



M Ű E G Y E T E M 1 7 8 2

Budapesti Műszaki és Gazdaságtudományi Egyetem
Villamosmérnöki és Informatikai Kar
Hálózati Rendszerek és Szolgáltatások Tanszék

Tapolczai Péter

**MOZGÓ ZAJFORRÁSOK
ÉSZLELÉSE ÉS KÖVETÉSE
AKUSZTIKUS
NYALÁBFORMÁLÁSSAL**

Diplomaterv

KONZULENS

Dr. Rucz Péter

BUDAPEST, 2018

Tartalomjegyzék

Összefoglaló	5
Abstract	6
1 Bevezetés	7
1.1 Motiváció	7
1.2 Az akusztikai kamera	8
1.3 Akusztikus nyalábformálás	9
1.4 Kisméretű pilóta nélküli repülőgépek lesugárzási tulajdonságai	13
2 Forráslokalizációs képtisztító algoritmusok.....	16
2.1 MUSIC – Multiple Signal Classification.....	17
2.2 DAMAS – Deconvolution Approach for the Mapping of Acoustic Sources	20
2.3 CLEAN algoritmusok	22
2.3.1 CLEAN-PSF – CLEAN based on Point Spread Functions	22
2.3.2 CLEAN-SC – CLEAN based on Source Coherence.....	23
2.4 CS – Compressive Sensing.....	24
3 Forráskövetés alkalmazása.....	26
3.1 Forráslokalizáció	26
3.2 Kalman-szűrő	28
3.2.1 Optimális lineáris állapotbecslő.....	29
3.2.2 Unscented Kalman Filter (UKF)	31
3.3 Frekvenciakövetés alkalmazása.....	33
3.3.1 HPS - Harmonic Product Spectrum	33
4 Szimulációs környezet.....	35
4.1 Források	36
4.2 A hangtér elemei	36
4.3 Mikrofontömb – a MicrophoneArray osztály	37
4.4 Hullámterjedés modellezése – a Propagation osztály	37
4.5 Blokkfeldolgozás – a BlockBuffer osztály	37
4.6 Szűrés.....	38
4.7 Akusztikai fókuszálás – a SumAndDelay osztály	38
4.7.1 A blokkösszegzés problémája mozgó forrás esetén.....	40
4.7.2 Doppler-effektus vizsgálata.....	42

4.8 Képkalkotás – A MUSIC osztály	44
4.9 Forráslokalizáció – A LocateSources osztály	45
4.10 Forráskövetés – A Kalman osztály	47
4.11 Frekvenciakövetés – A FreqSearch osztály	50
5 Eredmények.....	52
5.1 Futási teljesítmény	55
6 C++ implementáció	58
7 Konklúzió.....	62
Köszönetnyilvánítás	64
Irodalomjegyzék.....	65

HALLGATÓI NYILATKOZAT

Alulírott **Tapolczai Péter**, szigorló hallgató kijelentem, hogy ezt a diplomatervet meg nem engedett segítség nélkül, saját magam készítettem, csak a megadott forrásokat (szakirodalom, eszközök stb.) használtam fel. Minden olyan részt, melyet szó szerint, vagy azonos értelemben, de átfogalmazva más forrásból átvettem, egyértelműen, a forrás megadásával megjelöltem.

Hozzájárulok, hogy a jelen munkám alapadatait (szerző(k), cím, angol és magyar nyelvű tartalmi kivonat, készítés éve, konzulens(ek) neve) a BME VIK nyilvánosan hozzáférhető elektronikus formában, a munka teljes szövegét pedig az egyetem belső hálózatán keresztül (vagy hitelesített felhasználók számára) közzétegye. Kijelentem, hogy a benyújtott munka és annak elektronikus verziója megegyezik. Dékáni engedéllyel titkosított diplomatervek esetén a dolgozat szövege csak 3 év eltelte után válik hozzáférhetővé.

Kelt: Budapest, 2018. 12. 07.

.....
Tapolczai Péter

Összefoglaló

Az akusztikus nyalábformáló módszerek lehetővé teszik nagynyereségű, irányított akusztikai antennák létrehozását irányérzéketlen mikrofonok felhasználásával. Zajforrások helyének, illetve elosztott források eloszlásának meghatározására ipari környezetben is gyakran alkalmazunk a nyalábformálás elvén működő mikrofontömböket. A pontos lokalizációt különféle utófeldolgozó – más néven képtisztító – algoritmusok segítik.

Jelen dolgozat célkitűzése az akusztikus nyalábformálás mozgó zajforrásokra történő alkalmazásának vizsgálata. A mozgó források észlelése, követése és akusztikai jellemzőinek megmérése számos kihívást foglal magában. Ilyen például a Doppler-hatás figyelembe vétele vagy a mozgó célpontra való akusztikai fókuszálás. Példaalkalmazásként a dolgozat egy pilótánélküli helikopter (UAC) észlelését és követését tűzi ki célul.

A dolgozatban bemutatom az akusztikus nyalábformálás elméletét, jelfeldolgozási vonatkozásait, illetve a forráslokalizációhoz használható képtisztító eljárásokat (MUSIC, DAMAS, CLEAN). Megvizsgálom a nyalábformáló módszerek működését mozgó zajforrások mellett, a vizsgálatokhoz felhasználok az általam készített, Matlab környezetben működő szimulációs keretrendszert. Saját algoritmusokat implementálok az észlelt mozgó források követésére nemlineáris Kalman-szűrő segítségével, valamint az ilyen forrásokra történő akusztikai fókuszálásra. A forrás követése során rotorzajra optimalizált frekvenciakövetést valósítok meg, a példaalkalmazáshoz köthető szimulációkat pedig egy quadrocopter előzetesen rögzített hangjával demonstrálok. A Matlab környezetben megvalósított funkciókat C++ programnyelvű környezetbe ültetem át a futásidő csökkentése céljából.

Abstract

Acoustical beamforming methods allow the creation of high-gain, directed acoustic antennas using non-directional microphones. To determine the location of noise sources and the distribution of spatially distributed sources, microphone arrays using beamforming principles are also utilized in numerous industrial applications. The exact localization is supported by various post-processing algorithms (also known as image-cleaning algorithms).

The aim of this thesis is to examine the application of acoustical beamforming to moving noise sources. The detection, tracking, and acoustical characterization of moving sources involve many challenges. One such example is to take the Doppler effect or acoustic focusing on the moving target into account. As an example application, the thesis aims to detect and track an unmanned helicopter (UAV).

In the thesis I present the theory of acoustical beamforming, its signal processing aspects, and the image-cleaning algorithms for source localization (MUSIC, DAMAS, CLEAN). I examine the operation of beamforming methods with moving noise sources, and use the simulation framework in a self-made Matlab environment for the tests. I implement my own algorithms for tracking detected moving sources using a nonlinear Kalman filter and acoustical focusing on such sources. During the tracking of the source, a frequency tracking procedure optimized for rotor noise is performed. I demonstrate the simulations associated with the sample application with a pre-recorded voice of a quadrocopter. I also adapted the functionality developed in Matlab environment into C++ programming language to reduce the processing time.

1 Bevezetés

1.1 Motiváció

Napjainkban sokféle helyzetben van szükség akusztikai iránymeghatározásra, képalkotásra, egy adott térrész vagy test által kibocsátott sugárzás mérésére. Előfordul azonban, hogy a lesugárzó felületre nem, vagy csak nehezen helyezhetők gyorsulásmérő szenzorok vagy mikrofonok, mivel az túlságosan nagy kiterjedésű, túl magas hőmérsékletű, nagy sebességgel mozgó, esetleg távol van, vagy pedig a mérési elrendezés kialakítása túl költséges.

Ezekben az esetekben akusztikai kamerát alkalmazhatunk. Akusztikai kamera segítségével fókuszálhatunk egy-egy forrásra, különböző algoritmusok segítségével képet alkothatunk a forráseloszlásról. A vizsgálandó felület és az akusztikai kamera távolsága nem korlátozott, az elérhető felbontás pedig a mikrofonok számától, egymáshoz képesti elhelyezkedésüktől, valamint a feldolgozó algoritmustól függ.

TDK dolgozatom témájának mozgó zajforrások észlelését és követését választottam akusztikus nyalábformálás segítségével. A dolgozatban bemutatott algoritmusokat és szimulációkat egy nagyobb projekt kapcsán valósítottam meg. A projekt célja mini és kisméretű pilóta nélküli eszközök (UAV) felderítését, mozgásának irányát meghatározni és követni képes, több távérzékelési technológia együttes felhasználásán alapuló szenzorrendszer kifejlesztése. A szenzorrendszer kifejlesztésével a robusztusság tovább növelhető, ugyanis mindegyik távérzékelési technológiának vannak korlátai. Akusztikus forráslokalizáció használata akkor előnyös, amikor sem a képi lokalizáció (pl. rossz látási viszonyok között, vagy éjszaka), sem pedig a rádiófrekvenciás iránymeghatározás (pl. az UAV nem bocsát ki rádiófrekvenciás jeleket) használható.

A csapatunk feladata a projekten belül akusztikai alapon működő észlelés és követés megvalósítása. A dolgozatban a projektből a saját munkámat, fejlesztéseimet mutatom be. A dolgozat célja szimulációs keretrendszer fejlesztése, amelyben minden kitzűzött feladat megoldásra kerül. Az algoritmusokat forgószárnyú eszközök észlelésére – mint amilyen egy pilóta nélküli repülőgép (drón) is – optimalizáltam.

A következő fejezetben szeretném bemutatni az akusztikus kamerák elvi hátterét, a mikrofontömbös érzékelés megvalósításának menetét. A feladat alapvetően két elkülöníthető részre osztható. Az egyik a forráslokalizáció, mely során különböző algoritmusok és akusztikai képalkotás segítségével meghatározzuk a források pozícióit. A másik az akusztikai nyalábformálás, mely során egy adott forrásra fókuszálva annak hangját a hangtérből a többi forrás és a háttérzaj kiszűrésével kiemeljük. Jelen alkalmazásban a két rész teljesen elkülönülten nem képes megfelelően működni, ugyanis a nyalábformálás során felhasználjuk a lokalizáció által számított pozíciót, míg a lokalizáció során is felhasználhatjuk a nyalábformálásból megkapott akusztikai jelet. Ezzel mozgó forrásokra alkalmazva a lokalizáció és az akusztikai fókuszálás részfeladatai egy visszacsatolt rendszer elemeiként jelennek meg.

1.2 Az akusztikai kamera

A projekt egyik feladata egy akusztikus kamera létrehozása. Ebben a részben az akusztikus kamerák kerülnek ismertetésre, bemutatásra.

Az akusztikus kamera egy olyan eszköz, melynek segítségével képesek vagyunk a különböző irányokból érkező hangokra való fókuszálásra, vagy éppen azok elnyomására, illetve a hangtérben a források amplitúdójának képi megjelenítésére. E két alapfeladat mellett jelfeldolgozási technikákkal rengeteg funkciót meg lehet még valósítani, úgy, mint forráslokalizációt, -követést, -azonosítást vagy -analízist. Az akusztikai kamera alapvetően három részegységre bontható: mikrofontömb; A/D átalakító; szoftver.


A mikrofontömb egy több mikrofonból álló rendszer. A mikrofonok elhelyezkedhetnek sokféle elrendezésben, úgy, mint gömb, spirál, négyzetrács, stb. A mikrofonok a térben elhelyezett mintavételi pontoknak tekinthetőek, mely során a jelkülönbségek segítségével fókuszálni lehet különböző irányokra, távolságokra. A működési elve megegyezik az elektromágneses antennarendszerekével.

Két különböző elrendezésű akusztikai kamerát mutat a 1. ábra. Ahogy az ábrán is látható, a mikrofontömb mellé sokszor optikai kamera is társul, így az optikai kép és akusztikai forrástérkép egyszerre jeleníthető meg, ami az elemzés során megkönnyítheti az egyes források azonosítását.

A mikrofonok elrendezése befolyásolja a mikrofontömb karakterisztikáját. Ez magában foglalja azt, hogy milyen széles frekvenciatartományban ideálisak az akusztikai kamera paraméterei, valamint a főnyaláb-szélességet és a melléknyalábok számát, nagyságát is.

Az A/D átalakító segítségével a mikrofonok jeleit külön-külön digitalizáljuk, majd a jelfeldolgozás már digitálisan történik. Lehetőség lenne analóg módon is összegezni a jeleket, az egyes mikrofonok után vezérelhető fázistolókat és csillapítókat beépítve. Azonban a digitális jelfeldolgozás napjainkban sokkal hatékonyabb módszer.

Az utolsó lépésben pedig a szoftveres feldolgozás következik egy adott processzoron, ami lehet hagyományos CPU, DSP, esetleg GPU. A DSP a digitális jelfeldolgozó processzor, a GPU pedig a grafikai processzor rövidítése. Ezekben a lépésekben megtörténnek a kívánt számítások, amik lehetnek képképzés, -tisztítás, forráslokalizáció, spektrális elemzés, stb. [1][2][3]



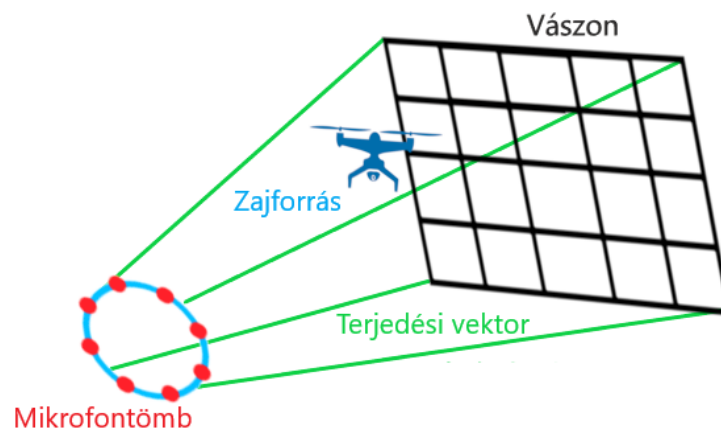
1. ábra Különböző elrendezésű mikrofontömbök

1.3 Akusztikus nyalábformálás

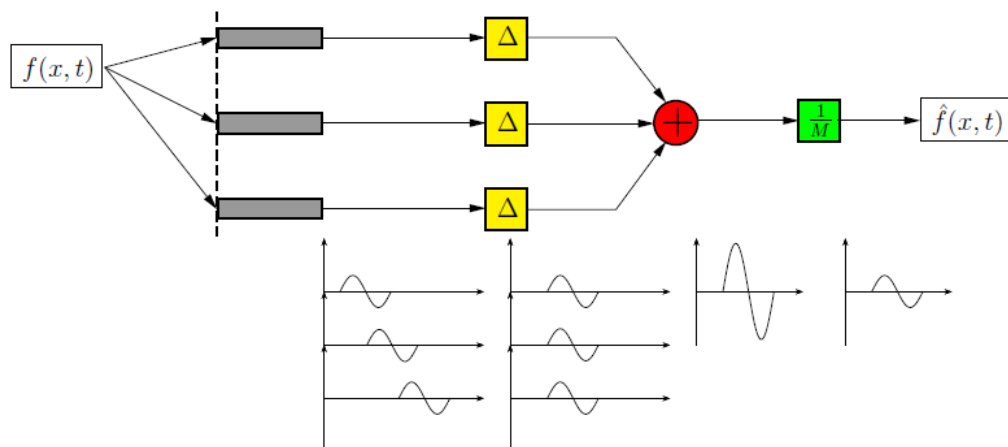
Egy akusztikus kamera megvalósításának alapja a nyalábformálás. Ennek során egy adott felület, vagy térrész összes pontját végigpásztázzuk, és mindig az éppen vizsgált pontra „fókuszáljuk” a különböző mikrofonok jeleit. Az elrendezést a 2. ábra vázolja. A kiválasztott térrész pontjai elvileg tetszőleges ponthalmaz pontjai lehetnek, a gyakorlatban azonban ezeket egy sík- vagy gömbfelületen adott rács csomópontjaiban szokás felvenni, mivel így a pásztázás eredményeként kapott amplitúdókat könnyű vizualizálni. A letapogatott pontokat virtuális forráspozícióknak is szokás nevezni, a

pontok sokaságát pedig képsíknak, vagy vászonnak. Minden egyes virtuális forráspozícióból a mikrofonokhoz a hullámterjedésből adódó fázistolást és csillapítást az ún. terjedési vektorok adják meg.

