



M Ű E G Y E T E M 1 7 8 2

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

Kupfer Viktória

MIKRO-DOPPLER FOLYAMATOK MÉRÉSE ÉS ANALÍZISE

TDK dolgozat

KONZULENS

Dr. Seller Rudolf

BUDAPEST, 2023

Tartalomjegyzék

Összefoglaló	4
Abstract	5
1 Bevezetés	6
2 Méréshez használt technológiák és eszközök	7
2.1 A radar	7
2.2 Mikro-Doppler jelenségek	8
3 A mérési rendszer működése, korlátai	9
3.1 Kalibráció.....	9
3.2 Érzékenység szintbeli különbségre	11
4 A gépi tanulás (ML)	13
4.1 A mesterséges intelligencia alapja és tanulási technikáinak típusai	13
4.2 Felhasznált algoritmusok	14
5 Spektrum elemzési algoritmus	16
6 Az MI tanítása	19
6.1 Tanító adat formátuma.....	19
6.2 AI tanítása felső szinten	20
6.3 Az AI használata anyag klasszifikációra	22
6.4 Fordulatszám meghatározás mesterséges intelligenciával.....	23
7 Mérések és megfigyelések	28
7.1 Szénszállás és műanyag propeller összehasonlítása	28
7.2 Fordulatszám meghatározás.....	31
7.3 Forgási frekvencia hatása.....	34
7.4 Helyfüggés	36
7.5 Környezeti tényezők hatása – többutas terjedés	38
7.6 Két propeller együttes spektruma	41
7.6.1 Egymás melletti elrendezésben.....	42
7.6.2 Egymás takarásában.....	44
7.6.3 Két propeller fordulatszámának becslése	46
7.7 Egy valós drón spektruma rögzített állapotban.....	52
7.8 Egy valós drón mérése a levegőben.....	56
7.9 Valós drón fordulatszám becslése.....	59

8 Összegzés.....	62
Irodalomjegyzék.....	63
Függelék.....	64

Összefoglaló

Dolgozatom témája a drónok radar általi klasszifikációja, főbb paramétereinek becslése. A klasszifikációhoz és a paraméterbecsléshez a drónok mikro-Doppler jelenségét használom fel. Ehhez a HVT tanszéken speciálisan mikro-Doppler folyamatok mérésére kifejlesztett radart használok, aminek a fejlesztésében magam is részt vettem és ezen radar a céltárgy mozgó alkatrészeiről képes adatokat szolgáltatni, jelen esetben propellerekről, azok fordulatszámáról, jellegzetes anyagra és formára jellemző spektrumáról.

Bemutatom a mérési folyamatot, a különböző elrendezéseket, laboratóriumban, a szabadterben, modellek és valós drón esetén. Ismertetem az adatrögzítés, feldolgozás, regresszió lépéseit. Utóbbi során egy transzformációt hajtok végre a spektrumon, ami a leginkább jellemző tulajdonságokat emeli ki. Erre több lehetséges megoldást is ismertetek, illetve a fordulatszám becslésre is hozok példákat.

Mindemellett kitérek a területen a mesterséges intelligencia jogosultságára, bemutatok több eljárást, típust és egy konkrét tanítási módszerét. Megvizsgálom, mely paraméterek becsülhetők a technológia segítségével és mennyiben valósítható meg vele a drónok klasszifikációja.

Abstract

The topic of my thesis is the classification of drones by radars and the estimation of their main parameters. I use the micro-Doppler phenomenon of drones for classification and parameter estimation. For this, I use a radar specially developed at the HVT department for measuring micro-Doppler processes. I have also taken part in the development of this radar, which can provide data on the moving parts of the target, in this case on its propellers. From the data I can estimate their speed, and examine their spectrum looking for characteristics referring to the materials and shape.

I will present the measurement process, with different layouts, including in laboratory circumstances and in the open air using models and real drones. I explain the steps of data recording, processing, and regression. During the latter, I perform a transformation on the spectrum, which highlights the most characteristic features. I will explain several possible solutions for this, and I will also give examples for estimating the speed.

In addition, I discuss the authority of artificial intelligence in the field. I present several procedures, types and a specific teaching method. I will examine which parameters can be estimated with the help of the technology and whether classification of drones can be realized with it.

1 Bevezetés

Korunk sokoldalú eszközei a drónok, amit számos területen használnak egyre gyakrabban. A hobbi és esztétikai céloktól, a mezőgazdaságig, katonai felhasználásokig, a csomagszállításig egyre inkább terjed az alkalmazása.

A légteret mindig is figyelemmel kísérte az ember, tanulmányozta a madarakat, példájukra megépítette a repülőgépet. Onnantól óriási fejlődésnek indult a repülés tudománya, főleg a háborús években. Ekkor különösen fontossá vált a repülő tárgyak követése. Száz éve, a radar feltalálása óta, már nem lehet akadály a sötétség vagy a felhőzet, hogy az égen észleljünk valamit. A légtér szabályozása fontos, közérdekű feladat, így a drónok engedélyezése, szabályozása és észlelése aktuális probléma. Az észlelésen túl dolgozatomban megkísérlek több tulajdonságot is megbecsülni a drónokról a mikro-Doppler jelenség tanulmányozásával. Ezen adatok alapján klasszifikációs eljárásokat kutatok, hogy olyan paraméterek becsülhetőek legyenek, mint a propellerek fordulatszáma és azok miből készültek.

