomvonalak merőlegesek voltak a repülés első szakaszának nyomvonalaira. Ennek megfelelően a kialakult repülés nyomvonal egy négyzetrácsot eredményez. A 6.4. ábrán látható nyomvonalat utólag a tényleges repülés során rögzített GPS adatok alapján rekonstruáltam.




6.4. ábra. Egy folyamatos mérés eredménye - (a) mérést végző eszköz; (b) a repülés nyomvonala; (c) a feldolgozást követő szignifikáns sugárforrás helye; (d) a területről készült ortofotóra vetített sugárforrás

Az 6.4. ábrán látható sugárzási folt a háttér beütésszámának kétszerese, azaz szignifikáns jel a mért területen. A vizsgálat során a háttérsugárzásra átlagosan $80cpm$ (Count Per Minute) adódott, míg a minta felett ez a beütésszám átlagosan $172cpm$ volt. A 6.4. ábra utolsó képén a georeferált ortofotóra vetített korrigált sugárzási kép látható. A georeferált ortofotó a drón fedélzeti kamerájának képei alapján készült [55]. Mivel a kamera nem függőleges tengelyre volt pozícionálva (90° helyett 80°), a berepült területtől nagyobb területről állt rendelkezésre képi információ ami megkönnyíti az ortofotó kalibrációját. A kísérlet részletesebben a [55] értekezésben lett közzé téve.

6.1.2. Diszkrét pontokban történő mérési eljárás

A kísérleti tapasztalatok azt mutatták, hogy a forrás detektálása hatékonyabb lenne, azaz a háttérsugárzáshoz képes határozottabb eltérés mutatkozna, ha a mérés egy adott pontra vonatkoztatva hosszabb ideig tartana. Ennek egyik módja, hogy tovább csökkentjük a repülési sebességet. Az alkalmazott eszköz vezérlő szoftvere azonban a $2m/s$ –nál kisebb sebességű repülést nem tette lehetővé. Tekintettel a kezdeti feltevésre, miszerint két szomszédos mérési pont között nem számítunk ugrásszerű sugárzásváltozásra, kidolgoztam egy diszkrét pontokból álló mérési eljárást. Az eljárás lényege, hogy a megtervezett útvonalon az eszköz nem folyamatosan repül, hanem a kijelölt mérési pontokon (melyek egy raszteres hálót alkotnak) előre meghatározott ideig lebeg, majd tovább repül a következő mérési ponthoz. A lebegési időt 10 másodpercben határoztam meg. Így a detektor érzékenységeinek megfelelően az egyes pontokon közelítőleg ötször több adatot tudunk rögzíteni. A megnövekedett adatmennyiség jobb jel/zaj arányt (sugárzó minta/háttér sugárzás) biztosít, ami növeli a detektálható forrás érzékelésének valószínűségét.



6.5. ábra. Diszkrét mérési pontokkal történő mérés - (a) repülési nyomvonal illesztése látható a mérési terület felett; (b) a feldolgozott detektor adatok alapján létrehozott dóziseloszlás kép; (c) a mérési terület ortofotójára vetített dóziseloszlás kép a kimért sugárforrással

A 6.5. ábrán egy $60m \times 20m$ kísérleti területen helyeztem el mintát. A minta aktivitása $300\mu Sv/h$ volt. Mivel az alkalmazott szállító eszköz vezérlő szoftvere nem tette lehetővé a 10 másodperces lebegéseket, a repülés kézi vezérléssel történt. Minden előre meghatározott mérési pont felett a multikopter 10 másodpercet lebegett, majd a következő pontra állt. A 6.5. ábra (b) képen látható az adatok feldolgozása során készült színes dóziseloszlás fedvény.

Minél melegebbek a színek a fedvényen, annál magasabb az adott területen a mért dózis. Jól látható a fedvényen az intenzív piros folt melyet a mért minta okozott. A 6.5. ábra (c) képén a vizsgált terület ortofotójára vetített dóziseloszlás látható. A háttérsugárzástól markánsan elkülönülő piros folt a mért mintának megfelelő helyen található.

6.1.3. Részeredmények

Mind a megszakítás nélküli, mind a diszkrét mérési eljárásokkal a kísérleti mérések során a szükséges paraméterek mellett ($8m$ feletti magasság, minimum $300\mu Sv h$ aktivitású minta, $\pm 1,5m$ pontosság) sikerült a mintát sikeresen detektálni és lokalizálni. A diszkrét módszer előnye a megszakítás nélküli méréssel szemben az egyszerűbb utófeldolgozás volt. Diszkrét mérések esetén nem szükséges a mozgási elmosódást és a lokalizációs hibákat kompenzálni. A mérhető területeket tekintve a diszkrét módszerrel nem volt előny. A lebegés energetikai és repülésdinamikai szempontból kedvezőtlenebb, mint a megszakítás nélküli repülés. Mint ilyen, a repülési idő bár kissé, de csökkent. A megfelelő rácspontok beállításának köszönhetően azonban a mért terület mérete megegyezett a megszakítás nélküli mérési eljárás méretével.

Kutatásom során olyan módszert dolgoztam ki, amelynek előnye, hogy egy kicsi méretű multikopterrel, költséghatékonyan feltérképezhető az adott terület. A felmérés során egy kalibrált, georeferált, gamma-eloszlást reprezentáló térkép készül, amellyel emberi beavatkozás nélkül is meg lehet határozni a sugárforrásokat. A kisméretű multikopterek repülési idejét figyelembe véve a mérési módszerek hatékonyságát szem előtt tartottam. Számos mérési módszer tesztelése mellett fejlesztettem a detektorrendszert. A végeredmény egy kisméretű, $500grammos$ detektorrendszer $120perces$ működési idővel. Percenként átlagosan 30 esemény mintavételére képes, emellett $10m$ magasságból letapogató repülés során $\pm 1,5m$ pontossággal érzékeli a $300\mu Sv h$ aktivitású forrást is jelentős mértékben. A frissített feldolgozószoftver használatával a térképkészítés könnyen kezelhetővé vált.

6.2. Sugárforrás lokalizálása modell alapú megközelítéssel

A szabadtéri gamma-sugárforrás lokalizálása alapvetően gamma tartományban érzékeny képalkotó eszközök segítségével végezhető el egyszerűen. Ilyen képalkotó eszköz többek között a gyógyászatban használt gamma-kamerák vagy azok különféle továbbfejlesztett változata [59] [60]. Ezen eszközök esetében a képalkotás feltétele egy gamma tartományban működő optikai leképező rendszer alkalmazása. Ilyen például a gamma kamerára illesztett pinhole „optika” vagy az úgynevezett kollimátor előtét [61] [62]. Mindkettő ólomból készül és rendkívül nagy tömegű. Tekintettel arra, hogy a projekt egy hordozható, gyorsan és olcsón üzembe helyezhető drón platformra rögzített érzékelő segítségével kívánja a forrás lokalizációját megvalósítani, a detektornak kis tömegűnek kell lennie. Ebből adódóan a hagyományos gamma tartományban érzékeny képalkotó eszközök a feladat szempontjából nem alkalmazhatók.

Amennyiben a képalkotás során keletkező képpontok jellemzőit a képpont intenzitásával (esetenként színcsatornákra bontott intenzitásokkal), valamint a képpont pozíciójával (a sík képen értelmezett $X; Y$ koordináta) határozzuk meg, akkor megállapíthatjuk, hogy az intenzitást a sugárzásra érzékeny szenzor jele, a képpont pozícióját pedig a leképező optika szolgáltatja. Ennek értelmében a képalkotó rendszert két alapegységre, a mért sugárzás intenzitásának mérésére, valamint a mérési koordináta meghatározására alkalmas egységekre bonthatjuk [63].

A fentiek alapján lehetőség kínálkozik klasszikus értelemben optikai leképező rendszer nélküli képalkotásra. A projekt során a mért sugárzás intenzitását Geiger-Müller számlálóval, illetve más kísérletek során szcintillációs detektorokkal valósítottam meg. A mérési koordináta meghatározását GPS helymeghatározó készülékkel valósítottam meg. A komplex rendszer minden mért koordináta értékhez hozzárendeli az aktuálisan megmért sugárzás intenzitását, azaz a detektor által érzékelt gamma fotonok számát [64]. A kísérletek során eleinte $1Hz$, később $5Hz$ mérési frekvenciájú GPS készüléket alkalmaztam. Ennek megfelelően a gamma fotonok számát a GPS mérési periódusához illesztettem és abból számítottam át a mért értékeket másodpercenkénti eseményszámra (Count per Second, CPS).