Egy adott forráspozícióra való fókuszálás a fázistolások késleltetéssel történő kompenzációját majd opcionális erősítés/csillapítás utáni összegzését jelenti. Ezt a módszert „Delay and sum” nyelábformálásnak is nevezik, blokk-sémáját pedig a 3. ábra szemlélteti. Amikor éppen arra a pontra fókuszáltunk, ahol valóban forrás volt, ott az összes mikrofon jele az eltolás után fázisban lesz, így maximális jelszintet kapunk. Azokban a pontokban azonban, ahol nincsen forrásunk, a mikrofonok jelei nem kerülnek fázisba, kölcsönösen gyengítik egymást, kioltások keletkezhetnek. Természetesen ezek az állítások akkor érvényesek, ha betartjuk a térbeli mintavételezés szabályait. Egy adott frekvencia felett olyan helyeken is fázisba kerülhet az összes mikrofon jele, ahol nincs forrás, ebben az esetben szellemforrások fognak megjelenni. Amennyiben azonban a hullámhossz jóval nagyobb a mikrofonok egymáshoz képesti távolságainál, abban az esetben a képünk túlságosan homályos, „szétkent” lesz. Az akusztikai képet más néven amplitúdótérképnek nevezzük, ezen ábrázoljuk az adott térrészekben észlelt jelszinteket. Mindig érdemes a mikrofonok távolságát a vizsgált frekvenciatartományhoz beállítani, vagy olyan mikrofonelrendezést alkalmazni, ami széles frekvenciatartományban üzemel.




2. ábra Akusztikus nyelábformálás elrendezésének vázlata

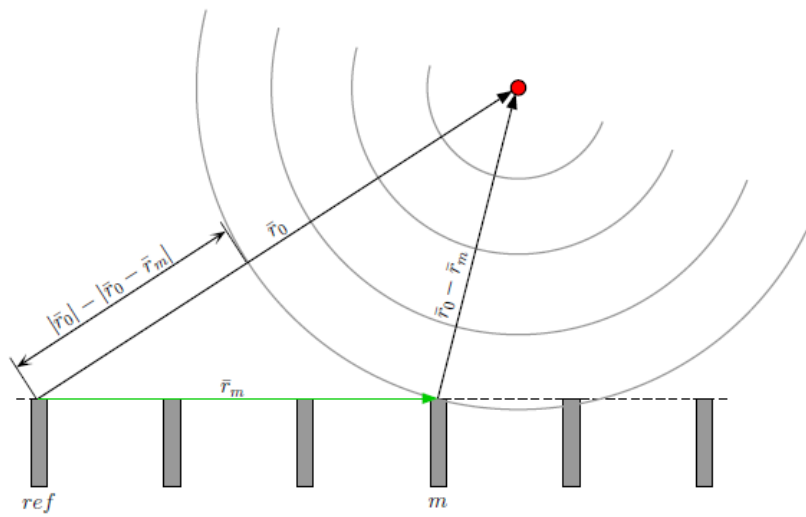


3. ábra Delay and sum nyálábformálás működési elve

Nyalábformálás módját tekintve szükséges megkülönböztetni a véges és a végtelen messzinek tekintett forrásokat. Előbbi esetben a feltételezett hullámfront egy síkfelület lesz, minden mikrofonhoz azonos szintű jel érkezik, csupán fázisban eltérő a jel. A nyálábformálásban kizárólag a beesési szög játszik szerepet, a távolság nem. Ezt az elrendezést szemlélteti a 4. ábra. Nem végtelen messze található forrásoknál azonban a hullámfront egy gömbfelület, a mikrofonokhoz különböző jelszintek érkezik a gömbfelületből adódó jelszint távolságfüggése miatt, emellett a fázisok is eltérőek. Ez esetben a nyálábformálás során a beesési szögön kívül figyelembe kell venni az adott mikrofon és a forrás távolságát is, azzal korrigálni. Érdeemes megjegyezni, hogy gömbhullám esetén minden egyes mikrofonhoz más beesési szöggel érkezik a jel a forrásból, így a szöget is egyedileg kell számítani minden mikrofonra. A véges fókusz távolságú elrendezést az 5. ábra mutatja. [4]



4. ábra Végtelen fókuszú nyalábformálás



5. ábra Véges fókuszú nyalábformálás

1.4 Kisméretű pilóta nélküli repülőgépek lesugárzási tulajdonságai


Annak érdekében, hogy az algoritmusainkat elektromos motorokkal felszerelt pilóta nélküli repülőgépek követésére optimalizáljuk, szükséges ezen eszközök lesugárzási tulajdonságainak ismerete is. Ritecz Tamás hallgató elvégzett egy ehhez kapcsolódó mérést, az ő méréseire alapozva vizsgáltam a spektrális tulajdonságokat. [5] A mérések során egy quadrokopter, vagy más néven négyrotoros drón lesugárzási tulajdonságai kerültek meghatározásra. A mérések a BME HIT akusztikai süketszobájában történtek, így a reflexiómentesség biztosítva volt. A lesugárzás iránykarakteristikája egy teljes gömbfelületen rögzítésre került, széles fordulatszám-tartományon, és egy, kettő illetve négy üzemelő motorral is. A mérések alapján egy quadrokopter jó közelítéssel irányítatlan sugárzóként modellezhető, így a szimulációs környezetünkben is ezzel a feltételezéssel élünk.

A vizsgálataim során négy darab motor által keltett zajt vizsgáltam, percenkénti 6000-es fordulatszámon. Egy adott fordulatszámon forgó légsavár lesugárzási alapfrekvenciája megkapható a következők szerint:

$$f_0 = \frac{rpm}{60} \cdot N,$$

ahol *rpm* (Rotation per minute) a fordulatszám 1/percben, *N* pedig a légsavár lapátainak száma. A vizsgált rotor két lapátból állt, így megkapható, hogy 6000-es fordulatszám esetén 200 Hz alapfrekvenciájú lesugárzást várunk. Ezt az alapfrekvenciát lapátfrekvenciának (BPF – Blade Passing Frequency) is nevezzük. A lesugárzott zajban az alapfrekvencia felharmonikusain is számottevő jelteljesítményre számíthatunk.

A jelmintából Gyors-Fourier Transzformáció segítségével megkapható a lesugárzási spektrum, ezt mutatja a 6. ábra. Az ábrán a drónnal egy vízszintes síkban, 1 m távolságra elhelyezett mikrofon által vett jel hangnyomásszintje látható.




6. ábra. Négyrotoros helikopter zajlesugárzásának amplitúdóspektruma széles frekvenciasávban.

A teljes spektrumon megfigyelhetjük, hogy két elkülöníthető komponens van jelen, egy a maximum jelszintet tartalmazó komponens 8 kHz környékén, és egy több felharmonikkal bíró periodikus jel 2 kHz alatt.

A 8 kHz középpontú komponensről a vizsgálataink során megállapítottuk, hogy ezt az erős jelszintet a motorvezérlő zaja okozza. Mivel ennek a komponensnek a nagysága és frekvenciája eszközönként eltérhet, esetleg más motortípus vagy motorvezérlési mód esetén nem is létezhet, így erre a tartományra nem tudjuk a követést alapozni. Ezzel a tartománnyal az egyik probléma még, hogy a légkör abszorpciós tulajdonságaiból adódóan ilyen magas frekvenciák a távolság növekedésével jobban szenvednek csillapítást, mint az alacsonyabbak.

Az 7. ábra mutatja a lesugárzási spektrumot 2 kHz alatt. Amint megfigyelhetjük, ebben a tartományban a legerősebb komponens 200 Hz-nél található, a vizsgálataink szerint ez a rotor által keltett zaj alapfrekvenciája. Ahogy az ábrán is jelölésre került, a rotorzaj erős harmonikustartalommal rendelkezik, még 2 kHz-n is észlelhetők az alapfrekvencia harmonikusai. Mivel a kisméretű drónok forgószárnyakkal rendelkeznek, így ezen a tartományon minden eszköz lesugárzása jellegre hasonló. A harmonikustartalmat felhasználva kisebb jel-zaj viszony esetén is észlelhetőnek tűnik a zajforrás, valamint a lesugárzott hang frekvenciájának mérésével a rotorok fordulatszámát is meg lehet állapítani. Az r mérési távolság növelésével a geometriai $1/r$

alakú csillapítás határozza meg a mért szintet. A jel-zaj viszony – ezzel pedig az érzékelés hatótávolsága – a mikrofonok számának emelésével növelhető.



7. ábra Négyrotoros helikopter zajlesugárzásának amplitúdóspektruma a 0–2 kHz frekvenciasávban

Egy drón esetén még adott pozíció tartása közben is a legritkább esetben fordul elő, hogy a rotorok azonos fordulatszámra forogjanak. A navigáció és szabályzás folyamatos korrekcióiból adódóan az egyes rotorok nyugalmi helyzetben is egymáshoz képest valamelyest eltérő, enyhén ingadozó fordulatszámra forognak. Ezekben az esetekben természetesen a spektrumképünk nem lesz ilyen tiszta, a rotorok által keltett lesugárzási spektrumképek összeadódnak, a fenti ábrákon látható harmonikusokhoz tartozó vonalak pedig kiszélesednek.

2 Forráslokalizációs képtisztító algoritmusok

Mint már a korábbi fejezetekben említésre került, a hagyományos nyálábformálással különböző problémák fordulhatnak elő. Ilyen például a melléknyalábok zavaró hatása, mely szellemforrások megjelenését okozza, vagy éppen a túl nagy főnyalábszélesség (elmosódás). Forráskép készítése során az akusztikai kamera forráspontjával pásztázzuk végig a kívánt vásznat vagy teret. A pásztázás során egy adott idejű jelszakaszból a vászon összes pontjára kiszámítjuk a jelszintet. Amennyiben a pásztázás során éppen egy olyan pontra fókuszálunk, ahol egy melléknyaláb található, úgy az adott irányból egy nem létező forrást detektálunk, ugyanis azt a főirányban levő forrás okozta, nem az adott irányban levő forrás. Másként megfogalmazva ezeket az okozza, hogy a mért amplitúdótérkép a valós forráseloszlás és a mikrofontömb okozta karakterisztika konvolúciójaként adódik, ami az amplitúdótérkép térbeli felbontását csökkenti. A térben pontszerű, egységnyi erősségű forrás által adott amplitúdótérképet (az akusztikai kamera térbeli impulzusválasztát) PSF-nek (Point Spread Function) nevezzük. Képtisztító algoritmusok segítségével megkísérelhető a dekonvolúció, vagyis a hamis források kiszűrhetővé válnak, valamint a főnyaláb szélessége is csökkenthető.

A forráslokalizációs algoritmusok az elosztott szenzorok (pl. mikrofontömb) által vett jelek közötti fázis- és amplitúdókülönbségek értékelésén alapulnak. Az adatfeldolgozás történhet idő- és frekvenciatartományban is. Az ebben a dolgozatban ismertetett metódusok mindegyike frekvenciatartományban dolgozik, és a mikrofonok jeleinek keresztkorrelációs mátrixán (CSM) alapul.

A keresztkorrelációs mátrix kiszámítása a következő alapon történhet: Felbontjuk az időtartományi jeleinket K hosszúságú (csatornánként K mintát tartalmazó) blokkokra, melyeken Gyors Fourier-Transzformációt (későbbiekben: FFT) hajtunk végre. Minden diszkrét frekvenciára a komplex hangnyomás értékek egy $p_k \in \mathbb{C}^M$ vektorban tárolódnak, melynek annyi sora van, ahány mikrofon jelét használtuk. A csatornák közötti „cross-spectra” mátrix formában kerül kiszámításra és tárolásra minden blokk számára. A keresztkorrelációs mátrixot megkapjuk az összes „cross-spectra” átlagolásával:

$$C = \frac{1}{K} \sum_{k=1}^K p_k p_k^H$$

A keresztkorrelációs mátrix főátlója tartalmazza a mikrofoncsatornák autospektrumát, amely nem hordoz a mikrofonok közötti fáziskülönbségekre utaló adatot. Jóllehet a főátló tartalmazhat a mérésből származó korrelálatlan zajt, azonban a későbbiekben tekinthető nullának az értéke. Azt feltételezzük tehát, hogy minden mikrofon egymáshoz képest korrelált jeleket vesz.

A hagyományos delay-and-sum módszer a frekvenciatartományban a következőképpen írható fel:

$$b(x_t) = h^H(x_t)Ch(x_t), \quad t = 1 \dots N \quad (1)$$

ahol $b(x_t)$ tartalmazza a négyzetes hangnyomás-szintet az x_t fókuszpontban. Az akusztikus forrásleképzéshez a források tárolására feltételezett térbeli tartományt N fókuszpontokból álló rács jellemzi. A h forgatási (terjedési) vektor tartalmazza a fázistolást és az amplitúdókorrekciót. Ez a mért vagy modellezett átviteli függvények alapján kerül kiszámításra. Homogénnek tekinthető hangtérben a terjedési vektorok a távolságból, a hangsebességből és a frekvenciából egyszerűen számíthatók mind sík-, mind gömbhullámú terjedési modellt feltételezve. A h vektor további súlyozásokat is tartalmazhat a karakterisztika javítása céljából. A súlyozás változtatásával a főnyalábszélesség, és ennek következtében a melléknyalábok nagysága is befolyásolható, azonban ezt a mikrofonok elhelyezése nagyban befolyásolja.

A következőkben a leggyakrabban alkalmazott három algoritmust mutatom be: a MUSIC, a DAMAS és a CLEAN (-SC és -PSF) algoritmust. Ezek közös jellemzője, hogy a hagyományos nyalábformálásnál pontosabb forráslokalizációt tesznek lehetővé, működési elvük, számításigényük, és felhasználási módjuk azonban más és más. A MATLAB szimulációs környezetben mind a három algoritmust implementáltam, a szemléltető ábrák is ebben a környezetben készültek. Ezen kívül bemutatok egy új módszert, ami napjainkra vált gyakran kutatott témává, a Compressive Sensing (CS) metódust.[6]

2.1 MUSIC – Multiple Signal Classification

A MUSIC algoritmus inkohereus források helyének feltérképezésére használható. Az eljárás a pásztázás során minden pontról megbecsüli, hogy az adott pontban elhelyezett forrás a mért adatokkal konzisztens kimenetet adna-e figyelembe véve, hogy kevés számú forrás aktív egyszerre. Az algoritmus egy egyszerű és kis számításigényű

iránybecslő eljárás, amelyet elektromágneses iránymérési eljárásokban (többantennás vétel pl. helymeghatározás során) alkalmaznak. A módszer a mikrofontömb korrelációs mátrixának sajátvektor-sajátérték elemzésén alapul.

Az algoritmus során a vizsgált frekvenciatartománynak megfelelő hosszúságú jelrészleteket veszünk, majd ezeken elvégezzük a Gyors Fourier-transzformációt. A jelrészletek hosszúságát úgy határozzuk meg, hogy egy blokkba legalább néhány periódus beleférjen. Ezután megtörténik a korrelációs mátrix számítása, majd a sajátvektor–sajátérték analízis. Az algoritmus a becsült források számának megfelelő legnagyobb sajátértékekhez tartozó sajátvektorokat veszi figyelembe, majd megtörténik a terjedési vektorok vetítése ezekre a sajátvektorokra:

$$G_U = U(U^H U)^{-1} U^H$$

Ahol U a jeltér bázisa, amit a kiválasztott sajátértékekhez tartozó sajátvektorok feszítenek ki, G_U pedig a vetítés mátrixa. A források összes pontját végigpásztázva minden egyes pontra meghatározhatók a $h_n = h(x_n)$ terjedési tényezők. Ha a terjedési vektor és a jel altérre vett vetülete között a bezárt szög kicsi (azaz, a terjedési vektor jól illeszkedik a jeltérbe), azt jelenti, hogy az n -edik pontban forrás található. Az n ponthoz tartozó terjedési vektor hajlásszögét a következő módon határozhatjuk meg:

$$\theta = \arccos\left(\frac{(G_U h_n) \cdot h_n}{|G_U h_n| |h_n|}\right)$$

A gyakorlatban a hajlásszög koszinuszának négyzetét ábrázolva kapjuk a források eloszlását a forrásokon, ez tehát az ábrázolandó amplitúdótérkép.

Egyik hátránya az algoritmusnak, hogy csak inkoherens forrásokra működik. Másik hátránya, hogy előre szükséges megadni a becsült források számát, adott számú forrásra generálódik a kép. A frekvenciatartománybeli algoritmusokra jellemző módon ez esetben is többszöri végrehajtás során lehetőség van egy adott frekvenciatartomány végigpásztázására is.

A források szám előzetes megbecslésére adódó módszer, hogy a növekvő sorba rendezett sajátértékek sorában megkeressük azt a pontot, ahol a legnagyobb a hányados két szomszédos sajátérték között. Ahol ezt a pontot találjuk, addig fog tartani a zajtér, a többi sajátértéket pedig a jeltér elemeinek vesszük. Rádiós iránybecslés során ezt a módszert előszeretettel alkalmazzák, ugyanis beltérben vagy városi környezetben a reflexiók miatt nem lehetséges előre megbecsleni a források számát. Felmerül

ugyanakkor a kérdés, hogy reflexiókkal gyarapított környezetben hogyan képes egy inkoherens források azonosítására alkalmas algoritmus működni. A válasz erre az, hogy rádiós alkalmazások során jóval nagyobb mintavételi frekvenciákkal dolgoznak, és a reflexiók valamint a fading is folyamatosan változik, így a vizsgált időablakokban inkoherensnek tekinthetők már az ugyanattól a forrástól különböző utakon érkező jelek.