Mind ehhez segítségül hívom a mesterséges intelligenciát, a gépi tanulásos algoritmusokat, hogy mintázatokat keressek az adatokban. Napjaink új feladatára egy innovatív megoldást keresek, egy olyan technológiát használok, ami olyan forradalmat jelenthet, mint maga korábban a számítógép megjelenése.

2 Méréshez használt technológiák és eszközök

2.1 A radar

A RADAR maga egy mozaik szó, a RAdio Detection And Ranging (rádióérzékelés és távmérés) rövidítése. Hadi fejlesztések során jött létre az 1930-as években és a második világháborúban már alkalmazták. [7] Meghatározott irányban, adott frekvenciával rendelkező elektromágneses impulzust bocsát ki, ami a céltárgyról visszaverődve jut a detektorba. [2] A visszavert jel torzulásaiból következtethetünk a céltárgyra. Mivel a hullám terjedési sebessége állandó, a visszatérési időből következtethetünk a távolságra. Az energiaszintből megállapíthatjuk a céltárgy határos keresztmetszetét, ami a reflexiós tulajdonságait írja le az objektumra. A határos keresztmetszet egy adott sugarú gömb visszaverési képességeivel von analógiát. A céltárgy rendszerint mozgást végez, ami azt jelenti, hogy frekvencia torzulást okoz. Mikor közeledik magasabb lesz a frekvencia, amikor pedig távolodik csökken. Ezt hívjuk Doppler jelenségnek.

Az általam használt radart a Szélessávú Hírközlés és Villamosságtan Tanszék, Radar és távérzékelés csoportja fejlesztette. A radar folyamatos (CW – Continuous Wave) hullámot bocsát ki K-sávban, azaz 24 GHz frekvencián. Két elkülönített adási és vételi apertúra antennával rendelkezik. Az adó oldali antenna 10 dBm jelteljesítménnyel üzemel. Tápellátása történhet 12 V-os akkumulátorról vagy hálózati feszültségről, amit 12 V-ra transzformálunk és egyenirányúsítunk. A radar a vett jelet lekeveri 44.1 kHz frekvenciára, hogy egy számítógép hangkártyája által feldolgozható legyen. USB kábellel csatlakoztatható a radar egy PC-hez.

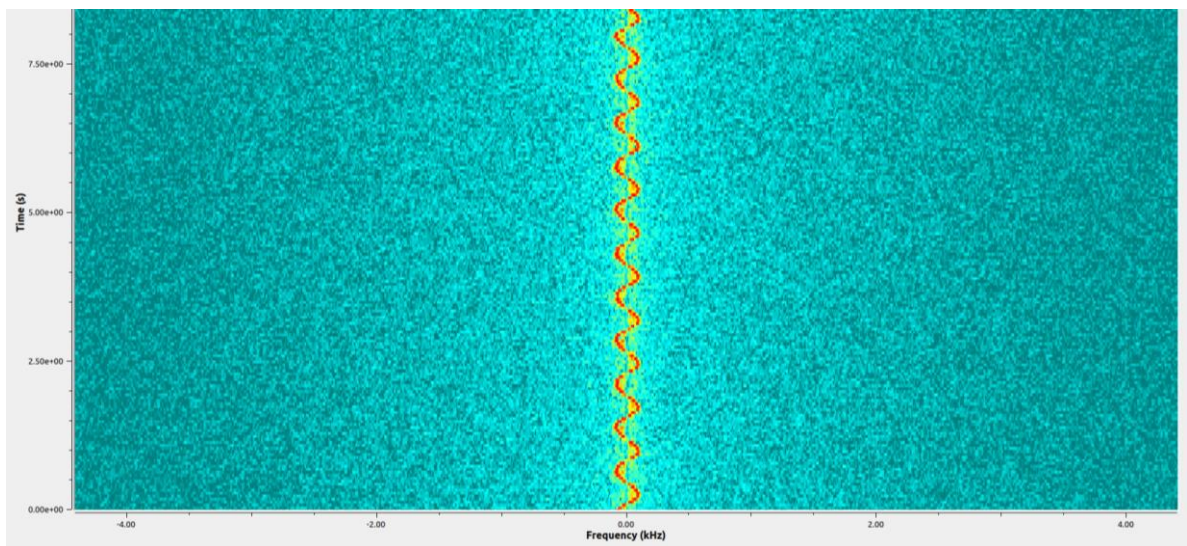
Ez a radar mikrohullámú Doppler jelenségek vizsgálatára lett fejlesztve, tehát távolság és sebesség mérésre nem alkalmas. Az általa hallható tartomány az akusztikus sáv, ami azt jelenti, hogy a céltárgy 0,1-62,5 m/s sebesség tartományban mozog. [2]

A vett jel alapsávra keverése esetén szükséges a koherens jelfeldolgozás, ami elérhető az I-Q értékek külön csatornán kezelésével. A folytonos FM jel értelmezhető egy feszültség komplex forgó vektor valós értéke szerint. Az I-Q csatornák külön kezelésének köszönhetően, a beérkező jel spektruma vivőfrekvencia körül azonos az alap sávra kevert jel spektrumával 0 Hz-től pozitív és negatív irányban. [2]

2.2 Mikro-Doppler jelenségek

Előző részben ismertettem a radar működését és a Doppler jelenséget általánosságban. Következőkben egy specifikus esetét ismertetem a jelenségnek.