A megfogalmazott detektorrendszer adatai alapján közvetlenül gamma tartományban nem lehet képet alkotni. A kép elkészítéséhez további feldolgozásra van szükség. A gamma tartományú vizsgálatok során a keresett forrás intenzitása igen alacsony, a mindenhol jelenlévő háttérsugárzástól alig különül el. Ez más megfogalmazásban nagyon rossz jel-zaj viszonyt jelent. Az utófeldolgozás során kiemelt feladat az ilyen nagy zajjal terhelt mérési adatokból kiemelni az információt. A vizsgált terület színezéssel kódolt dóziseloszlás térképének előállítására területegységekre osztott integrálással és területegységek közötti interpolációval sikeres megoldást dolgoztam ki [65–69]. Ugyanakkor a módszer nagyon érzékeny a feldolgozás során meghatározott egységnyi cellák méretére [70]. A mért értékek minél pontosabb vizuális megjelenítése érdekében szükség volt egy hatékony, de alapjaiban az alkalmazott módszertől eltérő elveket alkalmazó eljárásra. Egy ilyen lehetséges kontroll módszer a mérési adatok korreláción alapuló feldolgozása. Mivel ez a módszer nem alkalmazza a területek egységnyi felosztását, eredménye felhasználható a területi felosztás során az elemi területek méretének automatizált meghatározásához. Egy forrás lokalizálása esetén azonban a korrelációs módszer önmagában is jól alkalmazható [71] [72].

A sugárforrás helymeghatározása fizikai modellek és szimulációk segítségével jelenleg aktívan kutatott terület [73] [74]. Az egyponthoz sugárforrás környezetében mért intenzitáseloszlást rögzítő matematikai modell megfogalmazásához a következő feltételezéseket tettem [75]. Először azt feltételeztem, hogy a mérések csak viszonylag kis területet fednek le, ezért a Föld görbülete figyelmen kívül hagyható a számításoknál. Ez lehetővé teszi, hogy az M adatainkat megfigyelések halmazaként ábrázoljuk, ahol minden mérés $m_k = (x_k, y_k, i_k)$ alakú, ahol x_k és y_k a megfigyelés kétdimenziós térbeli koordinátáit adja, és i_k pedig a szonda által mért intenzitást egy adott hely felett. A leírás több intenzitásmérést is lehetővé tesz ugyanarra a térbeli helyre vonatkozóan, amely a tényleges repülési útvonal eredményeként előfordulhat. Azt is feltételeztem, hogy a forrás egyetlen $s = (s_x, s_y)$ pont, amely nem feltétlenül az aktuális mérési zónán belül van, és a sugárzás izotrop. Harmadik feltételezésem az volt, hogy a készülék magassága repülés közben elhanyagolható a mérési zóna térbeli méreteihez képest, ezért a szonda és a sugárforrás közötti távolság eltűnik, ha a készülék pontosan s fölé lebeg.

Az izotrop sugárzó által kibocsátott gamma-sugárzás elektromágneses hullámként inverz négyzettörvényt követ, ezért a repülés során különböző helyeken mért egységnyi időegységben kifejezett intenzitásoknak ezt a törvényt kell tükrözniük. Adott a sugárforrás valós (hipotetikus) helye (s_x, s_y) , a mért intenzitásokat a következőképpen modellezzük:

$$\hat{i}_k = \frac{\mu_p}{d(s, m_k)} + \varepsilon_k, \quad (6.9)$$

ahol $d(s, m_k)$ a sugárforrás helyzete közötti távolság s , és a mérés helye m_k , míg μ_p egy arányos tényező, amely a sugárzás intenzitását a szonda által egységnyi idő alatt rögzített számláláshoz skálázza, és ε_k a véletlenszerű zaj leírására szolgáló kifejezés (pl. a természetes háttérsugárzás hozzájárulása). A képlet valójában a sugárzás terjedésének alaptörvénye. Azt írja le, hogy a sugárzás hogyan gyengül le, miközben közegeken halad át [76]. A háttérsugárzás jellegéből fakadóan a zaj eloszlása normál eloszlást követ [77] [78]. A fenti első feltevésemet felhasználva, $d(s, m_k)$ itt a földrajzi koordináták Euklideszi távolságának tekintem.

Most, adott egy sor tényleges mérés M és egy ismeretlen sugárforrás $\hat{s}$, kiszámítjuk a modell előrejelzési hibáját az alábbi szerint:

$$e(M, \hat{s}) = \sum_{k=1}^{|M|} \left(\hat{i}_k - i_k \right)^2. \quad (6.10)$$


Az előző képlet segítségével $\hat{i}_k$, átírhatjuk az egyenletet:

$$e(M, \hat{s}) = \sum_{k=1}^{|M|} \left(\frac{\mu_p}{\sqrt{(\hat{s}_x - x_k)^2 + (\hat{s}_y - y_k)^2}} - i_k + \varepsilon_k \right)^2 \quad (6.11)$$

amely minimálisra csökkenthető optimális választási lehetőségek megtalálásával $\hat{s}_x$, $\hat{s}_y$ és μ_p a sugárforrás helyének és intenzitásának megfelelően.

Elméletileg és különösen ε_k hiányában, a probléma triviális, bár a zaj jelentős hozzájárulása a gyakorlatban nagyobb kihívást jelent a minimalizáláshoz, mivel sok szabványos optimalizálási eljárás valószínűleg leáll egy helyi optimumban. Ennek elkerülésére egy sztochasztikus megközelítésű, pontosabban egy evolúciós algoritmust használtam, ame-

lyet az Excel Solver bővítményében implementáltak, $\hat{s}_x$, $\hat{s}_y$ és μ_p értékeinek legjobb közelítését találja meg. A koordináták alsó és felső korlátja a következőképpen lett beállítva: $\hat{s}_x^L = \min_k \{x_k\}$, $\hat{s}_x^U = \max_k \{x_k\}$, és $\hat{s}_y^L = \min_k \{y_k\}$, $\hat{s}_y^U = \max_k \{y_k\}$. Az alsó határ μ_p beállítva 0 értékre, de mivel nem állt rendelkezésre információ a lehetséges felső határról, előzetes vizsgálatokat hajtottam végre, hogy megkapjam a μ_p^U reális értékét. Az optimalizálási módszert több paraméterbeállítással (azaz populációmérettel és mutációs rátával) teszteltem, és az ideális populációméretet 100-nak, a mutációs rátát pedig 0,2-nek találtam hozzávetőleg 2000 megfigyelést tartalmazó adatkészleteimhez.




6.6. ábra. A matematikai modell gondolatának sematikus ábrája. A szondával mért intenzitás fordítottan arányos az ismeretlen forrásponttól való távolsággal, így a megfigyelt és a modellezett intenzitásmérések közötti különbség minimalizálásával meghatározható a forráspont koordinátái.

6.3. A kísérletekhez használt eszközök

A kísérletek során két sugármérő detektor került alkalmazásra. Az egyik detektor a Geiger-Müller (GM) számlálóra épült [79]. Ez a detektorrendszer lényegében csak az ionizáló sugárzást, jelen esetben a gamma részecskét (sugárzást) érzékeli. Az egységnyi idő

alatt detektált események arányosnak tekinthetők a sugárdózissal. A detektor nem képes a gamma részecske energiájának meghatározására. Előnye a GM detektoros rendszernek, hogy a jelei egyszerűen feldolgozhatók, így a fedélzetén elegendő egy kis számítási teljesítményű mikrokontroller alkalmazása. Hátránya a viszonylag magas tápfeszültség igény (a GM csöveknek típusától függően 700-900V tápfeszültséget igényelnek).

A másik detektálási eljárás alapja a szcintillációs detektor [80]. Ezzel a detektorral az észlelt gamma részecske energiája is megmérhető. Ez a többlet információ segít egy adott minta szelektív detektálásában. További előnye a szcintillációs detektornak a relatív kis méret melletti nagy érzékenység. A detektor hátránya éppen az energia mérése okán a nagy adatmennyiség keletkezése, valamint a natív adatok feldolgozása. Az energiaszint meghatározása okán valamivel nagyobb számítási teljesítményű mikrovezérlőre van szükség a GM detektoros rendszerekhez képest.