Akusztikai alkalmazás során azonban nem várható, hogy a reflexiók inkoherens forrásoknak tekinthetők a nagy hullámhosszok miatt, így csak közel reflexiómentes környezetben alkalmazható az algoritmus. Mivel mi mozgó zajforrások, azon belül pilóta nélküli repülőgépek követhetőségének a vizsgálatát tűztük ki célul, így szabadtéri alkalmazást feltételezünk kis sűrűséggel beépített területeken. Ilyen környezet akusztikai szempontból már reflexiómentesnek tekinthető, így az algoritmus használata elméletileg lehetséges.

A kis számításigény ára, hogy a metódus csak egy bizonyos frekvencia felett képes a források intenzitását és helyét pontosan megbecsülni, e frekvencia alatt a kimeneten nem várt eredmények jelenhetnek meg, e felett viszont a többi vizsgált algoritmusnál pontosabban becsül meg minden paramétert. Szakirodalom kutatás során azt találtuk, hogy ez a frekvencia az ún. Helmholtz-szám négyszeresével becsülhető. [7] A képletben f a vizsgált frekvencia, d a mikrofontömb legnagyobb kiterjedése (átmérője), c pedig a hangsebesség.

$$He = \frac{fd}{c}$$

Az általunk alkalmazni kívánt, 2 méter átmérőjűre tervezett kör alakú 24 mikrofonból álló tömb esetére azt kapjuk, hogy ez a frekvencia megközelítőleg 685 Hz. Mint az előzőekben már ismertetésre került a drónok által keltett zaj spektrális felbontása, így kijelenthető, hogy kb. 200 Hz alaphang mellett még az 1000 Hz feletti harmonikusok is kellő erősséggel vannak jelen a spektrumban. Ekkora mikrofontömb-átmérő mellett így az algoritmus alkalmazhatónak tűnik.

Általánosan elmondható tehát, hogy a fent említett megkötések mellett egy jól alkalmazható algoritusról beszélünk. Kis, ill. párhuzamosítható számításigénye miatt valósidejű felhasználások során is alkalmazható, ami lehetővé teszi mozgó források követésére is.

2.2 DAMAS – Deconvolution Approach for the Mapping of Acoustic Sources

A DAMAS algoritmust a célból fejlesztették ki, hogy az akusztikai kép tisztább legyen, kiszűrje a hibásan detektált forrásokat, és a tényleges források intenzitását és helyét minél pontosabban becsülje meg. A módszer a nyálábformálás karakterisztikáját igyekszik kitörölni, így a kép kitisztul és a hamis források is eltűnnek. Ezt – mint a nevéből is következtethetünk rá – dekonvolúcióval próbálja elérni, ha a vett jeleket dekonvolváljuk az akusztikai kamera (térbeli) impulzusválaszával, visszakapjuk az eredeti forráseloszlást.

Az algoritmus Brooks és Humphreys által leírtak [8] alapján a valós b' forráseloszlást kísérli visszaállítani a következő egyenletrendszer segítségével:

$$b = Pb', \quad (2)$$

ahol b egy N elemszámú vektor, ami az (1) egyenlet eredményeként adódik. A P mátrix oszlopai tartalmazzák a terjedési vektorokat minden pásztázott pontból minden más pásztázott pontra. Mivel P szinguláris, így SVD felbontás során azt az eredményt kapjuk, hogy P rangja nagyon alacsony is lehet – gyakran kevesebb mint 25%-a a mátrix méretének. Ez azt jelenti, hogy nagyon nagyszámú megoldás létezik. Az egyenletrendszer így egy módosított Gauss-Seidel algoritmus segítségével kerül megoldásra. Ezt az iteratív megoldási eljárást ritka mátrixú egyenletrendszerénél, vagy nagy elemszámú egyenletrendszerénél alkalmazzák. Kellő számú iteráció után a megoldás közelíteni fog az egyenletrendszer valós megoldásához. Az algoritmus azzal a kényszerfeltétellel van kiegészítve, hogy nem enged meg negatív értékeket, mivel a hangnyomás négyzetes (várható) értéke sem lehet negatív. Így a negatív értékek minden iteráció végén nullával helyettesülnek. A módszer működését láthatjuk a következőkben.

A (2) egyenletrendszer egyetlen sora:

$$b_n = P_{n1}b'_1 + P_{n2}b'_2 + \dots + P_{nn}b'_n + \dots + P_{nN}b'_N$$

$P_{nn} = 1$ választással átalakítva:

$$b'_n = b_n - \left[\sum_{n'=1}^{n-1} P_{nn'}b'_{n'} + \sum_{n'=n+1}^N P_{nn'}b'_{n'} \right]$$

Ezt az egyenletet használjuk az iterációs algoritmusban, hogy megállapítsuk a b'_n forráseloszlást minden n -re 1 és N között a következők szerint:

$$b'_1{}^{(i)} = b_1 - \left[0 + \sum_{n'=1+1}^N P_{1n'} b'_{n'}{}^{(i-1)} \right]$$

$$b'_n{}^{(i)} = b_n - \left[\sum_{n'=1}^{n-1} P_{nn'} b'_{n'}{}^{(i)} + \sum_{n'=n+1}^N P_{nn'} b'_{n'}{}^{(i-1)} \right]$$

$$b'_N{}^{(i)} = b_N - \left[\sum_{n'=1}^{n-1} P_{Nn'} b'_{n'}{}^{(i)} + 0 \right]$$

Az első iteráció során ($i = 1$), b'_n kezdeti értéke nullának vehető, vagy pedig b_n -nek (a választás egy kis különbséget okoz a konvergenciárátában). Látható, hogy a b'_n szukcesszív determinációjában növekvő n mellett, az értékek folyamatosan figyelembe vannak véve a növekvő b'_n kalkulációk során. Minden iterációt (i) ehhez hasonló típusú számításokkal végzünk, azonban minden második iterációnál fordított irányban haladunk, $n = N$ -től $n = 1$ -ig haladva az iterációs lépések simítása érdekében. A következő iteráció ($i+1$) újra $n = 1$ -gyel kezdődik. A fentiek szerint alkalmazott pozitív korlát alkalmazásával a megoldások kellően determinisztikusak lesznek a konvergencia garantálásához. Természetesen a választott rácsfelületnek megfelelő módon illeszkednie kell a nyalábformálás karakterisztikájához annak érdekében, hogy elegendő különbség legyen b_n között, így biztosítva az egyenletek függetlenségét.

Az algoritmus előnye, hogy alacsony frekvenciákon (már 1 Helmholtz-szám érték felett) is pontos becslést ad mind a helyről, mind pedig a forrás intenzitásáról.

Az algoritmus nagy hátránya ugyanakkor a jó eredményhez szükséges számításigény. Mivel minden pásztázott pontra ki kell számolni a minden másik pásztázott pontra eső terjedési vektort, így a számításigény a vászon pontjainak növelésével négyzetesen nő. Mivel így a megoldandó egyenletekből is sokkal több lesz, ez még tovább növeli a számításigényt. Mivel az iteráció az aktuálisan kiszámított értékeket használja fel a következő értékek kiszámításához, így párhuzamosítása sem lehetséges, míg a többi vizsgált algoritmusnál GPU vagy DSP felhasználásával a számítási idő század részére eshet vissza.

Az algoritmus hátránya még, hogy nem rendelkezik előre meghatározott számításigénnyel, mivel tetszőleges, hogy hány iteráció után elégszünk meg az

eredménnyel. Kellő számú iteráció után már az amplitúdótérkép szinte teljes mértékben kitisztul, és a források egyértelműen azonosíthatóvá válnak.

Az algoritmusról tehát általánosan elmondható, hogy rendkívül robusztus, széles körben alkalmazható, és kevés megkötéssel rendelkezik. Számításigénye miatt azonban valós idejű használatra nem igazán alkalmas, így offline alkalmazások során használható leginkább. [8]

2.3 CLEAN algoritmusok

CLEAN algoritmusból kétféle is létezik. A CLEAN-PSF algoritmus alkalmazásánál azt feltételezzük, hogy a források pontszerűek és egyben irányfüggetlenek is. Ebben az esetben az amplitúdótérkép előáll a több forrás által gerjesztett hangnyomás értékek szuperpozíciójaként. Ez a már korábban említett PSF (Point Spread Function), ami a mikrofontömb válasza egy pontforrásra. Az eljárás során a maximumhelyekre kiszámolt PSF-eket kivonjuk az eredeti amplitúdótérképből, és ezt ciklusonként ismételjük egy meghatározott pontig.

A CLEAN-SC a CLEAN-PSF egy továbbfejlesztett formája, amely figyelembe veszi azt is, hogy a tényleges források nem kizárólag pontszerűek, és a melléknyalábok okozta hamis források jelei koherensek. Az algoritmus iteratívan eltávolítja az amplitúdótérképről azokat a részeket, amik a tényleges forrással (vagyis az aktuálisan vizsgált maximummal) koherensek.

2.3.1 CLEAN-PSF – CLEAN based on Point Spread Functions

A CLEAN algoritmus a hagyományos nyalábformálás által létrehozott amplitúdótérképből indul ki. Erről a forrásképről feltételezzük, hogy kizárólag PSF-ek szuperpozíciójaként jött létre. Az algoritmus a következő ciklust hajtja végre:

1. Maximumhely keresése
2. A maximumhelyre helyezett megfelelő intenzitású monopól forrás PSF-jének kivonása az eredeti képből
3. Az eredeti képbe egy megfelelő intenzitású pontforrás (nyaláb) helyezése.

Az algoritmus alkalmas a feltűnően hamis források eltüntetésére az amplitúdótérképből. Azonban bizonyos körülmények között létrejöhetnek olyan maximumhelyek is, melyek intenzitása nagyobb, mint a valós forrásoké. Ezekben az

esetekben a CLEAN algoritmus a hamis forrást detektálja, ennek következtében pedig éppen a valós forrást vonjuk ki – vagy csupán az intenzitását csökkentjük – az amplitúdótérképből, miközben a hamis forrás megmarad a képen. Ilyen körülmény két esetben jöhet létre: Ha pont úgy vannak jelen reflexiók, hogy azok pont a melléknyaláb irányában, ráadásul fázisban beérkezve összegződnek a melléknyalábbal, vagy pedig ha a főnyalábbal megegyező melléknyaláb vesz részt a képalkotásban. Előbbi lehetőség szabadtéri felhasználás során kis eséllyel következik be, utóbbi eshetőség pedig a mikrofontömb helyes kialakításával nem fordulhat elő. Mivel a CLEAN-SC algoritmus ennek a továbbfejlesztése, és hátrányokkal ehhez képest nem rendelkezik, így a szimulációkban csak azt implementáltuk. [9]

2.3.2 CLEAN-SC – CLEAN based on Source Coherence

Mint már említettük, a hagyományos nyalábformálás során a térben kiterjedt forrás, valamint ennek melléknyalábjai is koherensek a főirányból érkező forrás jelére, és ezt használja ki a CLEAN-SC algoritmus. Az elgondolás az algoritmus mögött, hogy megkeressük az eredeti amplitúdótérképen a maximumot, és ezt a megfelelő intenzitással eltávolítjuk egy új (tisztá) képen. Ezután a forrást és a koherens részeit kitöröljük az eredeti képből. Az iteráció addig folytatódik, amíg nem találunk több szignifikáns forrást, vagy az előre megadott maximális iterációs számot elértük. A módszer teljesítményét egy csillapító faktor – ami 0 és 1 közötti értékeket vehet fel – valamint a ciklusok száma befolyásolja. 1 alatti csillapító faktorról csak a talált forrás és annak koherens részeinek töredéke kerül ciklusonként kivonásra az amplitúdótérképből. Erre azért van szükség, hogy szuperponált forrásokat vagy azokat a forrásokat, amelyek egy erősebb forrás oldalnyalábjánál helyezkednek el, ne töröljük. Túl alacsony csillapítás választása sem javasolt, ugyanis ilyenkor több iterációra van szükség, ami a számításigényt növeli. Köztes csillapítás választása célszerű, melynél kevés iteráció mellett kellően tisztá forráskép érhető meg el a dekonvolúció által. A szimulációk során 0,6 körüli csillapítási tényezőt választottunk a szakirodalom elemzése után.

Az algoritmus azonos körülmények között nagyjából dupla akkora számítási kapacitást igényel, mint a MUSIC, azonban még ez is nagyon alacsonynak tekinthető. A MUSIC-hoz hasonlóan ez is kb. 4 Helmholtz számtól alkalmazható, azonban magas frekvenciákon (kb. 8-10 He felett) kevésbé pontos. Mivel a koherens részeket törli, így ez is inkoherens forrásokra alkalmazható, a forráskövetés során azonban inkoherens

forrásokot feltételezünk, így ez nem jelent problémát. A CLEAN-SC algoritmus alkalmas már elosztott (nem pontszerű) források detekciójára is, további előnye még, hogy nem szükséges előre meghatározni a forrásszámot, bár egy küszöbérték beállításával a MUSIC-hoz hasonló módon előre meg kell adnunk, mit tekintünk még forrásnak.

Összességében tehát elmondható, hogy sok tulajdonságában hasonlít az algoritmus a MUSIC-hoz, és ez is alkalmasnak tűnik valós-idejű forráskövetés használatára.

2.4 CS – Compressive Sensing

A CS egy általános jelfeldolgozási metódus, ami alulhatározott lineáris rendszerek megoldásainak a keresésével állít helyre egy jelet. Előzetes ismeret nélkül nincsen lehetőség egy jel helyreállítására a minták között. Előzetes ismeretek, vagyis a helyreállítási problémát kiegészítő kényszerfeltételek segítségével azonban egy jel tökéletesen helyreállítható a mintákból. A metódus működése azon az elven alapul, hogy a jel „ritkaságát” fel lehet használni ahhoz, hogy sokkal kevesebb mintából helyreállítható legyen, mint amit a Shannon–Nyquist mintavételi törvény megkövetelne. Az utóbbi évtizedben a CS aktív kutatási területté vált az akusztikában. [10] Friss tanulmányok gyakori témája a ritkaság kutatása különböző tartományokban, mint: idő-, frekvencia-, tér-, hullámszám-tartomány, illetve a nyálábformálás területén is. [11][12]

Akusztikai felhasználás során mérjük az $y \in \mathbb{C}^M$ jelformát M darab mintavevőn (esetünkben mikrofonon). Feltételezzük, hogy a mért jelformák lineáris kapcsolatban állnak az $x \in \mathbb{C}^N$ fizikai forrást leíró modellel egy $A \in \mathbb{C}^{M \times N}$ érzékelési mátrixon keresztül. A hozzáadódó zajtól eltekintve a lineáris összefüggés:

$$y = Ax$$

Ritka és CS modellek esetében, x dimenziója sokkal nagyobb, mint a megfigyelési y vektor dimenziója, $N \gg M$. Ha x ritka, abban az esetben csak K eleme nem nulla értékű, ahol $K \ll N$. Ha x sűrítető (compressible), akkor közelítőleg ritka, vagyis x jól közelíthető egy ritka fizikai forrásmodellel. A_{mn} alakját, ahol A_{mn} az m -edik mintavevő a fizikai forrás modelljének x_n együtthatójára vonatkozó elem, a hullám terjedési tényezője és a forrásmodell határozza meg.

A ritka fizikai modell helyreállítása megfogalmazható egy korlátozott minimalizálási feladatként is. Azt az x megoldást keressük, ahol a lineáris relációhoz

tartozó négyzetes hiba a legkisebb, azzal a korlátozással, hogy x elemeinek legfeljebb K eleme nem nulla:

$$\min_{x \in \mathbb{C}^N} \|y - Ax\|_2^2, \quad \text{ahol} \quad \|x\|_0 \leq K$$

Ez a minimalizálási feladat nem-konvex, és NP-nehéz probléma. Egyszerű megoldás a problémát küszöbölés segítségével megoldani, vagy ortogonális megfeleltetés segítségével, ahol egyesével megkeressük a csúcsokat, majd elimináljuk ezeknek a választ megfigyeléseinkből. Más módszer segítségével, az ℓ_0 kényszert lecseréljük egy ℓ_1 kényszerre $\|x\|_1 \leq \eta$, ami az ℓ_0 kényszer konvex közelítése:

$$\min_{x \in \mathbb{C}^N} \|y - Ax\|_2^2, \quad \text{ahol} \quad \|x\|_1 \leq \eta$$

Itt η egy felhasználó által megadott érték a jelek amplitúdójának az összegére vonatkoztatva. Ez a közelítés ismert LASSO-ként (Least Absolute Shrinkage and Selection Operator) is. A CS metódus áttörése annak a bizonyításával érkezett, hogy eléggé ritka jelek esetében az ℓ_0 kényszerű minimalizálási feladat ekvivalens annak konvex relaxációjával, az ℓ_1 minimalizálási feladattal. [10] Ennek segítségével a feladat hatékonyan megoldható konvex optimalizáció segítségével, még nagyszámú dimenzió esetében is.

A probléma megoldásával a képtisztítás is a korábbiaknál hatékonyabban lehetséges, mivel a mikrofontömb által vett jeleket felhasználva rekonstruálható az eredeti forráskép. A metódus a DAMAS algoritmus robusztusságát megtartva annál alacsonyabb számításigénnyel rendelkezhet. Érdeemes még megemlíteni a DAMAS algoritmussal való hasonlóságot, miszerint mindkét módszer plusz kényszerek segítségével oldja meg a dekonvolúciós feladatot. Míg a DAMAS esetében a kényszer a forráseloszlás pozitivitásra vonatkozik, addig a CS ritkasági kényszert alkalmaz.

A szimulációs keretrendszerem egyelőre nem tartalmaz CS alapú akusztikai képalkotó módszert, ugyanakkor ezek jövőbeli megvalósítása ígéretes továbbfejlesztési irányoknak mutatkozik.

3 Forráskövetés alkalmazása

Miután az amplitúdótérképet létrehoztuk, a megfelelő algoritmusok segítségével eltávolítottuk a mikrofontömb karakterisztikáját és a reflexiók okozta hibákat a képből, lehetővé válik a források pontos lokalizációja és követése is. A követés a lokalizációtól annyiban különbözik, hogy a múltbéli történéseket is figyelembe vesszük a követés során. Mivel a környezetünk folyamatosan változik – új zajforrások jelennek meg, a követett objektumunk mozog, vagy pedig a spektrális képe változik, – a lokalizációnak is alkalmazkodni kell a környezethez úgy, hogy továbbra is az általunk kívánt objektumot kövessük.

A követés segítségével képesek vagyunk különböző szűrésekkel még pontosabb becslést adni az objektum sebességére, helyére. A pontosság javítható pl. Kalman-szűrés megvalósításával, amellyel mind a sebességet, a pozíciót, és ezek szórását (korrelációs mátrixát) is pontosabban tudjuk becsülni. Az is előfordulhat, hogy a forrásunk zajkibocsátása ingadozik, a hasznos jel szintje néha a mérés zajszintje alá csökken, néha pedig kiemelkedik onnan. Ebben az esetben a követés és a Kalman-szűrő predikciója jól együtt tud működni, a forrásra akkor is rendelkezésre áll becslésünk, amikor az nem „látszik”, vagyis jelszintje nem emelkedik ki az amplitúdótérkép zajszintjéből.


A pontosított pozíciót felhasználva és a forrásra fókuszálva annak jelét is venni tudjuk. Miután a forrás fókuszált jele a birtokunkban van, frekvenciatartománybeli vizsgálatával meghatározhatók a domináns komponensek a spektrumban. Ezt felhasználva lehetőség nyílik frekvenciakövetés alkalmazására, melynek segítségével a zajforrások zavaró hatását lehet csökkenteni. Ennek a kimenetét a képtisztító algoritmusnak célszerű a következő amplitúdótérkép előállításához megkapnia, így frekvenciatartománybeli szűréssel pontosabb amplitúdótérkép kapható. Ebben a fejezetben a forráslokalizáció- és követés különböző lépéseit mutatom be.

3.1 Forráslokalizáció

Miután valamely algoritmus (MUSIC, DAMAS, CLEAN) segítségével meghatároztuk az amplitúdótérképet, szükség van a vászonról az egyes források helyének, illetve a szórásának a becslésére. A forráslokalizációt végrehajtó algoritmusok működése ciklikus, addig ismétlődik a belső lépések sorozata, amíg a legerősebb pont

egy meghatározott küszöbérték felett van. A források lokalizációjára kétféle módszert is megvalósítottam, ezeket ismertetem az alábbiakban.

Az első módszer szerint minden ciklus elején a legerősebb pontot megkeressük, majd a vásznat jelentő tömbből kivesszük az ennek a pontnak megfelelő oszlop, illetve sorvektort. Ezután erre a két vektorra elvégezzük a medián, illetve a szórás keresést, ezzel megbecsültük a várható középértéket, illetve magát a szórást, mely értékeket majd a Kalman-szűrőnek is bemenetül tudjuk adni. Ezt követően szükséges a vászonból kivonni az adott ciklusban megtalált forrást, hogy a későbbiekben ezt már ne találhassuk meg. Erre azt a módszert alkalmaztam, hogy a kapott szórásból és középértékből meghatározok egy-egy eloszlásfüggvényt (a két független irányra egyet-egyét), ebből képezek egy kétdimenziós eloszlást, amit levonunk a vászonból, így a forrás közel teljesen eliminálásra kerül. A valós eloszláshoz leginkább közelítőnek a „Stable” eloszlást találtam. [13]



8. ábra Valós és a "Stable" eloszlás összehasonlítása

A másik megoldás szerint egy adott küszöbszint alatt kinullázzuk a ciklus elején a vásznunkat, majd pedig ezen a módosított amplitúdótérképen végzünk ún. összefüggésvizsgálatot. A legnagyobb összefüggő objektumnak meghatározzuk így a pozícióját, és ezekre az összefüggő pontokra egy ellipszist illesztünk. Ennek az ellipszisnek a segítségével következtetni lehet a szórásra is; ugyanis az ellipszis középpontja az eloszlás várható értékét adja meg, a tengelyek hosszai és állásszögei pedig a kovarianciamátrixszal állnak összefüggésben. Ezt követően ebben az esetben is az adott

forrás „törlésére” van szükség, amit úgy végzek el, hogy egy alacsonyabb küszöb szerint nullázom ki a vászon pontjait, majd erre a módosított vászonra ismételten elvégzem az összefüggésvizsgálatot, és az előbb talált pont koordinátái szerinti objektumot törlöm ki a vászonnól, így a következő ciklusban biztosan nem fogjuk az adott forrást ismételten megtalálni, mivel az oldalnyalábjai is törlődni fognak. A következő ciklusban aztán ismét elvégezzük ugyanezeket a lépéseket, ami aztán addig folytatódik, amíg még találunk forrást. Az algoritmus működését a 4.9 pontban részletesen ismertetem. Az adott pontokat magába foglaló minimális térfogatú ellipszoid (MVEE – Minimal Volume Enclosing Ellipsoid) illesztésének lépéseit a [14] folyóiratcikk mutatja be.

A két módszer mindegyike a szimulációk során működőképesnek bizonyult, de mindkét módszer esetében további fejlesztésekre is van még lehetőség. Jelen pillanatban a második megoldás tűnik járhatóbb útnak, mivel kevésbé számításigényes, és kevésbé érzékeny a források egymáshoz képesti elhelyezkedésére. Ennél a legrosszabb esetben az algoritmus a két forrás közül az egyiket találja csak meg. (Amennyiben ezek szinte összeérnek), A talált forrás pozícióját, illetve a pozícióbecslés szórását megbízhatóan becsli. Ezzel szemben az első módszernél ebben az esetben egy második forrás a talált pozíciót is eltorzíthatja, vagyis az algoritmus a két forrás közé becsli a pozíciót, szellemforrást talál. Ennek kijavítása természetesen lehetséges, csupán nagyobb számítások és tervezés segítségével.

3.2 Kalman-szűrő

A Kalman-szűrő mozgó, változó rendszerek állapotáról ad optimális becslést a korábbi állapot, valamint megfigyelések (mérések) alapján. Ezzel az algoritmussal jóval pontosabb információ kapható a vizsgált tárgyról, mintha csak egy mérést végeznének el. Más szóval a Kalman-szűrő a zajos bemenő adatok rekurzív mérésével optimális becslést ad a mérés tárgyának állapotáról. A Kalman-szűrőt széles körben alkalmazzák, használják navigációs, vezérlő (repülőgépek, űrhajók, pilóta nélkül repülőgépek), valamint jelfeldolgozó rendszerekben és az ökonometria területén is.

A következőkben bemutatom a lineáris állapotbecslésen alapuló megoldást, amely lineáris rendszereknél használható. Ezután ismertetem ennek kiterjesztését, az „Unscented Kalman Filter”-t, amely nemlineáris rendszerek esetén használható. Mint az utolsó pontban azt bemutatjuk, az általunk a szimulációban felépített modell egy nemlineáris rendszer, így a kiterjesztett Kalman-szűrőt implementáltam.

3.2.1 Optimális lineáris állapotbecslő

A szűrő használatához a vizsgálni kívánt környezetről egy modellt szükséges felépítenünk. Legyen ennek a modellnek a folytonos idejű állapotegyenlete:

$$\dot{x}(t) = f(x(t), u(t))$$

ahol $x(t)$ a rendszer belső állapotát leíró valós vektor, $u(t)$ pedig t időpillanatban a bemenetek vektora. Amennyiben a bemeneti vektor nem ismert, mérnünk szükséges, vagyis a megfigyelésünket fogja tartalmazni. Általában a rendszer belső állapotát nem tudjuk közvetlenül mérni, csak a belső állapotokból kifejezhető mennyiségeket, ezeket hívjuk a rendszer kimeneteinek:

$$y(t) = g(x(t_0), u(t))$$

A Kalman-szűrő feladata a rendszer $x(t_0)$ állapotvektorának becslése a korábbi időszakokról rendelkezésre álló állapotvektorok, a bemenetek valamely szórással ismert értéke és a kimenetek valamely szórással mért értéke alapján. [15]

Mivel mi a szűrőt diszkrét környezetben alkalmazzuk, így áttérünk a rendszer diszkrét idejű leírására. A diszkrét idejű állapotegyenlet az előzőek alapján:

$$x(n+1) = F(x(n), u(n), n)$$

A diszkrét idejű kimeneti egyenlet pedig:

$$y(n) = G(x(n), u(n), n)$$

Amennyiben a rendszerünk lineárisnak és időinvariánsnak tekinthető, akkor a következő egyenletrendszert írhatjuk fel:

$$x(n+1) = Ax(n) + Bu(n)$$

$$y(n) = Cx(n) + Du(n),$$

ahol A , B , C és D a rendszerre jellemző mátrixok. Általános esetben a bemenet nem hat közvetlenül a kimenetre, így $D = 0$ feltételezéssel élünk.

A Kalman-szűrő minden n időlépésben kiszámítja a rendszer állapotának $\tilde{x}(n)$ becslőjét. A bemenetek értékéből és a becslőből a kimeneti egyenlet alapján kiszámítja a kimenetek becslött $\tilde{y}(n)$ értékét. Az állapotegyenlet alapján az $n+1$. időlépésre az x^- előzetes becslést is kiszámítja:

$$x^- = A\tilde{x}(n) + Bu(n)$$

$$\tilde{y}(n) = C\tilde{x}(n)$$

Ezután a kimenetek becslt és mért értéke közötti

$$d(n) = y(n) - \tilde{y}(n)$$

különbség alapján egy megfelelően választott K_n súlyozómátrixszal megszorozva pontosítja az állapotbecslést:

$$x^+ = x^- + K_n d(n)$$

Az így megkapott értéket használjuk fel a rendszer állapotának a becslésére az $n+1$ -ik időlépésben:

$$\tilde{x}(n+1) = x^+$$

A K_n optimális súlyozómátrix az alábbi feltételek teljesülése esetén zárt képlettel is megadható:

- A kimeneti egyenlet és a rendszeregyenlet idővariáns, lineáris
- A kimenetek és a bemenetek mérései 0 várható értéke additív Gauss eloszlású zajjal terheltek

Ekkor a rendszeregyenletek az alábbi alakban írhatóak:

$$x(n+1) = Ax(n) + Bu(n) + w(n)$$

$$y(n) = Cx(n) + v(n),$$

ahol $w(n)$ a bemeneteket terhelő terhelő zajvektor, Q_n kovarianciamátrixszal, $v(n)$ pedig a kimenetek mérését terhelő zajvektor, R_n kovarianciamátrixszal. $\tilde{x}(n)$ becslés P_n kovarianciamátrixa minden n időlépésben kiszámítható:

$$P_n^- = AP_{n-1}A^T + Q_n$$

Ebből kifejezhetjük az optimális K_n mátrixot:

$$K_n = P_n^- C^T (C P_n^- C^T + R_n)^{-1} = P_n^+ C^T R_n^{-1} \quad (3)$$

ennek ismeretében pedig megkaphatjuk a mérés alapján pontosított állapotvektor becslésének a kovarianciamátrixát:

$$\begin{aligned} P_n = P_n^+ &= (I - K_n C) P_n^- (I - K_n C)^T + K_n R_n K_n^T \\ &= (P_n^{-1} + C^T R_n^{-1} C)^{-1} \\ &= (I - K_n C) P_n^- \end{aligned}$$

3.2.2 Unscented Kalman Filter (UKF)

Ha a rendszeregyenlet vagy a kimeneti egyenlet nem lineáris, vagy a mérési zajok nem additív Gauss eloszlású 0 várható értékű zajok, akkor a (3) kifejezés a K mátrixra nem használható.

A kiterjesztett Kalman-szűrők (EKF, Extended Kalman Filter) valamilyen linearizáláson alapulnak. A linearizáláshoz általában ismerni kell az f többváltozós függvény deriváltjait, a Jacobi-mátrixot. Ennek meghatározása sokszor nemtriviális és számításigényes feladat. A linearizálás mellett egy másik lehetőség, hogy a becsült kovarianciamátrix alapján szórt állapotvektorokat állítunk elő. Amikor valamilyen (esetünkben Gauss) eloszlású változóra egy nemlineáris függvény hat, az eredmény a nemlineáris transzformáció miatt már más eloszlású lesz, valamint az eredmény momentumai sem az adott momentum transzformáltja lesznek. A szórt állapotvektorokra ezért alkalmazzuk az állapotegyenlet és a kimeneti egyenlet transzformációit, majd a szórt transzformált értékekből számítunk momentumokat. Az ilyen elven működő Kalman-szűrőket Particle Filter-nek is szokás nevezni. Véletlenszerűen kiválasztott szórt pontok esetén a pontos becsléshez nagyon sok szórt állapotvektort kellene előállítani. A szórt állapotvektorok kiválasztására egy speciális javaslatot ad az UKF, amely egy szórás ellipszis mentén, úgynevezett szigma-pontokra számítja ki a transzformált állapotok statisztikáit. Ezzel a szórás pontok száma jól definiálható, a számításigény pedig kézben tartható. Bizonyítható, hogy többféle nemlineáris transzformáció esetén is az UKF pontválasztása optimális. [16][17]

A számítás lépései a következők:

1. Az n . időlépésben az aktuális állapotvektor körül ($x(n)$) összesen $2N$ darab szigma-pontot, ahol N az állapotter dimenziója

$$x_i^\sigma, x_{N+i}^\sigma = x_n \pm \sigma_i, i = 1 \dots N$$

oly módon, hogy az így kapott ponthalmaz statisztikája megegyezzen az állapotterünk aktuális statisztikáival. Másként fogalmazva a pontok átlaga adja vissza az állapotvektort, a tapasztalati szórásuk pedig adja ki a P_n kovarianciamátrixot. Ha σ_i -nek $\sqrt{NP_n}$ mátrix oszlopait választjuk, éppen ilyen tulajdonságú pontokat kapunk.

2. A szigma pontokra alkalmazzuk az állapotegyenletet. Jelöljük a transzformált szigma-pontokat $x_i^{\sigma^*}$ -vel. Az új állapot előzetes becslőjét megkaphatjuk ezen pontok átlagából:

$$\tilde{x}^- = \frac{1}{2N} \sum_{i=1}^{2N} x_i^{\sigma^*}$$

a kovarianciájuk pedig:

$$\tilde{P}^- = \frac{1}{2N} \sum_{i=1}^{2N} (x_i^{\sigma^*} - x_i^{\sigma^-}) (x_i^{\sigma^*} - x_i^{\sigma^-})^T$$

Ehhez a rendszerzajt (Q) hozzáadva megkapjuk a becslés kovarianciájának becslését:

$$P^- = \tilde{P}^- + Q$$

3. A mérés figyelembe vételéhez az x^- körül P^- segítségével ismét szigma pontokat hozunk létre, és alkalmazzuk ezekre a kimeneti egyenletet. A kapott ponthalmaz (y_i^σ) átlaga lesz a becslő kimenete (\tilde{y}). Kiszámítjuk a kovarianciáját (P_{yy}) és az x^- -szal vett keresztkorrelációs mátrixot is (P_{xy}):

$$P_{yy} = \frac{1}{2N} \sum_{i=1}^{2N} (y_i^\sigma - \tilde{y})(y_i^\sigma - \tilde{y})^T$$

$$P_{xy} = \frac{1}{2N} \sum_{i=1}^{2N} (x_i^{\sigma^*} - x_i^{\sigma^-})(y_i^\sigma - \tilde{y})^T$$

4. A becslőt és a mért kimenet közötti különbséget a korrelációkból számított

$$K_n = P_{xy} P_{yy}^{-1}$$

visszacsatoló mátrixszal csatoljuk vissza. Így megkapjuk az állapotvektor méréssel pontosított becslőjét:

$$x_{n+1} = \tilde{x}^+ = x^- + K_n(y_n - \tilde{y})$$

valamint annak kovarianciáját:

$$P_{n+1} = P^+ = P^- + K_n(P_{yy} + R)K_n^T$$

3.3 Frekvenciakövetés alkalmazása

Amint már említettük az előző fejezetekben, a frekvenciakövetés alkalmazása egy fontos lépés a követés során. Ebben a fejezetben bemutatjuk a módszereket, melyekkel a képtisztító algoritmusok számára optimális frekvenciákon történhet a követés.