6.7. ábra. A drónokra szerelt terepi dóziseloszlás-mérést szolgáló kísérleti eszközök - (a) Inspire I egy GM-csöves detektorral (b) Inspire I négy GM-csöves detektorral; (c) Mavic Pro egy kisméretű szcintillációs detektorral; (d) Inspire I szcintillációs detektorral, amely gyors spektrumelemzésre alkalmas

Hordozó eszköz tekintetében a nagy méretű GM csövek miatt olyan multikopterre esett a választás, amely fedélzetén elfér a detektor rendszer. A DJI cég Inspire I multikoptere (6.7.a és 6.7.b ábra) megbízható és kellő teherbírással rendelkezik. Képes automatikus útvonal repülésre ami kényelmessé teszi a kísérleti terület pásztázó berepülését. Szintén DJI termék a Mavic (6.7.c ábra), amelyre kis méretű szcintillációs detektor került. Hasonlóan az Inspire I -hez, a Mavic is képes előre programozott útvonalrepülésre, ugyanakkor kisebb mérete okán kényelmesebben szállítható, kezelhető. Sajnos a Mavic teherbírása erősen korlátozott, így nagyobb szcintillációs detektort nem képes a kísérletek szempontjából minimálisan 10-15 percen át szállítani. A felszerelt detektor érzékenysége megegyezik a 4 GM csöves


(6.7.b ábra) detektorrendszerével, így megfelelő alternatívája a nagy méretű 4 csöves Inspire I hordozónak. Noha a szcintillációs detektor alkalmas a detektált gamma részecske energiájának meghatározására is, az 6.7.c ábrán bemutatott eszköz részecskeszámláló módban működik, hogy ne kelljen nagy teljesítményű és ezáltal nagyobb energiaigényű fedélzeti mikrovezérlőt alkalmazni.

Annak érdekében, hogy teljes mértékben kiaknázható legyen a szcintillációs detektorokban rejlő lehetőség egy speciális detektor került kifejlesztésre [65–67]. Ennek a detektornak az érzékenysége lehetővé teszi, hogy másodpercenként statisztikailag is feldolgozható mennyiségű, energiaszinteket is tartalmazó mérési adatokat szolgáltatson. A detektor tömege azonban már túl nagy a DJI Mavic számára, így ismét a már bevált DJI Inspire I fedélzetére került (6.7. d ábra).

6.4. Mérési eredmények

A méréseket autonóm repüléssel, különféle drónokra szerelt detektorokkal végeztem [81] [82]. A repülések magassága a minták felett 5-6 méter volt. A referencia pontok felvétele a mérést végző eszközzel, a kísérlet záró szakaszaként, az eszköz kikapcsolása nélkül történt. Ez a módszer biztosította, hogy a koordináták a mérés során azonos hibákkal terheltek, így relatív pontosságuk a lehető legnagyobb. A GPS készülék átlagos statikus pozícióhibája 3 méter, de a kísérlet ideje alatt a koordináták egymáshoz viszonyított pontossága 0,2 méter volt. A mérési adatok kiértékelése során a referenciapont mérési adatai eltávolításra kerültek. A kiértékelés során meghatározott forrás kizárólag az aktív mérés során gyűjtött gamma részecske észlelési értékei, valamint az azokhoz rendelt koordináták lettek figyelembe véve. Az ábrákon látható referenciapontok a mérés pontosságának vizuális érzékelése céljából kerültek feltüntetésre. A tesztterületek kis eltérésekkel 30 x 90m méretűek voltak.


6.4.1. A mérések kivitelezése



6.8. ábra. A tesztterületen, folyamatos pásztázó repüléssel végzett GM csöves mérés natív adatainak kiértékelése

A GM csöves detektorok kizárólag a gamma részecskék detektálását teszik lehetővé. A részecske energiájáról információkat a GM csövek nem szolgáltatnak. Amennyiben a keresett forrás a vizsgálati távolságban szignifikáns észlelésszám növekedést okoz a háttérsugárzáshoz képest, az észlelésekhez kapcsolt koordináták felhasználásával a vizsgált területen jól lokalizálható a minta [65–67]. A kísérlet során a drónra 4 darab LND 7808 [83] típusú GM került telepítésre. A mérés során a minta a detektor észlelési értékét esetenként a háttérsugárzás átlagos másodpercenként 13-as észlelési értékéhez képest kicsivel több, mint a duplájára, 30 észlelés másodpercenként értékre emelte. Mivel ez az észlelési szám növekedés önmagában is elegendő a forrás észlelésére és lokalizálására, a feldolgozási eljárások tesztelésére igen alkalmas. A 6.8. ábra egy ilyen detektorrendszerrel felszerelt drón pásztázó repülésének feldolgozott mérési adatai alapján szemlélteti a felderített forrást és a referenciaponttal megjelölt forrás valós pozícióját. Jól látható, hogy a mért és a tényszerű pozíció igen közel van egymáshoz. Ez a pontosság tökéletesen elegendő egy földi


alakulat számára a felfedezett sugárforrás fizikai felleléséhez és a mentesítő munkálatok megkezdéséhez. A kiértékeléshez a repülés során rögzített nyers adatok lettek felhasználva. Az adatokból csupán a felszállás előtti, valamint a leszállást követő időben rögzített, a pásztázó mérés szempontjából irreleváns és egyben zavaró részek lettek eltávolítva. A rögzített adatokon nem történt semmilyen szűrés, zajeltávolítás vagy más előfeldolgozás [84].



6.9. ábra. A teszterületen, folyamatos pásztázó repüléssel végzett szcintillációs detektoros mérés natív adatainak kiértékelése

A 6.9. ábrán egy szcintillációs detektorral ellátott drón segítségével történt pásztázó mérés [85] [79–83]. A kísérlet célja az volt, hogy a területre kihelyezett alacsony aktivitású mintát, folyamatos pásztázó repülés során is ki lehessen mutatni. A szcintillációs kristály egy $21.5 \times 50 \times 50 \text{ mm}$ méretű CsI (Tl) (Thallium Activated Cesium Iodide) volt. A natív mérési adatokban szignifikáns eltérés a mérés alatt nem volt látható. A minta által okozott többlet sugárzás a háttérsugárzás okozta észlelésekbe beolvadt. A szcintillációs detektor lehetővé tette, hogy a GM csöves detektorokkal szemben nem csupán a gamma foton kölcsönhatását, hanem annak energiaszintjét is meghatározhassuk [86] [87]. A 6.10. ábrán a kísérlet során


mért natív adatok feldolgozásának eredménye látható. A feldolgozás során az észlelések energia szerinti osztályozását nem alkalmaztam. A szcintillációs detektor észleléseit a GM csöves detektorhoz hasonlóan kezeltem, az egységnyi idő alatt detektált részecskék számát vettem figyelembe (Count per Secound [CPS]) A gyengén detektálható minta ellenére a feldolgozási eljárás képes volt kimutatni a mérési adatokban a teszt területen bizonyos mértékű gócpontot, azaz pozitív irányú eltérést a területen mért sugárzási értékekhez képest. Az ábrából az is kiolvasható, hogy a minta kalkulált és valódi pozíciója (referenciapont) között jelentős távolságbeli eltérés mutatkozik.



6.10. ábra. A tesztterületen, folyamatos pásztázó repüléssel végzett szcintillációs detektoros mérés kiugró zajoktól megtisztított adatainak kiértékelése

A 6.10. ábra kapcsán látható pozícióeltérésnek okai egyrészt a mérés során keletkező zajok nagysága, másrészt a vizsgált minta alacsony aktivitásából következő alacsony észlelésnövekedés. A natív mérési adatokat idősoros formában elemezve megállapítható volt, hogy több ízben irreálisan magas észlelési érték került rögzítésre. Ezek az értékek csak igen rövid időre jelentek meg és értékük alapján nagy biztonsággal kizárhatók a mérési adatokból. A 6.10. ábra az irreálisan magas (kiugró) észlelési értékek automatikus törlését

követő, minden egyéb tekintetben a 6.9. ábrán bemutatott, szűretlen adatok feldolgozott eredményét szemlélteti. Az ábrán jól látható, hogy a kalkulált sugárforrás pozíciója a valódi (referencia) pozícióhoz képest lényegesen közelebb került egymáshoz. Tekintettel arra, hogy a zavaró mértékű zajok egyszerű algoritmikus eljárásokkal megjelölhetők, azok eltávolítása automatizálható. A zajos adatsorok az eljárás nem a környező adatok átlagának helyettesítésével, hanem azok teljes mértékű törlésével valósult meg. A kísérletek során egyértelműen megállapítást nyert, hogy a nagy eltérést mutató zajok kiszűrése a forrás lokalizációjának meghatározása szempontjából szükséges. A kísérletek során a zajmentesített adatokkal a lokalizáció pozíciója egyértelműen pontosabb lett.




6.11. ábra. Statikus mérés a vizsgált minta speciális spektrumának meghatározásához

A pozíció hiba, a már említett másik forrása az alacsony aktivitású minták kapcsán az alacsony észlelések száma okozza. Ez valójában a háttérsugárzás átlagos észlelési számának a natív adatokban nem, vagy alig észrevehető növekedést jelent. Más megfogalmazásban a jel-zaj arány nem elegendően magas, így a hasznos információ kinyerése nehézségekbe ütközik. Szcintillációs detektor alkalmazása esetén lehetőség nyílik az észlelt gamma-foton energiájának meghatározására is. Ismeretes, hogy egy adott izotóp bomlása során keletkező gamma-fotonok energiája, az izotópra jellemző energiaspektrumot mutat. Amennyiben ismert anyagi minőségű sugárforrást keresünk, kihasználható a keresett izotópra jellemző

sugárzási spektrum [88] [89].