Mivel a forgószárnyas repülők zajkibocsátása nagy harmonikustartalommal rendelkezik, így jó választásnak tűnik olyan algoritmus használata, ami ezt figyelembe veszi. A domináns frekvenciák vagy hangmagasságok meghatározása történhet idő-, valamint frekvenciatartományban is. A frekvenciatartományban működő algoritmusok sokkal robusztusabbak, így mi ezekkel foglalkozunk, ezek közül egyet mutatunk be.

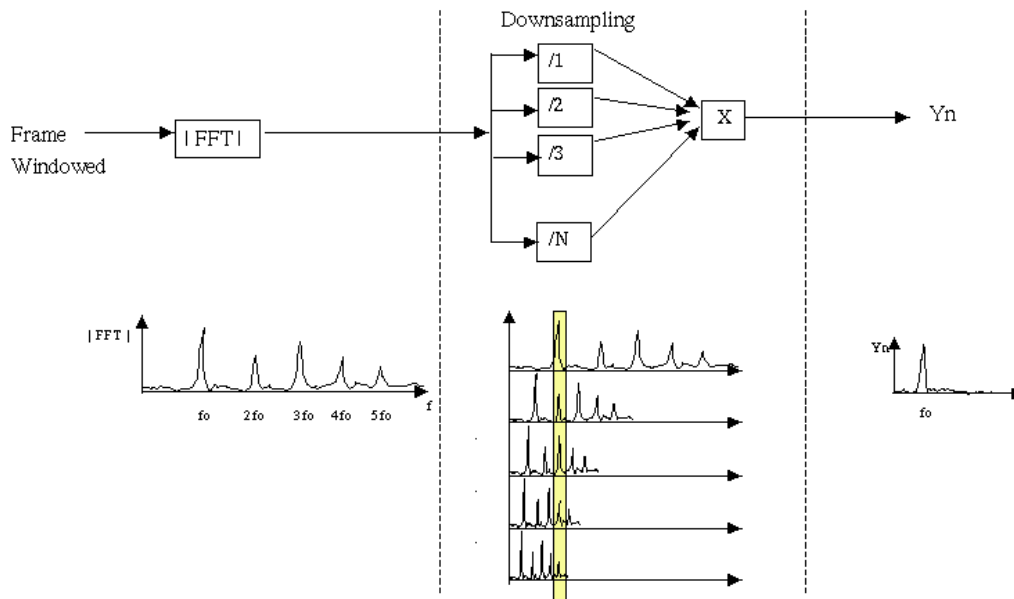
3.3.1 HPS - Harmonic Product Spectrum

A HPS hangmagasság-érzékelő algoritmus (Noll 1969, [18]) az egyik legegyszerűbben implementálható algoritmus, és széles körben alkalmazható hatékonyan. Az algoritmus a legnagyobb egybeesést keresi a harmonikusok között minden $X(\omega)$ spektrális keret esetében, a (4) képletnek megfelelően:

$$Y(\omega) = \prod_{r=1}^R |X(\omega r)| \quad (4)$$

$$\tilde{Y} = \max_{\omega_i} \{Y(\omega_i)\} \quad (5)$$

ahol R a figyelembe vett harmonikusok száma (jó választás pl.: $R = 5$), ω_i pedig a lehetséges alulfrekvenciákat tartalmazó tartomány. Y az eredményül kapott periodikus korrelációs tömb, ennek keressük a maximumát a (5) képletnek megfelelően. Az algoritmus működését mutatja a 9. ábra.



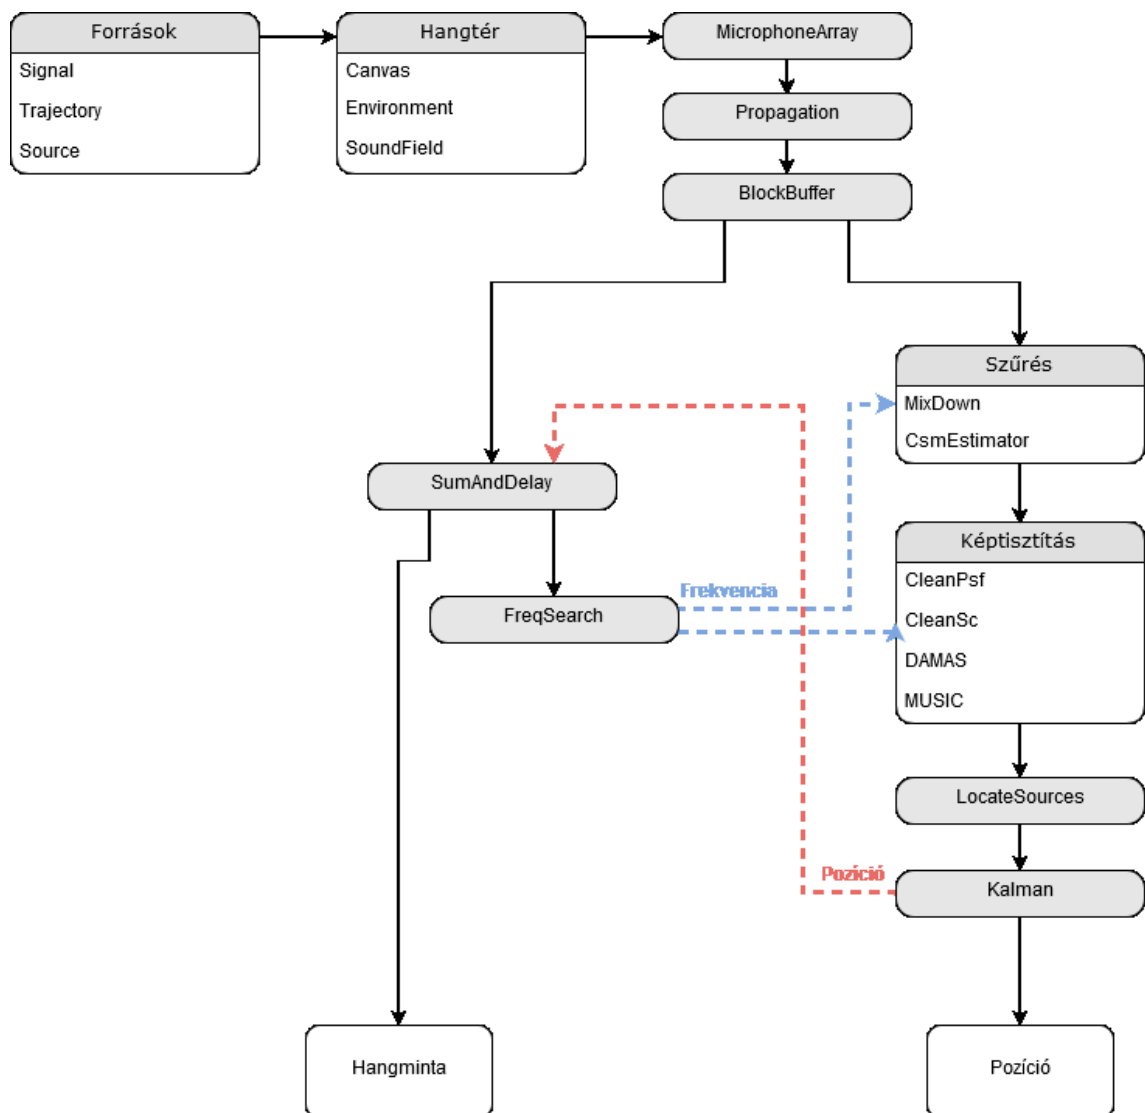
9. ábra HPS algoritmus működése [18]

Elsődleges hátránya, hogy alacsonyabb frekvenciákon a felbontás alacsony. Ezt a transzformációt megelőzően a jel nulla értékekkel való feltöltésével kompenzálni lehet, így nagyobb felbontás érhető el. Ez sok számítási kapacitást elvesz, ugyanis így a magas frekvenciák is interpolálásra kerülnek, szükségtelenül. A modern számítástechnikában azonban ez a megnövekedett számításgigé már nem jelent problémát. Gyakori hibája az algoritmusnak, hogy egy oktávval magasabb frekvenciát azonosít alapfrekvenciának. Az utófeldolgozás során ez a hiba javítható úgy, hogy összehasonlítjuk az egy oktávval alacsonyabban levő csúcst a választottal. [19]

Az algoritmus az ismertett korlátozások mellett valós időben is használható, viszont a légszavazaj esetében azt tapasztaltam, hogy nagyjából 50 Hz alatt a növekvő zaj miatt nem működőképes már.

4 Szimulációs környezet

Ebben a fejezetben szeretném bemutatni a MATLAB környezetben megvalósított szimulációs keretrendszer felépítését, annak működését. Minden számítás egy objektumorientált modellben történik, a futtatás során pedig a különböző osztályok blokkonkénti feldolgozással kommunikálnak egymással. Az osztályok úgy lettek kialakítva, hogy mindegyikből tetszőleges számú elem hozható létre, így lehetséges több forrás bevétele a szimulációba, valamint párhuzamos követés is. Létrehoztam még egy, az osztályokat összefogó környezetet is.



10. ábra Szimulációs környezet felépítése. A nyilak az adatáramlás irányát szemléltetik, a szaggatott vonalak pedig a visszacsatoló ágakat jelentik.

A 10. ábra mutatja a környezet felépítését. Amint látható, két visszacsatolási ág is található a szimulációs környezetben. A képtisztító algoritmusok felhasználják egyrészt a frekvenciakövetést végrehajtó osztály által adott frekvenciát. Másrészt a nyalábformálást végző osztály felhasználja a képtisztító algoritmusok, és ezután a Kalman-szűrő által számított pozíciót. Ezek a visszacsatoló ágak opcionálisak, más akusztikus képalkotási feladat megvalósítása során kikapcsolhatóak illetve külön-külön is használhatóak.

4.1 Források

Az ebbe a csoportba tartozó osztályok különböző trajektóriákon mozgó forrásokat valósítanak meg. A kisugárzott akusztikai jelet reprezentáló Signal osztálynak több alosztálya is van, ezekkel lehetséges harmonikus jelet, fehérzajt vagy tetszőleges előre megadott jelsorozatot kibocsátó zajforrások létrehozása.

A Trajectory osztály segítségével trajektóriák hozhatóak létre, amelynek ismét több alosztálya létezik. Ezek segítségével lehet álló, konstans sebességgel mozgó, illetve parametrikus függvényrel megadott tetszőleges trajektórián mozgó források létrehozása. A parametrikusan megadott trajektóriáknál lehetőség van ívhossz szerinti újraparaméterezést készíteni, amely után a trajektória állandó vagy időben változó nagyságú sebességgel bejárható.

A Signal és a Trajectory osztályok felhasználásával hozható létre a Source objektum, ami már az adott trajektórián mozgó adott jelformát kibocsátó forrást jelenti. Minden forrásobjektum képes tetszőleges t időponthoz megadni a kibocsátott akusztikai jel mintáját. Mintavételezett bemenet esetén ehhez interpolációt használhatunk.

4.2 A hangtér elemei

Ebbe a csoportba tartoznak azok az osztályok, amik a terjedési tényezőket, a letapogatandó vásznat és a hangteret létrehozzák.

Az Environment osztály számítja ki a terjedési tényezőket, a hőmérséklet, légnyomás és a páratartalom függvényében. Az osztály képes a hangsebesség kiszámításán kívül a frekvenciától függő légköri csillapítást is számítani. Ezen kívül lehetőség van adott frekvenciára a hullámszámot is lekérni az osztálytól, mellyel a terjedési vektorok számíthatóak a későbbiekben. [20]

A SoundField osztály számítja a teljes hangteret, források és az Environment osztály felhasználásával. Az osztálytól lekérhető a tér tetszőleges pontjára és időpontjára a hangnyomás. Az osztály ehhez az ún. retardált időket számítja ki. A t időpontban a j . vevő az i . forrás által a $t_{ij}' = t - \tau_{ij}$ retardált időpontban kibocsátott jelet veszi. A számítás nehézségét az okozza, hogy tetszőleges trajektória esetén a τ_{ij} terjedési idő maga is a t időpont függvénye, a retardált idő számításához pedig nemlineáris egyenletrendszer megoldására van szükség. A megoldáshoz az iteratív Newton–Raphson-módszert használom.

A Canvas osztály testesíti meg a vásznat, ennek megadhatjuk a letapogatandó pontokat tartalmazó tömböt. Ennek az osztálynak a segítségével tudja minden képtisztítást vagy nyalábformálást végző osztály a letapogatandó pontokat. Továbbá a Canvas osztály lehetőséget ad a kiszámított amplitúdótérképek megjelenítésére is.

4.3 Mikrofontömb – a MicrophoneArray osztály

Ennek az osztálynak a segítségével lehetséges mikrofontömbök létrehozása. Képes többféle paraméterezzhető elrendezésű tömb létrehozására, úgy, mint: egyenes vonalon elhelyezett mikrofonok, valamint kör, spirális és négyzethálós elrendezés. Emellett tetszőleges mikrofonpozíciók is megadhatóak a koordináták definiálásával. Az osztálytól a SoundField osztály segítségével lekérhető adott időpontra az összes mikrofonnál észlelhető hangnyomásszint, az adott forrástól való mikrofononkénti távolság, valamint a terjedési idők az adott forrástól minden mikrofonhoz.

4.4 Hullámterjedés modellezése – a Propagation osztály

Miután a forrásokat elhelyeztük a térben, ezekből kiszámítottuk a teljes hangteret, és a mikrofontömböt is elhelyeztük a térben, lehetővé válik a terjedési vektorok kiszámítása is. Ezt a számítást a Propagation osztály végzi, megadott frekvenciára számítva. Az osztálytól lehetőség van a terjedési vektorokon kívül a PSF-ek kiszámítására is. Az osztálynak beállítható a terjedés modellje, mely lehet gömb- vagy síkhullámú is.

4.5 Blokkfeldolgozás – a BlockBuffer osztály

Mivel a mikrofontömből érkező jeleket a feldolgozás során blokkosított formában dolgozzuk fel, így szükséges egyfajta tároló alkalmazása, amibe az új mintákat el tudjuk helyezni, és a legrégebbit pedig kinyerni belőle. Ezt a tárolót FIFO elven

valósítottam meg, és a BlockBuffer végzi ennek a kezelését. Lehetőség van a tároló maximális méretét is megadni, és amennyiben a tároló kiürülne, akkor mindig az utolsó mintát adja vissza.


4.6 Szűrés

Mivel a képtisztítást adott frekvencián végezzük, így szükség van a mikrofontömbre beérkező jelek szűrésére. A MixDown osztály végzi ezt a szűrést, IIR Butterworth-szűrő segítségével. Az osztálynak megadható a szűrő fokszáma, a középponti frekvencia és a szűrés sávszélessége. Az osztály a szűrést lekeveréssel valósítja meg, az f_0 középfrekvenciájú valós jelet zérus középfrekvenciájú komplex jellel keveri le, majd aluláteresztő szűrést végez. Az osztály tárolja a szűrő belső állapotát is, így két egymást követő blokk szűrése tranziens átmenet nélkül történik.


Miután a szűrést elvégeztük, a képtisztító algoritmusok számára szükséges létrehozni a keresztkorreláció és a keresztkovariancia-mátrixot. Ezt összevonva a CsmEstimator osztály végzi el, ami a kereszt-spektrális mátrixot hozza létre.

4.7 Akusztikai fókuszálás – a SumAndDelay osztály


A SumAndDelay osztály végzi a nyalábformálást, mellyel a különböző képtisztító algoritmusok és a Kalman-szűrő által meghatározott feltételezett forráspozícióra fókuszálhatunk. Ennek segítségével lehetőség van a forrás hangjának meghallgatására is. A fókuszálás ugyanazon módon van megvalósítva, amint azt már az 1.3 pontban bemutattam. A nyalábformálás véges fókuszú módon történik, vagyis a fázistolások különbsége mikrofonpáronként eltér. Ehhez először lekérdezésre kerül a MicrophoneArray osztály, ami az adott pozícióra kiszámolja a mikrofononkénti fázistolások vektorát.



11. ábra Mérési elrendezés. A kék folytonos vonal a forrás trajektóriáját mutatja, a piros körök pedig a mikrofonok pozícióit jelentik. (Minden tengely egysége [m])



12. ábra Vizsgált, 24 elemű kör elrendezésű mikrofontömb főirányra normalizált iránykarakterisztikája a példában használt 1 kHz frekvencián.