A 6.11. ábrán a kísérletek során alkalmazott Autunite ásvány spektruma lett a drónra szerelt detektorral rögzítve [90]. A diagram nem kalibrált detektor-adatokat szemléltet. A diagramon látható a háttérsugárzáshoz (6.11. ábra, narancssárga diagram) és a mintához (6.11. ábra, kék diagram) tartozó csatornákhöz rendelt másodpercenkénti észlelési száma [91]. Mivel a detektor nem volt kalibrálva, a diagramon is az energiaértékek helyett csupán a csatornaszámok jelennek meg. Tekintettel arra, hogy a mérések összehasonlító jellegűek és azok értelmezése csupán kvalitatív jellegű, a kalibráció hiánya nem okoz értelmezési problémákat. A 6.11. ábrán a vizsgált mintának két jellegzetes csúcsa is látható. Ezek környezetét is megjelöltem. Az egyik csúcs 800-970 csatornaszámok között, a másik pedig 1380-1620 csatornaszámok között található. Kis intenzitás esetén is feltételezhető, hogy a jelzett csatornatartományokban a minta által okozott észlelések száma magasabb arányban lesz kimutatható az érzékelhető további csatornatartományokhoz viszonyítva.



6.12. ábra. A teszterületen, folyamatos pásztázó repüléssel végzett szcintillációs detektoros mérés energia-szelektív natív adatainak kiértékelése

A 6.12. ábra a 6.9. ábrán bemutatott adatokból az előzőekben tárgyalt energiaablakkal

egyenértékű csatornaablakok adatainak feldolgozásával meghatározott sugárforrás kalkulált és valóságos pozícióját szemlélteti. Ebben az esetben az adott időegységre eső észlelések száma jelentősen csökkent ugyan, mégis a már említett jel-zaj viszony javulásának köszönhetően kedvezőbb kiértékelési eredményre jutottam. Az ábrán látható, hogy a kalkulált sugárforrás helye már erősen megközelítette a valóságos pozíciót, ami eleget tesz azon elvárásnak, hogy az így kapott koordináták alapján egy földi alakulat nagy biztonsággal megtalálhassa a keresett forrást.

6.5. Eredmények

A bemutatott lokalizációs eljárást számos régi és új felmérés adataival vizsgáltam. A GM csöves és szcintillációs detektoros méréseket is átdolgoztam. Minden olyan mérés esetében, ahol a keresett minták jelei egyértelműen kitűnnek a háttérsugárzás által keltett jelek közül, az eljárás megbízhatóan meghatározta a keresett minta földrajzi koordinátáit az alkalmazott GPS rendszer lokalizációs pontosságának megfelelően. A pontosság gyakorlatilag 3 m-en belül volt. Ugyanilyen lokalizációs pontosságot értem el a hagyományos mérésekkel a vizsgált távolságból nem észlelhető gyenge források esetén is, de a mintára jellemző energiaspektrum ismeretében úgynevezett energiaszelektív előfeldolgozást alkalmaztam. Az eljárás pontosságát nem befolyásolja a mérés során használt repülési útvonal geometriája. A kidolgozott módszert összehasonlítottam a korábban használt, saját fejlesztésű területalapú eloszlási modellemmel [65–67]. Az idézett modellem esetében a feldolgozás eredménye nagymértékben függ a megfelelő területegység meghatározásától. Mivel nem tudtam pontos matematikai módszert adni az optimális területosztásra, ezért empirikus eredményeimre támaszkodtam. Ennek megfelelően a repülések során meghatározott mérési távolságokhoz állítottam be a feldolgozó elemi területegység nagyságát. Az értekezésben bemutatott módszer esetében nincs szükség a terület felosztására. Az eljárás lokalizációs pontossága egybeesik a repülés során használt GPS készülék pontosságával. Ezért egy forrás esetében a forrás helyzetének meghatározása referenciaértéknek tekinthető. Ezzel a referenciaértékkel úgy állítom be módszerem területosztást igénylő paraméterét (mely meghatározza a számítások során felhasználandó területegység nagyságát), hogy az megadja a forrás e

módszerrel adott lokalizációját. Ezt követően további, azonos repülési viszonyokkal felvett ismeretlen területek adatainak feldolgozásával a területi paraméter megtartása mellett a források lokalizációit régi modellem esetében több forrás esetén is valószínűnek tekinthetjük. Minden bizonnyal, a bemutatott módszernél léteznek hatékonyabbak is, de jelen kutatásaim témája a nagy mennyiségű adatok fúziója, nagy mennyiségű adatok újszerű összekapcsolása, feldolgozása.

4. Tézis

Megalkottam két, egymástól független eljárást, melyekkel sugárzó anyag pozícióját lehet meghatározni. Az eljárás részeként alacsony tömegű, nagy érzékenységű, UAV-re szerelhető szenzorokat használtam. A felmérni kívánt terület helyben vagy előre tervezhető, a felmérés gyorsan végezhető, ezzel a felmérésben résztvevő személyek és eszközök sugárdózisa jelentősen csökken a hagyományos lokalizációs módszerekhez képest. Az általam kidolgozott eljárások képesek:

- 1. az eljárások képesek a szennyezés forrásának detektálására,*
- 2. a rendelkezésre álló 3D pozíció adatok segítségével a felmért terület sugárzási jellemzőinek vizualizációja lehetséges.*

Tézishez kapcsolódó tudományos közlemények: [T7][T8][T9]

7. fejezet

Tézisek

1. Tézis

Kidolgoztam és kísérleti eredményekkel igazoltam egy olyan komplex algoritmust, mellyel kisméretű robotrepülőgépek által készített légi felvételekből előálló nagy mennyiségű, több dimenziós adatot az előre, szabadon definiálható tartalmi feltételek mentén elemeztem. Az algoritmus több, egymástól függetlenül is értelmezhető eljárást tartalmaz, melyek mindegyike értékelhető eredményt ad, azonban az egyes vizsgált adatpontokra jobb eredményt értem el az eljárások fuzionálásával. Az általam kidolgozott és megvalósított megoldás a következő jellemzőkkel rendelkezik:

1. a komplex eljárás minden eleme önálló és egyenértékű, melyek között nincs előre definiált hierarchikus sorrend,
2. az eljárás egésze nagy mennyiségű adat elemzését teszi lehetővé,
3. alkalmas objektumok azonosítására úgy, hogy az egyes részmegoldások hamis-pozitív és hamis-negatív eredményeit eliminálja a végleges eredményből,
4. jobb eredményt szolgáltat, mint amit a felhasznált eljárások önállóan adnak.

Tézishez kapcsolódó tudományos közlemények: [T1][T2]

2. Tézis

Megalkottam egy eljárást, mely segítségével költséghatékonyan és nagy felbontással lehet valós objektumok hőmodelljét létrehozni. Az eljárás bemenetét alacsony felbontású, 7.5-13.5 μm tartományban készült, rossz minőségű hőképek alkotják, melyekből képes voltam a szenzor eredeti felbontását magasan meghaladó felbontású, 3D-ben értelmezhető kimenetet

prezentálni. A fúziós algoritmus a bemeneti 160x120 pixel felbontású képnél kb. 10-szer nagyobb felbontású kimeneti képet állított elő úgy, hogy az infravörös tartományban dolgozó alacsony felbontású kép egyes elemi részeit megfeleltette egy nagy felbontású, színes, RGB csatornákkal rendelkező kép bizonyos tartományainak. Az így létrejött kimeneti képekből már létrehozható a valós objektumot/tárgyat a virtuális térben reprezentáló megfelelője. Az általam kidolgozott és megvalósított eljárás a következő jellemzőkkel rendelkezik:

1. a fúziós algoritmus működéséhez szükség van a nagy felbontású színes képre és az alacsony felbontású hőképre, melyek páronként azonos nézőpontból készültek,
2. a kimenetként előálló képek alkalmasak 3D objektum építésére,
3. a- a módszer lehetővé teszi, hogy alacsony költségvetéssel nagy felbontású hőképek vagy térmodellek készüljenek.

Tézishez kapcsolódó tudományos közlemények: [T3][T4][T5]

3. Tézis

Megalkottam egy olyan eljárást, melynek segítségével lokális légszennyezettség mérése lehetséges alacsony tömegű, nagy érzékenységű, UAV-ra szerelhető szenzorok segítségével. A felmérni kívánt területet lefedő útvonal valós időben adaptívan tervezhető. Az eljárás eredményeként a 3D pozíciókhoz nagy mennyiségű 5D adat rendelhető. Az általam kidolgozott és megvalósított eljárás a következő jellemzőkkel rendelkezik:

1. az eljárás képes a szennyezés forrásának detektálására,
2. a rendelkezésre álló 3D pozíció adatok segítségével a felmért terület légi jellemzőinek vizualizációja lehetséges,
3. többszöri felmérést követően a szennyezés szóródása, terjedése kimutatható az idő függvényében.

Tézishez kapcsolódó tudományos közlemények: [T6]

4. Tézis

Megalkottam két, egymástól független eljárást, melyekkel sugárzó anyag pozícióját lehet meghatározni. Az eljárás részeként alacsony tömegű, nagy érzékenységű, UAV-re szerelhető szenzorokat használtam. A felmérni kívánt terület helyben vagy előre tervezhető, a

felmérés gyorsan végezhető, ezzel a felmérésben résztvevő személyek és eszközök sugárdózisa jelentősen csökken a hagyományos lokalizációs módszerekhez képest. Az általam kidolgozott eljárások képesek:

1. az eljárások képesek a szennyezés forrásának detektálására,
2. a rendelkezésre álló 3D pozíció adatok segítségével a felmért terület sugárzási jellemzőinek vizualizációja lehetséges.

Tézishez kapcsolódó tudományos közlemények: [T7][T8][T9]

8. fejezet

Szemléleti összefoglaló

A fentiekben bemutatott lehetőségekre, problémákra eljárásokat dolgoztam ki, melyek elméletét gyakorlati megvalósításokkal teszteltem és igazoltam. A képfeldolgozás során a multidimenziós adatok fúziójára és azok többleteredményére szemléletes felhasználási eseteket mutattam be.

Első témában egy egyértelmű, mindenki számára könnyen érthető témát elemeztem: épített kerti medencéket kerestem neurális hálózat és klasszikus képfeldolgozási algoritmusok segítségével. Az egyenként keletkezett eredményeket fuzionáltam és ezzel egy jobb minőségű objektum kereső eljárást dolgoztam ki.

A második téma alacsony felbontású hőképek használhatósági lehetőségeinek növelése és az alacsony áron elérhető hőkamerák képességeinek bizonyítására irányult. Az alacsony felbontású hőképek fuzionálhatóak nagy felbontású színhelyes képekkel, így az eljárást használó olcsón kaphat elemzésre alkalmas hőmodelleket.

Harmadik témában bemutattam, hogy nagy mennyiségű 3D adat elemzése és vizualizációja milyen módokon lehetséges egy hétköznapi probléma megoldása során. Az adatok begyűjtésére speciális szenzorokat használtam, melyek értékeihez 3D pozíció koordinátákat is rögzítettem. Az így nyert adathalmaz feldolgozása során előállt az az információ, ami alapján egyértelműen lokalizálható volt a szennyezési forrás. Térképre helyezve az adatokat megfelelő vizuális ábrázolás is elérhető volt.

Negyedik témában bemutattam, hogy nagy mennyiségű 3D adat begyűjtése, elemzése és vizualizációja milyen módokon lehetséges egy szélsőséges, valós probléma megoldása során.

A sugárzás bizonyos típusai az élő szervezeteket drasztikusan károsítják, elektronikus eszközöket működésképtelenné teszik. A bemutatott eljárás során sem emberi, sem anyagi kár nem keletkezik, mivel a kezelő távolról vezérli az adatok begyűjtését, a feldolgozás később történik meg. Az eljáráshoz egyedi szenzorokat építettem.

Mindegyik témában közös, hogy nagy mennyiségű adatot gyűjtöttem megszokott vagy egyedi módszerekkel, azokat feldolgoztam, elemeztem és többlet információt nyertem ki belőlük.

Az adatfeldolgozás kulcsfontosságú lépés az adattudományi munkafolyamatban, és magában foglalja az adatok tisztítását, átalakítását és elemzésre való előkészítését. Az adatfeldolgozás célja, hogy az adatok pontosak, következetesek és az adott feladatra, elemzésre alkalmasak legyenek. Az adatfeldolgozás több lépésre osztható, beleértve az adattisztítást, az adatátalakítást és az adatintegrációt. Az adattisztítás magában foglalja a hibák, következetlenségek és hiányzó értékek azonosítását és eltávolítását az adatokban. Az adatátalakítás magában foglalja az adatok elemzésre alkalmas formátumba való átalakítását, például az adatok normalizálását vagy összesítését. Az adatintegráció magában foglalja a több forrásból származó adatok kombinálását egyetlen, egységes adatkészlet létrehozására.

Az adatfeldolgozás elengedhetetlen lépése az adattudományi munkafolyamatnak, mivel biztosítja, hogy az adatok pontosak, következetesek és elemzésre használható formátumban legyenek. Segít az adatokban előforduló hibák vagy következetlenségek azonosításában és kijavításában is, ami javítja az elemzés pontosságát és megbízhatóságát. Megfelelő adatfeldolgozás nélkül az adatok elemzése megbízhatatlan lehet, pontatlan vagy ellentmondásos adatokból következtetéseket vonhatunk le.

Az adatfeldolgozás fontos szerepet játszik a big data területén is, ahol az adatok mennyisége, sebessége és sokfélesége megnehezíti a betekintést és a döntéshozatalt. A megfelelő adatfeldolgozási technikák alkalmazásával a big data hasznos információkká alakítható, amelyek felhasználhatók üzleti döntések meghozatalára, a működési hatékonyság javítására, sőt új termékek és szolgáltatások létrehozására is.

Összefoglalva, az adatfeldolgozás az adattudományi munkafolyamat döntő lépése, amely magában foglalja az adatok tisztítását, átalakítását és elemzésre való előkészítését. Fontos

szerepet játszik a pontos, konzisztens és használható adatok biztosításában, amelyek felhasználhatók az üzleti döntések meghozatalára, a működési hatékonyság javítására, sőt új termékek és szolgáltatások létrehozására is.

Az ismertetett megoldások egyaránt használhatóak civil, ipari, oktatási és hadiipari célokra is.

Irodalomjegyzék

- [1] Dimitrios Boursinos and Xenofon Koutsoukos. Assurance monitoring of cyber-physical systems with machine learning components. *arXiv preprint arXiv:2001.05014*, 2020.
- [2] Charles Hartsell, Shreyas Ramakrishna, Abhishek Dubey, Daniel Stojcsics, Nagabhusan Mahadevan, and Gabor Karsai. Resonate: A runtime risk assessment framework for autonomous systems. In *2021 International Symposium on Software Engineering for Adaptive and Self-Managing Systems (SEAMS)*, pages 118–129. IEEE, 2021.
- [3] Zsolt Domozi and Andras Molnar. Surveying private pools in suburban areas with neural network based on drone photos. In *IEEE EUROCON 2019-18th International Conference on Smart Technologies*, pages 1–6. IEEE, 2019.
- [4] Zsolt Domozi, Marta Takacs, and Andras Molnar. Pool detection with concurrent algorithms. In *2019 IEEE 19th International Symposium on Computational Intelligence and Informatics and 7th IEEE International Conference on Recent Achievements in Mechatronics, Automation, Computer Sciences and Robotics (CINTI-MACRo)*, pages 000223–000230. IEEE, 2019.
- [5] Konstantinos Kontos and Manolis Maragoudakis. Automated pool detection from satellite images using data mining techniques. *International Journal of Image Mining*, 2(2):85–99, 2016.
- [6] Gábor Kertész and Zoltán Vámosy. Current challenges in multi-view computer vision. In *2015 IEEE 10th Jubilee International Symposium on Applied Computational Intelligence and Informatics*, pages 237–241. IEEE, 2015.