13. ábra Mozgó forrás jelének nyalábformált összegzése

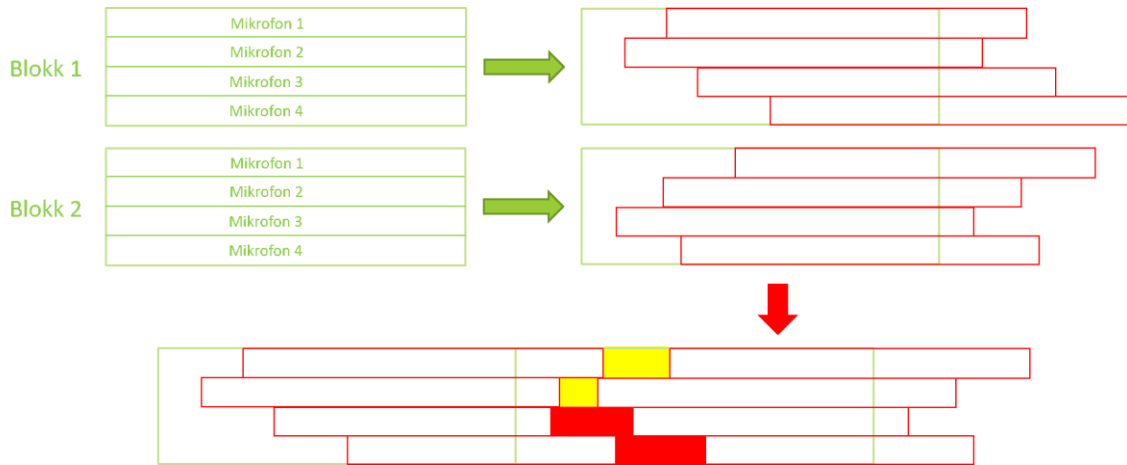
A 11. ábra egy szimulációs elrendezést mutat be, melyen egy 1 kHz frekvenciájú harmonikus jelet kisugárzó forrás a mikrofontömbbel párhuzamos síkban egy spirál alakú pályán halad végig. A forrás sebességének nagysága mindvégig 20 m/s. A 12. ábra mutatja a mikrofontömb iránykarakterisztikáját a vizsgálati frekvencián, a 13. ábra pedig a hagyományos nyalábformálással kapott összegzett jelet. Az összegzés során minden $T_{blk} = 0,05$ s hosszúságú blokkban a mikrofontömböt a forrás valós pozíciójára fókuszáltam, így blokkonként kaptam meg a fókuszáláshoz szükséges késleltetéseket.

Amint a fenti ábrákon látható, a nyalábformálás hatására közel azonos jelszintre került végig a vett jel, míg nyalábformálás nélküli esetben a forrás mozgásának hatására interferenciák alakultak ki, így a jelszint is ingadozott. Zajjal terhelt esetben (ahogy a valóságban is történne), nem csupán a jelszint lett egyenletes, hanem a forrás hangja is sokkal dominánsabban jelen van. Amint a jelformán észrevehetjük, a blokkok összegzése során még nem kívánt ugrások (kiugró éles csúcsok, hallható „kattogások”) jelentek meg, aminek a megoldását ebben a fejezetben tárgyaljuk.

4.7.1 A blokkösszegzés problémája mozgó forrás esetén

Amint a fenti 13. ábra látható, a kattogásokat az okozza, hogy minden egyes blokk során más helyre fókuszáljuk az akusztikus kameránkat, ennek hatására pedig minden blokknál más fázistolás szükséges. Emiatt létrejöhetnek átlapolódások a különböző

blokkok mintái között, vagy egymásra „csúsznak” egyes mikrofonok jelei, vagy pedig rés keletkezik a jelek között. A hibák kialakulásának módját szemlélteti a 14. ábra.



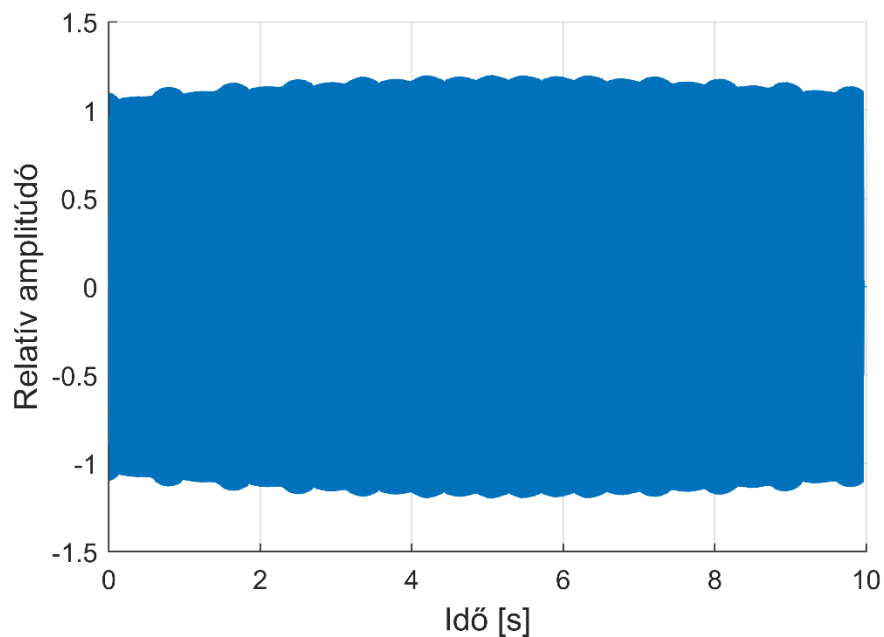
14. ábra Blokkösszegzés problémája. Két egymást követő blokk esetén az eltérő időeltolások miatt rések (sárga blokkrészek) vagy átlapolások (piros blokkrészek) keletkezhetnek.

Ennek a problémának a megoldására két módszert is implementáltam. Az egyik módszer szerint interpoláció segítségével minden blokkot az előző ciklusban megtett út hossza szerint nyújtunk, így a rések eltűnnek. Előnye ennek a megoldásnak, hogy mivel figyelembe veszi a forrás sebességét is, és a szerint változtatja az aktuális blokk méretét, így a Doppler-effektusból adódó frekvenciaeltolódások változását is kompenzálni tudja bizonyos mértékben. Hátránya ugyanakkor, hogy számításigényes, így valós idejű felhasználás során korlátozva használható.

A másik megoldás szerint két minta közötti interpolált pozícióra számítunk mindig egy-egy plusz blokkot, minden egyes eltolt blokkot súlyozunk egy emelt-koszinusz függvény segítségével, és a blokkösszegzést ezután hajtjuk végre. Előnye ennek a módszernek, hogy jóval kisebb számításigénnyel bír, mint az előbb ismertetett verzió. Ehhez hasonló ablakozási módszert használnak a veszteséges audio tömörítő eljárások is, ahol az ablakozásra a két blokk közötti eltérő bitszámokkal történő kvantálásból adódó zaj simítására van szükség.

A tesztelés során azt tapasztaltam, hogy számottevő különbség nem jelentkezik az interpolációval történő módszerhez képest, a vett jel ugyanolyan mértékben kitisztult mindkét esetben. A későbbi felhasználás során természetesen lehetőség van mind a kettő módszer alkalmazására, akár a kettőre egyszerre is, azonban valós idejű számítások

mellett az utóbbi módszer alkalmazása tűnik jobbnak. Amint a 15. ábra is látható (valamint a mintákon hallható), a kiugró csúcsok és így a „kattogás” eltűnt a felvételtől, immár szép tisztán tudjuk venni a forrás jelét. A simított jelen jól látható az amplitúdó lassú változása, ahogyan a mozgó forrás elhalad mikrofontömb előtt. Emellett megfigyelhető az amplitúdó gyorsabb, kisebb mértékű oszcillációja is, ami a spirál alakú trajektórián való haladásból adódó folytonosan változó forrás–vevő távolság miatt van jelen.




15. ábra Mozgó zajforrás jelének nyálábformált összegzése ablakfüggvény alkalmazásával


4.7.2 Doppler-effektus vizsgálata

Mint már az interpolációval működő összegzésnél említettük, egyetlen előnye lehet az interpolációs megoldásnak az ablakfüggvénnyel történő összegzéshez képest, hogy a Doppler-effektusra is hatással lehet. Ehhez a szimulációs környezetünkben egy tesztet állítottunk össze, mely során egy forrás a mikrofontömb előtt egyenes vonalon egyenletes sebességgel, a mikrofontömb síkjával párhuzamos síkban haladva, konstans 1000 Hz frekvenciájú és egységnyi amplitúdójú szinusz jelet bocsátott ki. A forrás sebessége 40 m/s így a Doppler-eltolódásból azt várjuk, hogy a frekvencia ≈ 900 Hz és 1130 Hz között fog változni. Az interpolációval történő összegzést mutatja a 16. ábra, az ablakfüggvénnyel történőt pedig a 17. ábra. Ahogy az ábrákból megfigyelhetjük, az interpoláció a Doppler-effektus változása ellen hat, annak változását simítja ki. Ennek megfelelően a frekvenciaváltozás egyenletesen megy végbe, míg csak ablakfüggvénnyel

történő összegzés során a frekvenciaugrás figyelhető meg a blokkok között. A szimuláció során a frekvenciamérés pontosságát mindkét esetben a blokkméret határozza meg, így az ábrázolt értékek a valós frekvenciaértékektől valamelyest eltérnek.



16. ábra Interpoláció segítségével történő blokkösszegzés



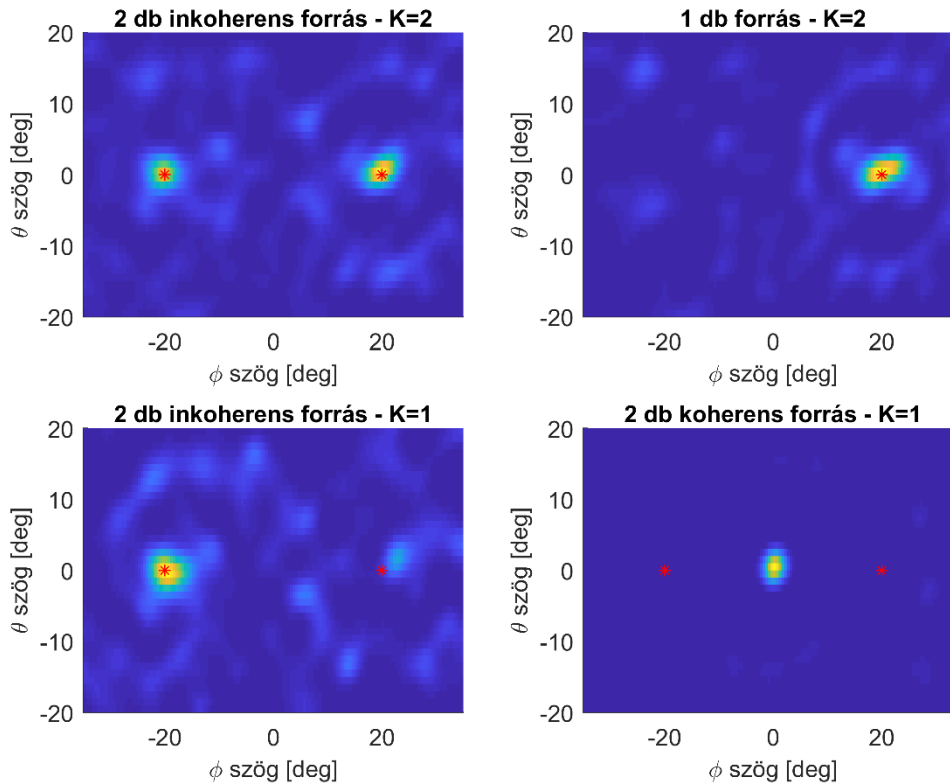
17. ábra Ablakfüggvény segítségével történő blokkösszegzés

4.8 Képzalkotás – A MUSIC osztály

A 2.1 szakaszban bemutatott MUSIC algoritmust úgy implementáltuk, hogy előre is meg lehessen adni a források számát, valamint az algoritmus is becsülni tudja azt. Amennyiben forrásszámnak 0-át adunk meg, úgy az algoritmus becsli meg a forrásszámot a kereszt-spektrum mátrix sajátértékei alapján. A vizsgálataink szerint a legtöbb esetben a becslés pontosan működik.

A melléknyaláb elnyomás nagyban nőtt az azonos környezetben futtatott Delay and sum módszerhez képest (18. ábra, vö. a 12. ábra iránykarakteristikájával) Az is megfigyelhető az ábrákon ugyanakkor, hogy a források számát rosszul megválasztva milyen eredményeket kapunk. (Az ábrákon a vászon felbontása és az amplitúdótérkép skálája azonos, minden ábrán a világosabb szín jelenti a nagyobb amplitúdót.) Amint látható, amennyiben alulbecsüljük a források számát, és a két forrás inkoherens, akkor valamelyik forrás nem jelenik meg. Amennyiben a két forrás koherens, úgy a kettő számtani közepénél egy szellemforrás jelenik meg. Ha túlbecsüljük a források számát, abban az esetben pedig valamelyik forrás lesz „szétkenődve”.

A MUSIC algoritmus mellett a CLEAN és DAMAS módszerek implementációi is külön-külön osztályokba kerültek. Mivel a dolgozatban is bemutatott tesztesetek többségében a MUSIC algoritmus volt a legjobban használható, így a többi algoritmus osztályait itt nem részletezem.




18. ábra MUSIC algoritmus működése


4.9 Forráslokalizáció – A LocateSources osztály

Amint már ismertettük, az amplitúdóterképből két lehetőség áll rendelkezésre a pozíció meghatározásához. Ezek közül az összefüggésvizsgálaton alapulónak az implementációját mutatjuk be ebben a fejezetben.


A 19. ábra mutatja a bemeneti amplitúdóterképet, amelyet valamely képtisztító algoritmus kimenetéről kapunk. Az ábrán két mozgó forrás képe látható. Megfigyelhető, hogy a mozgó forrás esetében az akusztikai kamera által adott amplitúdóterképen a források környékén elmosódott képet kapunk, az elmosódás alakja pedig illeszkedik a forrás trajektóriájához, ahogy azt várhatjuk is. Az eredeti forráskép egy küszöbszint meghatározása után kinullázzuk az amplitúdóterkép többi elemét, ahogy a 20. ábra mutatja. Ezután elvégezzük az összefüggőségi vizsgálatot a Matlab képfeldolgozó könyvtárának (Image Processing Toolbox) beépített `bwconncomp` függvény segítségével, és a legnagyobb kiterjedésű objektumot kiválasztjuk. Egy alacsonyabb küszöbszint beállítása után az eredeti amplitúdóterképen megkeressük ezt az objektumot, ahogy a 21. ábra mutatja. Ezt egyrészt kitöröljük az eredeti amplitúdóterképből, így előáll az új amplitúdóterkép, ahogy azt a 22. ábra mutatja.




19. ábra Eredeti amplitúdótérkép



20. ábra Küszöbérték feletti vászon

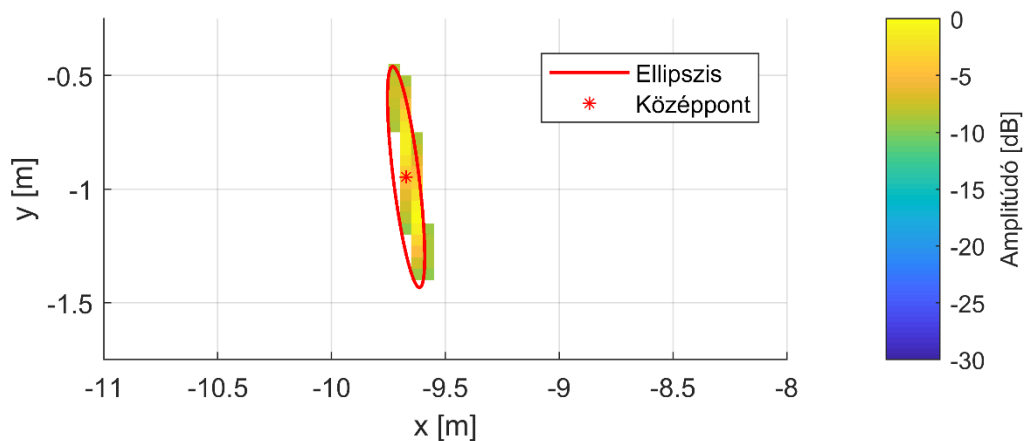


21. ábra Törlésre kerülő objektum



22. ábra Amplitúdótérkép a törlés után

Az eredetileg talált legnagyobb objektumra ellipszist illesztünk, ahogyan a 23. ábra mutatja. A kapott ellipsziszből meghatározható a forrás középpontja, illetve annak a szórása (a becült pozíció kovarianciamátrixa) is.



23. ábra Ellipszis illesztése a talált objektumra

Az osztály ciklikus működésű, addig fut, amíg a tisztított amplitúdótérképen még küszöbszint feletti objektumot talál. A talált források pozícióját, intenzitását, szórását visszaadja a hívó függvénynek.

4.10 Forráskövetés – A Kalman osztály

A 3.2.2. szakaszban bemutatott Unscented Kalman Filter (UKF) algoritmust valósítja meg a szimulációs keretrendszer Kalman osztálya. Az implementáció során a rendszeregyenletek számára Descartes-féle koordináta-rendszert választottunk, amelyben

a mikrofontömb található rögzített helyen, az origóban, a követett objektum pedig mozog. Az állapotvektor eltárolja a koordinátánkénti sebességet is:

$$x = \begin{bmatrix} r_x \\ r_y \\ r_z \\ v_x \\ v_y \\ v_z \end{bmatrix}$$

Az $\dot{r}(t) = v(t)$ összefüggést felhasználva felírhatjuk az A mátrixot is:

$$A = \begin{bmatrix} 1 & 0 & 0 & T_s & 0 & 0 \\ 0 & 1 & 0 & 0 & T_s & 0 \\ 0 & 0 & 1 & 0 & 0 & T_s \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix},$$

ahol T_s az időablak hossza. Ennek jelentése, hogy a becsült koordináta összeáll az előző pozícióból, valamint az előzőleg becsült sebességből számított elmozdulásból, míg a sebességet az előzőhöz viszonyítva változatlanoknak tekintjük. A formulában a következő pozíciót egyszerűen egy elsőfokú Taylor-sorral (előrelépő Euler-módszerrel) közelítjük.