- [7] Zeyi Huang, Wei Ke, and Dong Huang. Improving object detection with inverted attention. In *2020 IEEE winter conference on applications of computer vision (WACV)*, pages 1294–1302. IEEE, 2020.
- [8] Anna Lempart, Edyta Kudlek, and Mariusz Dudziak. Identification of micropollutants occurring in swimming pools. In *Proceedings*, volume 16, page 25. MDPI, 2019.
- [9] Dániel Stojcsics, László Somlyai, and András Molnár. Unmanned aerial vehicle guidance methods for 3d aerial image reconstruction. In *2013 IEEE 9th International Conference on Computational Cybernetics (ICCC)*, pages 321–326. IEEE, 2013.
- [10] Yogesh Tayal, Ruchika Lamba, and Subhransu Padhee. Automatic face detection using color based segmentation. *International Journal of Scientific and Research Publications*, 2(6):1–7, 2012.
- [11] Dr Sucharitha and Ranjan Senapati. Optimized image retrieval using hsv color space, local edge binary patterns and zernike moments. *J Eng Appl Sci*, 13:6777–6786, 2018.
- [12] Máté Tóth, Dániel Stojcsics, Zsolt Domozi, and István Lovas. Fuzzy based indoor navigation for mobile robots. In *2018 IEEE 16th International Symposium on Intelligent Systems and Informatics (SISY)*, pages 000333–000338. IEEE, 2018.
- [13] Gábor Kertész, Sándor Szénási, and Zoltán Vámosy. Multi-directional image projections with fixed resolution for object matching. *Acta Polytechnica Hungarica*, 15(2):211–229, 2018.
- [14] David G Lowe. Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60:91–110, 2004.
- [15] Hang Qi, Matthew Brown, and David G. Lowe. Low-shot learning with imprinted weights. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2018.

- [16] David G Lowe. Object recognition from local scale-invariant features. In *Proceedings of the seventh IEEE international conference on computer vision*, volume 2, pages 1150–1157. Ieee, 1999.
- [17] Daniel Stojcsics, Istvan Lovas, Zolt Domozi, and Andras Molnar. High resolution 3d thermal imaging using flir duo r sensor. In *2018 IEEE 22nd International Conference on Intelligent Engineering Systems (INES)*, pages 000311–000316. IEEE, 2018.
- [18] A Molnar, I Lovas, and Z Domozi. Photogrammetry on low resolution thermal pictures. In *Proceedings of the Sixth International Conference on Parallel, Distributed, GPU and Cloud Computing for Engineering”, Civil-Comp Press, Stirlingshire, UK, Paper*, volume 30, 2019.
- [19] Zhengyou Zhang. A flexible new technique for camera calibration. *IEEE Transactions on pattern analysis and machine intelligence*, 22(11):1330–1334, 2002.
- [20] Stephen Vidas, Peyman Moghadam, and Michael Bosse. 3d thermal mapping of building interiors using an rgb-d and thermal camera. In *2013 IEEE international conference on robotics and automation*, pages 2311–2318. IEEE, 2013.
- [21] András Molnár, István Lovas, and Zolt Domozi. Practical application possibilities for 3d models using low-resolution thermal images. *Acta Polytech. Hung*, 18:199–212, 2021.
- [22] Dániel Balla, Marianna Zichar, Anikó Kozics, Tamás Mester, Tomáš Mikita, József Incze, and Tibor József Novák. A gis tool to express soil naturalness grades and geovisualization of results on tokaj nagy-hill. *Acta Polytechnica Hungarica*, 16(6):191–205, 2019.
- [23] Xuexiu Zhao, Jiang He, Yanwen Luo, Nanxiong Huang, and Yilan Ni. Analysis of the thermal environment in pedestrian space using 3d thermography generated with unmanned aerial vehicles and infrared cameras. In *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium*, pages 4328–4331. IEEE, 2019.

- [24] Ha-Hyoung Jung and Joon Lyou. Matching of thermal and color images with application to power distribution line fault detection. In *2015 15th International Conference on Control, Automation and Systems (ICCAS)*, pages 1389–1392. IEEE, 2015.
- [25] Dorit Borrmann, Florian Leutert, Klaus Schilling, and Andreas Nüchter. Spatial projection of thermal data for visual inspection. In *2016 14th International Conference on Control, Automation, Robotics and Vision (ICARCV)*, pages 1–6. IEEE, 2016.
- [26] Márta Takács. Mamdani-type implication inference with degree of coincidence. 2003.
- [27] Marco Scaioni, Elisabetta Rosina, Luigi Barazzetti, Mattia Previtali, and Veronica Redaelli. High-resolution texturing of building facades with thermal images. In *Thermosense: Thermal Infrared Applications XXXIV*, volume 8354, pages 122–133. SPIE, 2012.
- [28] MC Harvey, JV Rowland, and KM Luketina. Drone with thermal infrared camera provides high resolution georeferenced imagery of the waikite geothermal area, new zealand. *Journal of Volcanology and Geothermal Research*, 325:61–69, 2016.
- [29] Andras Molnar. Innováció és fenntartható felszíni közlekedés - légköri emisszió vezérelt forgalomszervezés. conference, 8 2018.
- [30] Daniel Stojcsics, Zsolt Domozi, and Andras Molnar. Air pollution localisation based on uav survey. In *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 2546–2551. IEEE, 2018.
- [31] Athanasios Valavanidis, Konstantinos Fiotakis, and Thomais Vlachogianni. Airborne particulate matter and human health: toxicological assessment and importance of size and composition of particles for oxidative damage and carcinogenic mechanisms. *Journal of Environmental Science and Health, Part C*, 26(4):339–362, 2008.
- [32] Alexander Star, Vikram Joshi, Sergei Skarupo, David Thomas, and Jean-Christophe P Gabriel. Gas sensor array based on metal-decorated carbon nanotubes. *The Journal of Physical Chemistry B*, 110(42):21014–21020, 2006.

- [33] Daniel Stojcsics, Zsolt Domozi, and Andras Molnar. Air pollution localisation based on uav survey. In *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 2546–2551. IEEE, 2018.
- [34] András Molnár. A multi-rotor system for the collection and analysis of measurements to evaluate and spatially demonstrate the pollutants in the air. *International Journal of Advanced Robotic Systems*, 12(12):187, 2015.
- [35] László Somlyai, Antal Turóczy, and András Molnár. Atmospheric analyser for mobile robots. In *2012 IEEE 13th International Symposium on Computational Intelligence and Informatics (CINTI)*, pages 181–185. IEEE, 2012.
- [36] Lixin Li and Peter Revesz. Interpolation methods for spatio-temporal geographic data. *Computers, Environment and Urban Systems*, 28(3):201–227, 2004.
- [37] JC Pérez-Cobo, FJ Asencor, S Sanchez-Suero, and M Pérez-Arroyo. Brain potential mapping by a new method of polynomial interpolation. *Revista Espanola de Fisiologia*, 49(2):131–136, 1993.
- [38] Mathias Stolpe and Krister Svanberg. An alternative interpolation scheme for minimum compliance topology optimization. *Structural and Multidisciplinary Optimization*, 22:116–124, 2001.
- [39] Henrique S Malvar, Li-wei He, and Ross Cutler. High-quality linear interpolation for demosaicing of bayer-patterned color images. In *2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*, volume 3, pages iii–485. IEEE, 2004.
- [40] Seungyong Lee, George Wolberg, and Sung Yong Shin. Scattered data interpolation with multilevel b-splines. *IEEE transactions on visualization and computer graphics*, 3(3):228–244, 1997.
- [41] Jean-Daniel Boissonnat and Frédéric Cazals. Smooth surface reconstruction via natural neighbour interpolation of distance functions. In *Proceedings of the sixteenth annual symposium on Computational geometry*, pages 223–232, 2000.

- [42] Noboru Yamazoe and Norio Miura. Environmental gas sensing. *Sensors and Actuators B: Chemical*, 20(2-3):95–102, 1994.
- [43] Christophe Pijolat, Christophe Pupier, Muriel Sauvan, Guy Tournier, and René Lalauze. Gas detection for automotive pollution control. *Sensors and Actuators B: Chemical*, 59(2-3):195–202, 1999.
- [44] Cheng-Wei Fan and Junfeng Jim Zhang. Characterization of emissions from portable household combustion devices: particle size distributions, emission rates and factors, and potential exposures. *Atmospheric environment*, 35(7):1281–1290, 2001.
- [45] Paul G Burnet, Norman G Edmisten, Paul E Tiegs, James E Houck, and Rachel A Yoder. Particulate, carbon monoxide, and acid emission factors for residential wood burning stoves. *Journal of the air pollution control association*, 36(9):1012–1018, 1986.
- [46] Jacob D McDonald, Barbara Zielinska, Eric M Fujita, John C Sagebiel, Judith C Chow, and John G Watson. Fine particle and gaseous emission rates from residential wood combustion. *Environmental Science & Technology*, 34(11):2080–2091, 2000.
- [47] Tom G Farr, Paul A Rosen, Edward Caro, Robert Crippen, Riley Duren, Scott Hensley, Michael Kobrick, Mimi Paller, Ernesto Rodriguez, Ladislav Roth, et al. The shuttle radar topography mission. *Reviews of geophysics*, 45(2), 2007.
- [48] Bernhard Rabus, Michael Eineder, Achim Roth, and Richard Bamler. The shuttle radar topography mission—a new class of digital elevation models acquired by spaceborne radar. *ISPRS journal of photogrammetry and remote sensing*, 57(4):241–262, 2003.
- [49] Ondřej Šálek, Milan Matolín, and Lubomír Gryc. Mapping of radiation anomalies using uav mini-airborne gamma-ray spectrometry. *Journal of environmental radioactivity*, 182:101–107, 2018.
- [50] Yuki Sato, Shingo Ozawa, Yuta Terasaka, Masaaki Kaburagi, Yuta Tanifuji, Kuniaki Kawabata, Hiroko Nakamura Miyamura, Ryo Izumi, Toshikazu Suzuki, and Tatsuo