A kimeneti (mérési) vektor ismét csak a pozíciót tartalmazza, azonban már gömbi koordinátarendszerben, ezért a következő transzformáció kerül alkalmazásra:

$$y = \begin{bmatrix} \varphi \\ \vartheta \\ r \end{bmatrix} = \begin{bmatrix} \tan^{-1} \frac{r_y}{r_z} \\ \tan^{-1} \frac{r_x}{r_z} \\ \sqrt{(r_x + r_y + r_z)^2} \end{bmatrix}$$

Ezt a választást az indokolja, hogy a mérés során érdemes az irányszögeket és a távolságot kiszámítani a térbeli koordináták helyett, ugyanis ezek becslése függetlenül is történhet, ami megkönnyíti a mérés kovarianciamátrixának definiálását. Például végtelen fókusz távolságú esetben az r távolságról nem kapunk információt, véges fókusz távolságú esetben pedig joggal feltételezhetjük, hogy a távolság becslését más pontosság jellemzi, mint az irányszögekét. Mivel sem az inverz tangens, sem pedig a hatványozás nem lineáris operáció, így az UKF algoritmus választása indokolt.

A rendszerzajt a következő módon becsüljük, tekintve, hogy a sebességet sokkal pontatlanabban tudjuk becsülni:

$$Q = T_s \begin{bmatrix} 10^{-3} & 0 & 0 & 0 & 0 & 0 \\ 0 & 10^{-3} & 0 & 0 & 0 & 0 \\ 0 & 0 & 10^{-3} & 0 & 0 & 0 \\ 0 & 0 & 0 & 10^3 & 0 & 0 \\ 0 & 0 & 0 & 0 & 10^3 & 0 \\ 0 & 0 & 0 & 0 & 0 & 10^3 \end{bmatrix} \quad (6)$$

Ez a választás azt is jelenti, hogy míg az $\dot{r}(t) = v(t)$ összefüggést kis hibával érvényesnek tekintjük, addig a $\dot{v}(t) = 0$ feltételezést nagyobb hibájúnak tartjuk. Ez a választás indokolt, hiszen az utóbbi egyenlet nem fizikai törvényszerűsége alapján, hanem a drón mozgásának egy, a valóságtól kisebb-nagyobb mértékben elrugaszkodott modellje.


A becslés kovarianciamátrixának kezdeti P_0 értékét szükséges megadnunk, amit a kezdeti pontatlanság miatt nagyra választottunk. Emellett azt is feltételezzük, hogy kezdetben a becslések függetlenek egymástól, így a kezdeti kovarianciamátrix diagonális. Az időlépés során a nemlineáris megfigyelési egyenlet és a rendszer dinamikáját leíró kapcsolat következtében a kovarianciamátrix nem marad diagonális.

$$P_0 = \begin{bmatrix} 10 & 0 & 0 & 0 & 0 & 0 \\ 0 & 10 & 0 & 0 & 0 & 0 \\ 0 & 0 & 10 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1000 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1000 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1000 \end{bmatrix} \quad (7)$$

Hasonlóképp a kimenetet terhelő zajvektor kovarianciamátrixának is adunk egy kezdeti értéket, ezt azonban minden mérés során a forráslokalizációkor megállapított szórások figyelembevételével lehetőségünk van frissíteni:

$$R_0 = \frac{1}{T_s} \begin{bmatrix} 10^{-5} & 0 & 0 \\ 0 & 10^{-5} & 0 \\ 0 & 0 & 10^{-3} \end{bmatrix}$$

Amint az (6) és a (7) képletekből látható, a rendszerzaj a mintavételi idővel nő, mivel távolabbi időre kell előre becsülni a rendszer állapotát, ami a bizonytalanság akkumulációját jelenti. A mérés kovarianciamátrixa ezzel szemben a mintavételi idővel csökken, hiszen a méréshez a nagyobb idő alatt több minta áll rendelkezésre, így átlagolással pontosabb mérési eredményt kapunk. A szűrő működésének helyességét a 24. ábra szemlélteti, a fent bemutatott spirál trajektórián haladó forrás esetében. Az ábrán a szűrő már „beállt” állapotban látható, a viselkedését részletesebben az 5. fejezetben ismertetem.




24. ábra Kálmán-szűrő működése

4.11 Frekvenciakövetés – A FreqSearch osztály

A FreqSearch osztály feladata a megtalált forrás frekvenciájának meghatározása, a frekvencia változásának követése. Működésének alapja a 3.3.1. szakaszban ismertetett HPS módszer. Esetünkben a HPS algoritmus nem egy előre meghatározott iterációszám eléréséig fut, hanem az iteráció folytatásához küszöbszintek kerülnek meghatározásra. Annak a vizsgálata, hogy a ciklus folytatódjon-e, két küszöbszinttől függ, egyrészt teljesülnie kell valamely pontra, hogy az utolsó ciklus óta bizonyos mértékben nőtt a szintje, emellett a teljes HPS során nagymértékben nőtt a szintje. Amennyiben nem található olyan pont a spektrumban, amelyre ez a két feltétel érvényes, akkor a ciklus megáll. A küszöbértékek úgy lettek beállítva, hogy általános használat mellett a harmonikusok 4–6 iterációig legyenek figyelembe véve.

A 25. ábra az osztály működését mutatja, a baloldalon az eredeti jelminta spektruma látható, a jobb oldalin pedig a HPS spektruma, 6 harmonikus figyelembe vételével. Megfigyelhető, hogy míg hagyományos esetben kb. 10 dB különbség van a két legerősebb jelszint között, addig a HPS segítségével ezt 55 dB-re sikerült növelni, ami egyértelmű azonosítást tesz lehetővé. Ez azt is jelenti, hogy akár zajszint közeli jelszintek esetében is a HPS segítségével képesek lehetünk a lapátfrekvenciát azonosítani.



25. ábra A HPS implementációja


A HPS meghatározása után megkeressük annak maximum értékét, azzal a feltételezéssel élünk tehát, hogy nincs harmonikustartalmat sugárzó zavarforrás. Miután ezzel meghatároztuk a lapátfrekvenciát (a lesugárzás alapfrekvenciáját), meg kell azt is határozni, melyik harmonikuson történjen a követés. Erre az egyik korlátunk, hogy a képtisztító algoritmusaink többsége 4 Helmholtz-szám érték felett működőképes, így ennél alacsonyabb frekvenciát választani nem javasolt. A másik kitétel, hogy a választott harmonikus körül nagy legyen a jel-zaj viszony, vagyis vagy legyen kellően magas a jelszintje, vagy ne legyen körülötte zavarforrás. Az osztály a korábban választott frekvenciát is figyelembe veszi, az előzőleg választott frekvenciához közel eső harmonikusok közül választja ki a következőt.

Az algoritmus jelenleg úgy működik, hogy megkeresi a 4 Helmholtz érték feletti és az előzőleg választott frekvenciához közel eső legerősebb harmonikust, mindezt a frekvencia növekedésével fordított arányban súlyozva. A súlyozást a bemeneten egy aluláteresztő szűrő segítségével biztosított.

5 Eredmények

A felépített és implementált modellt az előző fejezetben bemutatott szimulációs keretrendszerben különböző teszteknek vettem alá. Néhány tesztet eredményeit már a 4. fejezetben ismertettem, ebben a fejezetben pedig egy kiválasztott tesztet mutatok be részletesen. A bemutatandó tesztet a szimulációs rendszer összes lényeges elemét felhasználja.

A teszt során a szimulációs környezetünkbe két forrás helyeztünk el (26. ábra): a zöld körpályán mozgó fehérzajt kibocsátó zavarforrást, valamint a piros trajektórián mozgó, a felvett quadrokopter hangját sugárzó jelforrást. Ezek mellett minden mikrofon jeléhez hozzáadtunk még egymástól független, alacsonyabb jelszintű fehérzajt. A mikrofontömb a fent is használt, 24 elemű, kör alakú elrendezés, a források pedig a mikrofontömb síkjától 20 m-re elhelyezkedő párhuzamos síkban mozognak. A mintavételi frekvencia a szabványos 44100 Hz, a feldolgozási blokkok hossza pedig $T_{blk} = 0,08$ s. A lekeveréshez harmadfokú, 100 Hz sáv szélességű szűrőt használtam.




26. ábra Szimulációs elrendezés

A zavarforrás sebessége 5 m/s, a jelforrásé pedig 20 m/s. A zavarforrás jelszintje közel háromszor akkora, mint a jelforrásé, így csak a harmonikusokat tartalmazó szűk sávokban erősebb a jelforrás jelszintje. Ezen beállítások mellett teszteltük a képtisztítást a MUSIC algoritmus segítségével, a forráslokalizációt, a Kalman-szűrőt, és a frekvenciakövetés működését, illetve visszacsatolásukat egymásba. A teszt során tehát végig a forráskövetés elemei az előző ciklusból származó meghatározott frekvencián


működtek, míg a frekvenciakövetés elemei pedig az előző ciklusból származó pozíciót használták fel.

A 27. ábra és 28. ábra mutatja a Kalman-szűrő kimenetén megjelenő pozíció- és sebességbecslést, illetve ezek becsült kovarianciájából számított szórásértékeket. Az ábrákról látható, hogy egy kis időre van szükség ahhoz, hogy a követés beálljon, a teszt elején még nagy kovariancia mellett a pozíció és sebesség becslése bizonytalan, azok értéke is nagyban ingadozik. A kezdeti pontatlanság aztán lecsökkent, és onnantól a követés megbízhatóan működött, nem ugrott át a másik forrás követésére a rendszerünk. A nemlineáris Kalman-szűrő beállása után tehát a pozícióbecslés megbízható. Az ábrákon láthatjuk a jelforrás tényleges sebességét is (zöld referenciavonal).

Ahogy a Kalman-szűrőt felépítettük, látható itt is, hogy a sebesség kovarianciája legalább egy nagyságrenddel nagyobb a teszt futtatása során is, mint a pozícióé. Megfigyelhető, hogy annak ellenére, hogy a szűrő a sebességre nem kap közvetlenül mért adatot, a rendszermodell és a visszacsatoló K mátrix segítségével a sebességről is jó becslést képes adni a szűrő. A kezdeti nagy kovariancia választása is helyes döntésnek tűnik, ugyanis így biztosítható a kezdetekben a helyes forrás megtalálása.



27. ábra Pozíció és sebesség becslése




28. ábra Pozíció és sebesség kovarianciájának (szórásának) becslése

A 27. ábra megfigyelhető az is, hogy az x - és y -irányú sebesség a becslés szerint nem szinuszosan változik, ahogy azt a spirál pályától elvárhatnánk. Ez eltérés oka a szűrőben megfogalmazott $\dot{v} = 0$ állítás, mely a szűrőben a pálya simítását vonja maga után. A simítás hatása legjobban a spirál legkisebb sugarú íveinél figyelhető meg, ekkor változik ugyanis a leggyorsabban a sebesség iránya. Elmondható, hogy a megválasztott paraméterekkel a szűrés jól működik, még a feltételezéseként megfogalmazott egyenletes sebességtől lényeges eltérő esetekben is.

A 29. ábra mutatja a frekvenciakövetés működését a szimuláció során. A felső ábrán a talált alapfrekvenciát láthatjuk kék színnel, míg zölddel a valós lapátfrekvencia értékét. Amint az ábráról leolvasható, az idő nagy részében éppen a lapátfrekvenciát találtuk meg, csupán néhányszor ennek a felét, és egyszer ennek a dupláját. Érdeemes megjegyezni, hogy amíg a lapátfrekvencia többszörösét, vagy annak hányadosát találjuk meg, addig a követés mindenképpen lehetséges marad, így ez a része hibátlanul működött a teszt során az algoritmusnak.

A 29. ábra alsó diagramján pedig a választott követési frekvenciát láthatjuk kék színnel, sárga színnel a lapátfrekvencia harmonikusait, míg piros színnel a Helmholtz-szám négyszeresét láthatjuk. Amint említettük az előző fejezetekben, a MUSIC algoritmus ezen érték felett tud csak hatékonyan működni, így a frekvenciát is e fölé célszerű választanunk. Amint látható, ez a feltétel teljesült a szimuláció során. A másik

feltétel, hogy a lapátfrekvencia valamely harmonikusát válasszuk ki, olyan szempontok figyelembe vételével, mint annak jelszintje, illetve jel-zaj viszonya. Amint az ábrán látható – és a helyes alapfrekvencia értékéből következtethető – ez a feltétel is teljesült végig a teszt során. Az is látható, hogy a választott frekvencia elég alacsonyan maradt a szimuláció során.



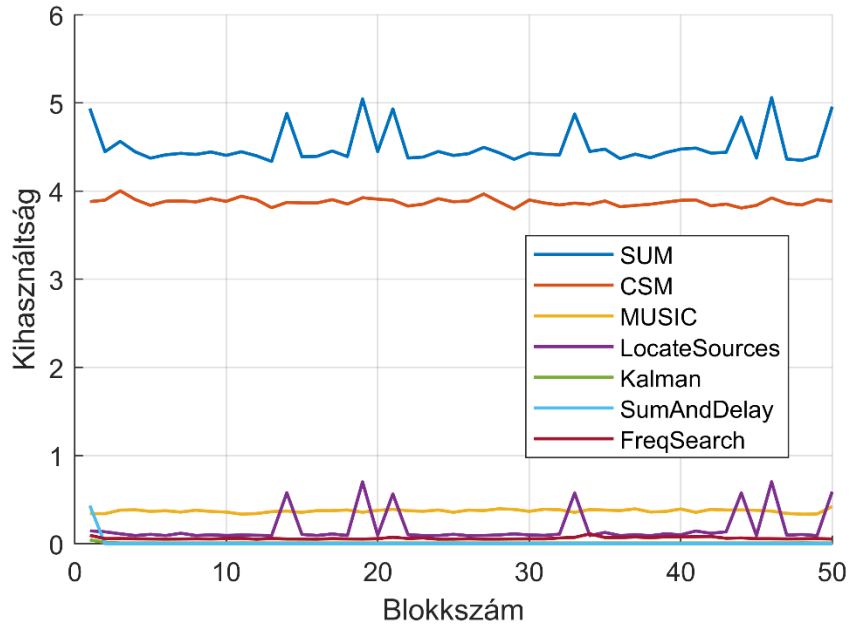
29. ábra Frekvenciakövetés működése

5.1 Futási teljesítmény

Az előbbi fejezetben bemutatott teszt során arra is kitértem, milyen futási idővel rendelkeznek az egyes komponensek a szimulációs környezetben belül. A futási időt a Matlab beépített tic és toc parancsaival mértem, a környezetet egy átlagos teljesítményű számítógéppel végeztem (Processzor: Intel Core i7-3632QM; Videókártya: Nvidia GT-645M; RAM: 8GB). A mérés során a vászon 100 x 250 pont felbontású volt, a blokkméret pedig 80 ms-nek adódott. A mérés során minden ábrázolás kikapcsolásra került.

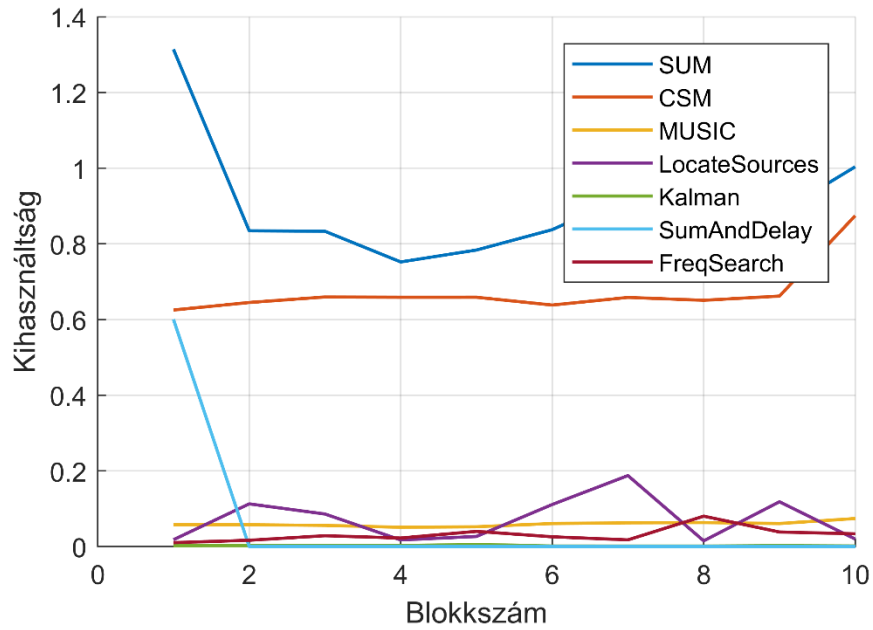
A 30. ábrán láthatóak a mérési eredmények. Az egyes folyamatok futási idejét a blokkmérethez viszonyítva ábrázoltuk. Elmondható, hogy a jelenlegi Matlab kód futtatása során a keresztkorrelációs mátrix létrehozása emészti fel a legtöbb erőforrást, átlagosan ennek kiszámítása négyszeresen felülmúlja a rendelkezésre álló időt. Ezek után a MUSIC algoritmus rendelkezik a legtöbb erőforrásigénnyel, ennek értéke 0.3 körül mozog. A Kalman, SumAndDelay és a FreqSearch osztályok alacsony

processzorkihasználtsággal rendelkeznek, ezek értéke 0.1 körül mozog. Amint az ábráról látható még, egyedül a LocateSources osztály futásideje nem determinisztikus, az a futás során erőteljesen ingadozhat.