- Torii. Remote radiation imaging system using a compact gamma-ray imager mounted on a multicopter drone. *Journal of Nuclear Science and Technology*, 55(1):90–96, 2018.
- [51] Tomas Lazna, Petr Gabrlik, Tomas Jilek, and Ludek Zalud. Cooperation between an unmanned aerial vehicle and an unmanned ground vehicle in highly accurate localization of gamma radiation hotspots. *International Journal of Advanced Robotic Systems*, 15(1):1729881417750787, 2018.
- [52] Saku Mochizuki, Jun Kataoka, Leo Tagawa, Yasuhiro Iwamoto, Hiroshi Okochi, Naoya Katsumi, Shuntaro Kinno, Makoto Arimoto, Takuya Maruhashi, Kazuya Fujieda, et al. First demonstration of aerial gamma-ray imaging using drone for prompt radiation survey in fukushima. *Journal of Instrumentation*, 12(11):P11014, 2017.
- [53] Jacopo Aleotti, Giorgio Micconi, Stefano Caselli, Giacomo Benassi, Nicola Zambelli, Manuele Bettelli, and Andrea Zappettini. Detection of nuclear sources by uav teleoperation using a visuo-haptic augmented reality interface. *Sensors*, 17(10):2234, 2017.
- [54] Thomas Hinterhofer, Martin Pfennigbauer, Andreas Ullrich, Dieter Rothbacher, Stephan Schraml, and Michael Hofstätter. Uav-based lidar and gamma probe with real-time data processing and downlink for survey of nuclear disaster locations. In *Chemical, Biological, Radiological, Nuclear, and Explosives (CBRNE) Sensing XIX*, volume 10629, pages 38–47. SPIE, 2018.
- [55] Andras Molnar, Daniel Stojcsics, Istvan Lovas, and Zsolt Domozi. Gamma radiation distribution map creation using a small-sized drone. In *2018 IEEE 18th International Symposium on Computational Intelligence and Informatics (CINTI)*, pages 000161–000166. IEEE, 2018.
- [56] Dániel Stojcsics and András Molnár. Airguardian–uav hardware and software system for small size uavs. *International Journal of Advanced Robotic Systems*, 9(5):174, 2012.

- [57] László Somlyai, Antal Turóczy, and András Molnár. Atmospheric analyser for mobile robots. In *2012 IEEE 13th International Symposium on Computational Intelligence and Informatics (CINTI)*, pages 181–185. IEEE, 2012.
- [58] Sakari Pieskä, Mika Luimula, and Taisto Suominen. Fast experimentations with virtual technologies pave the way for experience economy. *Acta Polytechnica Hungarica*, 16(6):9–26, 2019.
- [59] Kai Vetter, Ross Barnowski, Joshua W Cates, Andrew Haefner, Tenzing HY Joshi, Ryan Pavlovsky, and Brian J Quiter. Advances in nuclear radiation sensing: Enabling 3-d gamma-ray vision. *Sensors*, 19(11):2541, 2019.
- [60] Carlos A Barajas, Jerimy C Polf, and Matthias K Gobbert. Deep residual fully connected neural network classification of compton camera based prompt gamma imaging for proton radiotherapy. *Frontiers in Physics*, 11:903929, 2023.
- [61] Roberto Accorsi and Scott D Metzler. Analytic determination of the resolution-equivalent effective diameter of a pinhole collimator. *IEEE transactions on medical imaging*, 23(6):750–763, 2004.
- [62] Jalil Islamian, AhmadReza Azazrm, Babak Mahmoudian, and Esmail Gharapapagh. Advances in pinhole and multi-pinhole collimators for single photon emission computed tomography imaging. *World journal of nuclear medicine*, 14(01):3–9, 2015.
- [63] Carlo Noviello, Giuseppe Esposito, Giancarmine Fasano, Alfredo Renga, Francesco Soldovieri, and Ilaria Catapano. Small-uav radar imaging system performance with gps and cdgps based motion compensation. *Remote Sensing*, 12(20):3463, 2020.
- [64] Philippe Anfre, Christophe Dujardin, Jean-Marie Fourmigue, Benot Hautefeuille, Kheirreddine Lebbou, Christian Pedrini, Didier Perrodin, and Olivier Tillement. Evaluation of fiber-shaped lyso for double readout gamma photon detection. *IEEE Transactions on Nuclear Science*, 54(2):391–397, 2007.

- [65] Andras Molnar, Istvan Lovas, and Zsolt Domozi. Measurement of outdoor gamma dose distribution with a multicopter. In *2020 IEEE 24th International Conference on Intelligent Engineering Systems (INES)*, pages 103–108. IEEE, 2020.
- [66] Andras Molnar, Zsolt Domozi, and Istvan Lovas. Drone-based gamma radiation dose distribution survey with a discrete measurement point procedure. *Sensors*, 21(14):4930, 2021.
- [67] A Molnar. Three-dimensional detection of gamma radiation and polluting gases using quadrocopters. *Herald of Dagestan State Technical University Technical Sciences*, 47(1):102–116, 2020.
- [68] Steve B Jiang, Greg C Sharp, Toni Neicu, Ross I Berbeco, Stella Flampouri, and Thomas Bortfeld. On dose distribution comparison. *Physics in medicine & Biology*, 51(4):759, 2006.
- [69] Shahrokh Valaee, Benoit Champagne, and Peter Kabal. Parametric localization of distributed sources. *IEEE Transactions on Signal Processing*, 43(9):2144–2153, 1995.
- [70] Dmitry Malioutov, Müjdat Cetin, and Alan S Willsky. A sparse signal reconstruction perspective for source localization with sensor arrays. *IEEE transactions on signal processing*, 53(8):3010–3022, 2005.
- [71] RH Dicke. Scatter-hole cameras for x-rays and gamma rays. *Astrophysical Journal*, vol. 153, p. L101, 153:L101, 1968.
- [72] W Good, A Kip, and S Brown. Design of beta-ray and gamma-ray geiger-müller counters. *Review of Scientific Instruments*, 17(7):262–265, 1946.
- [73] Martin Nikl. Scintillation detectors for x-rays. *Measurement Science and Technology*, 17(4):R37, 2006.
- [74] Su Yeon Choi and Dowan Cha. Unmanned aerial vehicles using machine learning for autonomous flight; state-of-the-art. *Advanced Robotics*, 33(6):265–277, 2019.

- [75] Lorenz Meier, Petri Tanskanen, Friedrich Fraundorfer, and Marc Pollefeys. Pixhawk: A system for autonomous flight using onboard computer vision. In *2011 ieee international conference on robotics and automation*, pages 2992–2997. IEEE, 2011.
- [76] Robert Finck, Antanas Bukartas, Mattias Jönsson, and Christopher Rääf. Maximum detection distances for gamma emitting point sources in mobile gamma spectrometry. *Applied Radiation and Isotopes*, 184:110195, 2022.
- [77] Bodor Áron Csaba. Koincidencia-korrekciók számítása gamma-spektroszkópiában. <https://atomfizika.elte.hu/akos/tezisek/tdk/bodoraron.pdf>, 2015.
- [78] M.G. LÖTTER. Nuclear medicine physics statistics for radiation measurement. https://humanhealth.iaea.org/HHW/MedicalPhysics/e-learning/Nuclear_Medicine_Handbook_slides/Chapter_05._Statistics_for_Radiation_Measurement.pdf.
- [79] Shuo Wan, Jiaxun Lu, Pingyi Fan, and Khaled B Letaief. Toward big data processing in iot: Path planning and resource management of uav base stations in mobile-edge computing system. *IEEE Internet of Things Journal*, 7(7):5995–6009, 2019.
- [80] Ondřej Šálek, Milan Matolín, and Lubomír Gryc. Mapping of radiation anomalies using uav mini-airborne gamma-ray spectrometry. *Journal of environmental radioactivity*, 182:101–107, 2018.
- [81] Alexander Parshin, Vladimir Morozov, Nikita Snegirev, Evgeniya Valkova, and Fedor Shikalenko. Advantages of gamma-radiometric and spectrometric low-altitude geophysical surveys by unmanned aerial systems with small scintillation detectors. *Applied Sciences*, 11(5):2247, 2021.
- [82] Kari Kurvinen, P Smolander, R Pöllänen, S Kuukankorpi, M Kettunen, and J Lyytinen. Design of a radiation surveillance unit for an unmanned aerial vehicle. *Journal of environmental radioactivity*, 81(1):1–10, 2005.
- [83] E Ikonen. Interference effects between independent gamma rays. *Physical review letters*, 68(18):2759, 1992.

- [84] VE Michalk and JA McIntyre. Population of nuclear energy levels via photon-excited levels. *Nuclear Physics A*, 137(1):115–128, 1969.
- [85] New York USA LND, Inc. Oceanside. 7808 — LND — Nuclear Radiation Detectors — lndinc.com. <https://www.lndinc.com/products/geiger-mueller-tubes/7808/>. [Accessed 03-01-2025].
- [86] András Molnár. Gamma radiation dose measurement using an energy-selective method with the help of a drone. *Sensors*, 22(23):9062, 2022.
- [87] András Molnár, Daniel Kiss, and Zsolt Domozi. Radiation source localization using a model-based approach. *Sensors*, 23(13):5983, 2023.
- [88] Ray L Frost. An infrared and raman spectroscopic study of the uranyl micas. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 60(7):1469–1480, 2004.
- [89] Matthew W Cooper, James H Ely, Derek A Haas, James C Hayes, Justin I McIntyre, Lance S Lidey, and Brian T Schrom. Absolute efficiency calibration of a beta-gamma detector. *IEEE Transactions on Nuclear Science*, 60(2):676–680, 2013.
- [90] András Molnár, Daniel Kiss, and Zsolt Domozi. Radiation source localization using a model-based approach. *Sensors*, 23(13):5983, 2023.
- [91] Zoltán Kvasznicza, István Gyurcsek, György Elmer, Viktor Bagdan, and Ildiko Horvath. Mathability of emc emission testing for mission crucial devices in gtem waveguide. *Acta Polytech. Hung*, 18:159–173, 2021.

Tézisekhez kapcsolódó tudományos közlemények

- [T1] Z. Domozi and A. Molnar, "Surveying private pools in suburban areas with neural network based on drone photos," IEEE EUROCON 2019 -18th International Conference on Smart Technologies, Novi Sad, Serbia, 2019, pp. 1-6, doi: 10.1109/EUROCON.2019.8861770.
- [T2] Z. Domozi, M. Takacs and A. Molnar, "Pool Detection with Concurrent Algorithms," 2019 IEEE 19th International Symposium on Computational Intelligence and Informatics and 7th IEEE International Conference on Recent Achievements in Mechatronics, Automation, Computer Sciences and Robotics (CINTI-MACRo), Szeged, Hungary, 2019, pp. 000223-000230, doi: 10.1109/CINTI- MACRo49179.2019.9105208.
- [T3] D. Stojcsics, I. Lovas, Z. Domozi and A. Molnar, "High Resolution 3D Thermal Imaging Using FLIR DUO R Sensor," 2018 IEEE 22nd International Conference on Intelligent Engineering Systems (INES), Las Palmas de Gran Canaria, Spain, 2018, pp. 000311-000316, doi: 10.1109/INES.2018.8523914.
- [T4] A., Molnár ; I., Lovas ; Z., Domozi „Photogrammetry on low resolution thermal pictures" In: P., Iványi; B. H., V. Topping (szerk.) Proceedings of the Sixth International Conference on Parallel, Distributed, GPU and Cloud Computing for Engineering, Pécs, Magyarország : Civil-Comp Press (2019) pp. 1-11. , 11 p.
- [T5] András, Molnár; István, Lovas; Zsolt, Domozi „Practical Application Possibilities for 3D Models Using Low-resolution Thermal Images" ACTA POLYTECHNICA HUNGARICA 18 : 4 pp. 199-212. , 14 p. (2021)
- [T6] D. Stojcsics, Z. Domozi and A. Molnar, "Air Pollution Localisation Based on UAV Survey," 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Miyazaki, Japan, 2018, pp. 2546-2551, doi: 10.1109/SMC.2018.00436.
- [T7] A. Molnar, I. Lovas and Z. Domozi, "Measurement of outdoor gamma dose distribution with a multicopter," 2020 IEEE 24th International Conference on Intelligent Engineering Systems (INES), Reykjavík, Iceland, 2020, pp. 103-108, doi: 10.1109/INES49302.2020.9147190.
- [T8] Molnar A, Domozi Z, Lovas I. Drone-Based Gamma Radiation Dose Distribution

Survey with a Discrete Measurement Point Procedure. *Sensors*. 2021; 21(14):4930.
<https://doi.org/10.3390/s21144930>

- [T9] Molnár A, Kiss D, Domozi Z. Radiation Source Localization Using a Model-Based Approach. *Sensors*. 2023; 23(13):5983. <https://doi.org/10.3390/s23135983>

További tudományos közlemények

- [K1] Z. Domozi, D. Stojcsics, A. Benhamida, M. Kozlovsky, and A. Molnar, “Real time object detection for aerial search and rescue missions for missing persons,” in 2020 IEEE 15th International Conference of System of Systems Engineering (SoSE 2020), 2020, pp. 000519–000524.
- [K2] M. András, S. Daniel, D. Zsolt, and L. István, “Gamma radiation distribution map creation using a small-sized drone,” in IEEE 18th International Symposium on Computational Intelligence and Informatics (CINTI 2018), 2018, pp. 161–166.
- [K3] M. András and D. Zsolt, “Some Practical Problems of Photogrammetry Based Volume Control of Open-pit Mines,” in 2018 IEEE 16th World Symposium on Applied Machine Intelligence and Informatics (SAMI), 2018, pp. 217–224.
- [K4] S. Daniel, D. Zsolt, and M. Andras, “Iterative Closest Point Based Volume Analysis on UAV Made Timeseries Large-scale Point Clouds,” in 2018 IEEE 16th International Symposium on Intelligent Systems and Informatics (SISY), 2018, pp. 69–74.
- [K5] S. Daniel, D. Zsolt, and M. Andras, “Advances in Automated Volume Analysis based on Large Scale Pointclouds,” *INTERNATIONAL JOURNAL OF SIMULATION SYSTEMS SCIENCE AND TECHNOLOGY*, vol. 19, no. 2, 2018.
- [K6] S. Daniel, D. Zsolt, and M. Andras, “Large-Scale Point Cloud Based Volume Analysis Acceleration Based on UAV Images,” in IEEE 12th International Symposium on Applied Computational Intelligence and Informatics (SACI 2018), 2018, pp. 51–56.
- [K7] S. Daniel, D. Zsolt, and M. Andras, “Automated Volume Analysis of Open Pit Mining Productions Based on Time Series Aerial Survey,” in 2018 UKSim-AMSS 20th International Conference on Computer Modelling and Simulation (UKSim), 2018, pp. 84–89.
- [K8] S. Dániel, D. Zsolt, and M. András, “Automated evaluation of agricultural damage using UAV survey,” *ACTA UNIVERSITATIS SAPIENTIAE AGRICULTURE AND ENVIRONMENT*, vol. 2018, no. 10, pp. 20–30, 2018.
- [K9] T. Máté, S. Dániel, D. Zsolt, and L. István, “Fuzzy Based Indoor Navigation for Mobile Robots,” in 2018 IEEE 16th International Symposium on Intelligent Systems

- and Informatics (SISY), 2018, pp. 333–338.
- [K10] T. Máté, S. Dániel, D. Zsolt, and L. István, “Stereo Odometry based Realtime 3D Reconstruction,” in 2018 IEEE 16th International Symposium on Intelligent Systems and Informatics (SISY), 2018, pp. 321–326.
- [K11] M. Andras and D. Zsolt, “Tracking Production Volumes of Open-Pit Mines with Photogrammetry,” in 2017 European Modelling Symposium (EMS), 2017, pp. 100–106.
- [K12] M. Andras and D. Zsolt, “Volume Analysis of Open-Pit Mines on the Basis of Photogrammetry Principles,” WSEAS TRANSACTIONS ON ENVIRONMENT AND DEVELOPMENT, vol. 13, no. 31, pp. 304–312, 2017.
- [K13] A. Molnár and Z. Domozi, “Volume analysis of surface formations on the basis of aerial photographs taken by drones,” International Journal of Signal Processing, Image Processing and Pattern Recognition, vol. 1, pp. 152–159, 2016.
- [K14] L. Kutor, Z. Domozi, G. Nagy, C. Peller, and T. Véső, “Object Identification and Local Information Services Using Near Field Communication,” in Regional Conference on Embedded and Ambient Systems RCEAS 2007, 2007, p. 10.