30. ábra A különböző osztályok futásideje a blokkmérethez viszonyítva 80 ms hosszúságú blokkméret mellett

Természetesen a blokkméret növelésével, vagy pedig a vászon pontjainak a csökkentésével az egy blokkra eső számításigény csökkenni tud. Amennyiben a vászon pontjainak számát az ötödére csökkentjük, vagy pedig a blokkméretet növeljük az ötszörösére, akkor a jelenlegi környezet is képes valós idejű számítások végzésére. Így 400 ms hosszúságú blokkméretet választva a teljes futási idő immáron kisebb, mint a blokkméret, így a környezet valós idejű futásra képes, ezt mutatja a 31. ábra.



31. ábra A különböző osztályok futásideje a blokkmérethez viszonyítva 400 ms hosszúságú mellett


Elmondható tehát, hogy a jelenlegi tesztkörnyezetben, amennyiben a keresztkorrelációs mátrix kiszámítását nem vesszük figyelembe, valós idejű számítások végezhetők. A keresztkorrelációs mátrix számítását figyelembe véve azonban a futási idő többszöröse lehet a rendelkezésre álló időablaknak. Ennek a problémának a megoldására egyrészt lehetséges a programkód optimalizálása – ugyanis a jelenlegi kód még nem optimalizált, másrészt pedig más környezetbe, esetünkben C++ programnyelvre – való átültetés. Ennek a megvalósítását a következő fejezetben ismertetem.

6 C++ implementáció

Ahogy a korábbi fejezetben említettük, a futási teljesítmény növelésének érdekében C++ programnyelvű környezetbe ültettük át a Matlab szimulációs környezetet. A C++ környezetet a QtCreator nevű fejlesztőkörnyezetben alkottuk meg. A következő osztályokat valósítottuk meg: BlockBuffer; MixDown; CsmEstimator; Clean; MUSIC; SumAndDelay. Amint látható, a forráskövetést megvalósító algoritmusok (FreqSearch, LocateSources, Kalman-szűrő) még hiányoznak. Mivel azonban a hiányzó algoritmusok jelentették a legkisebb erőforrásigényt a Matlab környezetben is, így a futásidőben nem okoz ez számottevő különbséget.


A környezet úgy lett megalkotva, hogy az amplitúdótérkép egy valós kamera képére illeszthető, így láthatóvá válnak a zajt kibocsátó tárgyak is. A mikrofonok beérkező jeleinek a feldolgozásához szükséges a környezetben a mikrofontömb fizikai paramétereinek a megadása. Ahogy a Matlab szimulációs környezetet is megalkottuk, úgy ebben a környezetben sincsenek korlátozva a különböző osztályok példányszámai, így tetszőleges forrásra lehetséges a fókuszálás.

A környezet teszteléséhez több mérést vittünk véghez, ennek az elrendezését mutatja a 32. ábra. A méréseket a BME-HIT akusztikai süketszobájában végeztük, ami közelítőleg végtelen féltérként modellezhető.



32. ábra Mérési elrendezés


A rendelkezésre álló eszközeink segítségével jelenleg egy maximum 14 mikrofonból álló tömböt tudunk alkalmazni, így a teszthez is 14 ennyi mikrofont használtunk. A közeljövőben várjuk egy ennél jobb eszköz beérkezését, amellyel már a korábbi környezetben szimulált 24 elemből álló mikrofontömböt is megvalósíthatunk. A használt mikrofontömb elrendezését mutatja a 33. ábra. Amint látható, a mérés során egy a mikrofontömbünk kereszt alakú volt, a vízszintes száron nyolc, a függőleges száron pedig hat darab, egymástól egyenlő távolságra elhelyezett mikrofont alkalmaztunk.




33. ábra Mikrofontömb kialakítása - közeli kép, mind a négy irányban még egy-egy mikrofon található a tömbben

A mérés során összehasonlítottuk a különböző képalkotó algoritmusok hatékonyságát, ezeket mutatja a 34. ábra, 35. ábra és a 36. ábra. Megfigyelhető, hogy a hagyományos nyalábformálással alkotott kép sokkal jobban szétkenődött, mint a képtisztító algoritmusok által készített. A MUSIC és a CLEAN-PSF algoritmus összehasonlításáról elmondható, hogy azonos erőforrásigény mellett a MUSIC segítségével több pontból álló vászonra lehetséges a képalkotás, míg a CLEAN esetében csak kisebb felbontású vászon fér bele a számítási kapacitásba. Az ábrákon látható, hogy az előbbieken említett tényezők ellenére a CLEAN látszólag nagyobb felbontással rendelkezik abból az okból kifolyólag, hogy a CLEAN igyekszik a forrásokat egy-egy pontba összesűriteni. Azonban, amennyiben a forrásaink nem pontszerűnek tekinthetők, hanem kiterjednek, vagy pedig a vászon felbontása túl alacsony, a CLEAN algoritmussal nem a forrásunk középpontját találjuk meg, ebből pedig rossz forrásbecslés következhet. A MUSIC esetében habár a források szétkenődtebbek lehetnek, a valós forrás


középpontja egybe fog esni az amplitúdótérképen található középponttal, annak kiterjedéséből pedig következtethetünk a mérésünk szórására is.



34. ábra Hagyományos nyalábformálással alkotott amplitúdótérkép



35. ábra MUSIC algoritmussal alkotott amplitúdótérkép



36. ábra CLEAN-PSF algoritmussal alkotott amplitúdótérkép

Összességében tehát elmondható, hogy a rendszer használható valós idejű mérések végzésére, a környezet egyaránt alkalmas online és offline hang- és képminták feldolgozására. A különböző algoritmusok paraméterei is valós időben állíthatóak. A méréseink kimutatták, hogy a C++ nyelvű implementációt egy átlagos teljesítményű számítógép már gond nélkül tudja valós időben futtatni.

7 Konklúzió

Dolgozatomban egy szimulációs rendszert mutattam be, mely alkalmas mozgó zajforrások észlelésére és követésére az akusztikus képalkotás és nyálábformálás különféle módszereinek felhasználásával. Amint a dolgozatban leírtak rámutattak, mozgó források esetén a képalkotást és az akusztikai fókuszálást visszacsatolt rendszerként lehetséges alkalmazni. Így olyan forráslokalizációt valósíthatunk meg, mellyel pontosabban határozható meg a mozgó forrásunk pillanatnyi helyzete, és így az arra való akusztikai fókuszálás is pontosabb eredményt ad. A mozgás dinamikájának figyelembe vételével lehetőség van a mozgó forrás követésére és a lokalizáció robusztusabbá tételére. Célalkalmazásként kisméretű forgószárnyas pilóta nélküli repülőgépek követését tűztem ki célul. Megvizsgáltam az ilyen eszközök lesugárzási jellemzőit és a forráskereső és -követő algoritmusaimat ezekhez a jellemzőkhöz optimalizáltam. Szimulációkkal mutattam be a rendszer működését.

A szimulációs keretrendszert objektum-orientált Matlab környezetben implementáltam. A szimulátorban egyszerűen lehet tetszőleges trajektórián mozgó, tetszőleges jelet kibocsátó mozgó források hangterét szimulálni, a hangteret tetszőleges elrendezésű mikrofontömbbel mintavételezni, majd a vett jelet különböző algoritmusokkal elemezni, feldolgozni.

Saját implementációt készítettem több képtisztító algoritusról (MUSIC, DAMAS, CLEAN). Az ezek által alkotott amplitúdótérképekről a forráspozíciók kinyerésére, illetve az egyes pozíciókhoz tartozó szórásértékek becslésére két saját módszert is javasoltam, melyeket különböző tesztesetekben kipróbáltam. Megvalósítottam egy Unscented Kalman Filter algoritmust, mely a Kalman-szűrő nemlineáris kiterjesztése. Ezt az algoritmust alkalmazva egyidejűleg több forrás is követhető. A Harmonic Product Spectrum módszeren alapuló frekvenciakövetés bevezetésével a modell még robusztusabbá vált, ami a korábinál alacsonyabb jel-zaj viszony esetén is lehetővé teszi a stabil követést.

Érdekes problémát vetett fel a mozgó célpontra történő akusztikai fókuszálás megvalósítása. A hagyományos feldolgozás során a minták egymás után blokkjai elcsúsznak, így az eredő jelben hibás szakaszok keletkezhetnek. A probléma kiküszöbölésére két működőképes javaslatot is tettem: a blokkok interpolációval vagy

ablakozással történő összegzését. Míg az első módszer nagyobb számításigényű és a Doppler-hatás változását is képes kompenzálni, addig a másik megoldásom valós időben is alkalmazható és szintén elegendően sima kimeneti jelet állít elő.

A számításigény csökkentése céljából a Matlab környezeten belüli forráskód átültetésre került egy C++ programnyelvű környezetbe, amely bizonyíthatóan valós idejű működésre is képes. A későbbiekben tervezzük még az eddig nem implementált funkciók átátültetését is a C++ nyelvre.

A rendszer továbbfejlesztését tekintve elmondható, hogy a követést végző osztályokat még szükséges fejleszteni, illetve finomhangolni a lehető legpontosabb eredmények elérése céljából. Ugyanez igaz a Kalman-szűrőre, annak változóinak finomhangolása, illetve az adott alkalmazás paramétereit figyelembe vevő beállítása szükséges még.

Szükségesnek tűnik a számításigény csökkentése céljából két- vagy többlépcsős képtisztítás alkalmazása is, melynek során először egy fizikai méreteiben nagyobb, azonban kisebb sűrűségű vászonra végeznénk el a forráskeresést, majd ezután egy második, kisebb, azonban nagyobb sűrűségű vászon segítségével becsülnénk pontosabban a forrás(ok) helyzetét. A forrás távolságának pontosabb becsléséhez ugyancsak érdemes még megvizsgálni a forráslokalizáció egy átalakított változatát, amellyel egy háromdimenziós vászonon is lehetséges lesz a források helyzetének becslése.

A szimulációs rendszer tesztelésének következő lépése valós környezetben mikrofontömb segítségével felvett minták felhasználása lesz. A fejlesztések utolsó fázisában a MATLAB és a C++ forráskódot tervezzük átimplementálni DSP alapú célhardverre, így a számítási idő a tovább csökkenhet majd.

Köszönetnyilvánítás

Szeretnék köszönetet mondani konzulensemnek, Dr. Rucz Péternek a sok értékes segítségért, támogatásért és hozzászólásért.

Irodalomjegyzék

- [1] Tapolczai Péter: „*Akusztikus nyalábformálás alkalmazása mozgó zajforrások észlelésére és követésére*”, BME-VIK TDK dolgozat, 2018, online: <https://tdk.bme.hu/VIK/ViewPaper/Akusztikus-nyalabformalas-alkalmazasa-mozgo>
- [2] Németh Zsolt: „*Akusztikus iránymérő eljárás fejlesztése*”, BME-VIK Diplomaterv, 2011, online: <https://diplomaterv.vik.bme.hu/hu/Theses/Akusztikus-iranymero-eljaras-fejlesztese>
- [3] Almási Attila: „*Mikrofontömb alkalmazása az épület- és teremakusztikai méréstechnikában*”, BME-VIK Diplomaterv, 2014, online: <https://diplomaterv.vik.bme.hu/hu/Theses/Mikrofontomb-alkalmazasa-az-epulet-es>
- [4] H. L. van Trees: "*Optimum array processing Part IV of Detection, Estimation, and Modulation Theory*" John Wiley & Sons, Inc., New York (2002)
- [5] Ritecz Tamás Dániel: „*Forgó légcsavarok által lesugárzott zaj mérése és elemzése*”, BME VIK Szakdolgozat, 2018, online: <https://diplomaterv.vik.bme.hu/hu/Theses/Forgo-legcsavarok-atal-lesugarzott-zaj-merese>
- [6] R. P. Dougherty: „*Functional Beamforming*”, Proceedings of the 5th Berlin Beamforming Conference, February 19–20th, 2014, Berlin, Germany, pp. 1–25 online: <http://www.bebec.eu/Downloads/BeBeC2014/Papers/BeBeC-2014-01.pdf> (utoljára megtekintve: 2018. október 27.)
- [7] G. Herold, E. Sarradj: „*Performance analysis of microphone array methods*”, Journal of Sound and Vibration **401** pp. 152–168 (2017) DOI: [10.1016/j.jsv.2017.04.030](https://doi.org/10.1016/j.jsv.2017.04.030)
- [8] T. F. Brooks, W. M. Humphreys: „*A deconvolution approach for the mapping of acoustic sources (DAMAS) determined from phased microphone arrays*”, Journal of Sound and Vibration **294** pp. 856–879 (2006) DOI: [10.1016/j.jsv.2005.12.046](https://doi.org/10.1016/j.jsv.2005.12.046)
- [9] P. Sijtsma: "*CLEAN based on spatial source coherence*" Research report (NLR-TP-2007-345), National Aerospace Laboratory NLR (2007) online: <https://reports.nlr.nl/xmlui/bitstream/handle/10921/408/TP-2007-345.pdf> (utoljára megtekintve: 2018. október 24.)
- [10] P. Gerstoft, C. F. Mecklenbräuker, W. Seong, M. Bianco: „*Introduction to compressive sensing in acoustics*”, The Journal of the Acoustical Society of America **143**, 3731–3731 (2018) DOI: [10.1121/1.5043089](https://doi.org/10.1121/1.5043089)
- [11] A. Xenaki, P. Gerstoft, K. Mosegaard: "*Compressive beamforming*" Journal of the Acoustical Society of America **136**(1) pp. 260–271 (2014) DOI: [10.1121/1.4883360](https://doi.org/10.1121/1.4883360)

- [12] Y. Park, Y. Choo, W. Seong: „*Multiple snapshot grid free compressive beamforming*” *Journal of the Acoustical Society of America* **143**, pp. 3849–3859 (2018) DOI: [10.1121/1.5042242](https://doi.org/10.1121/1.5042242)
- [13] P. S. Maybeck: "*Stochastic models, estimation, and control*", Academic Press, Inc., New York (1979)
- [14] S. Bonnet, C. Bassompierrea, C. Godina, S. Lesecqa, A. Barraudb: "*Calibration methods for inertial and magnetic sensors*", *Sensors and Actuators A: Physical* **156**(2) pp. 302–311 (2009) DOI: [10.1016/j.sna.2009.10.008](https://doi.org/10.1016/j.sna.2009.10.008)
- [15] D. Simon: "*Optimal State Estimation – Kalman, H_∞ , and Nonlinear Approaches*" John Wiley & Sons, Inc., Hoboken, New Jersey (2006)
- [16] Belső Zoltán, Gáti Balázs, Koller István, Rucz Péter, Turóczi Antal: "*Design of a nonlinear state estimator for navigation of autonomous aerial vehicles*" *Repüléstudományi közlemények (Aviation scientific publications)* **XXVII/3** pp. 255–276 (2015) online: http://www.hit.bme.hu/~rucz/pub/Belso_etal_-_2015_reptud.pdf
- [17] Turóczi Antal, Belső Zoltán, Rucz Péter: „*Nemlineáris állapotbecslésen alapuló navigációs algoritmus*”, AMORES (Autonomous Mobile Remote Sensing) projekt, belső kutatási jelentés (2014)
- [18] P. de la Cuadra: „*Robust Methods for Pitch Detection*”, CCRMA, Stanford University, online: https://ccrma.stanford.edu/~pdelac/220c/pitch_detection/img2.htm (utoljára megtekintve: 2018. október 24.)
- [19] P. de la Cuadra, A. Master, C. Sapp: „*Efficient Pitch Detection Techniques for Interactive Music*”, CCRMA, Stanford University (1999), online: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.142.7667&rep=rep1&type=pdf> (utoljára megtekintve: 2018. október 24.)
- [20] H. E. Bass , L. C. Sutherland, A. J. Zuckerwar , D. T. Blackstock, D. M. Hester: „*Atmospheric absorption of sound: Further developments*”, *Journal of the Acoustical Society of America* **97**, 680–683 (1995) DOI: [10.1121/1.412989](https://doi.org/10.1121/1.412989)