A mikro-Doppler-effektus Doppler-frekvencia-modulációként jelenik meg koherens lézer- vagy mikrohullámú radarrendszerekben, amelyeket a céltárgy vagy a cél bármely részének mechanikai rezgései vagy elfordulása vált ki. Ezek a Doppler-modulációk a céltárgy jellegzetes jeleivé válnak, amelyek rezgő vagy forgó struktúrákat tartalmaznak, és bizonyítékot szolgáltatnak a cél és a mozgás azonosságáról. [8] Ezen jellegzetességek alapján megkülönböztethetünk biológiai lényeket, mint madarak vagy emberek, vagy négylábú emlősök; különféle légi és földi járműveket, illetve hajókat, tengeralattjárókat. Célszerű a mért spektrumokat vízszintes diagrammon ábrázolni, ami azt jelenti, hogy vízszintes tengelyen ábrázoljuk a spektrum intenzitását és a függőleges tengely szerint az adott időpontokban mért állapotát. Ilyen formában emberi szemmel is megfigyelhetünk jellegzetességeket, különbségeket.




1. ábra: Szabályos körmozgás spektruma vízszesdiagrammon ábrázolva a mikro-Doppler jelenség alapján

3 A mérési rendszer működése, korlátai

3.1 Kalibráció

A valós adatok érdemi feldolgozásához elengedhetetlen, hogy a mérő eszköz jól legyen kalibrálva, helyes működéséről meggyőződünk. Egy a feladatra ideálisnak tekinthető elrendezéssel végeztem a méréseket, ami azt jelenti, hogy egy úgy nevezett sárkány mikro-Doppler jelenségeit vizsgáltam. A sárkány egy alufóliával bevont gömb, amit egyenletes sebességgel egy karral együtt körbe forgat egy villanymotor. Ez egyfelől azért megfelelő, mert az egység sugarú gömb alapvető viszonyítási alap a radar technikában, ehhez mérten határozzák meg a hatásos keresztmetszetet. Az alufólia bevonat jó reflexiós felületet biztosít. Másfelől, a forgatási sebesség nem túl magas, emberi szemmel követhető. A periódusideje 1,7 másodperc. Mivel egyenletes körmozgást mérünk, ezért a vizesés diagrammon elvárt kép szinusz jellegű. A vizesés diagram nem más, mint a spektrumok időben egymás utáni ábrázolása.



2. ábra: A sárkány sematikus rajza

Ahhoz, hogy értelmezni tudjuk Doppler frekvenciában mért spektrumokat, pár számítást kell végezni. Ismert periódusidő és forgástengely alapján meghatároztam a

kerületi sebességet. A gömb középpontja és a forgástengely távolságát vettem a sugárnak, ami 14,75 cm.

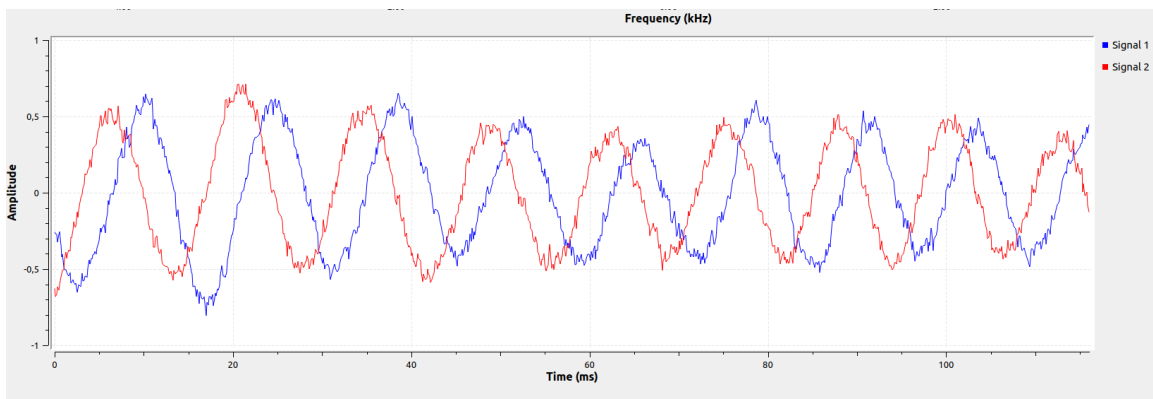
$$v_k = \frac{2\pi r}{T} = 0.545 \frac{m}{s}$$

A radar 24 GHz-es jelet bocsát ki, ennek a hullámhossza 1,25 cm. A Doppler frekvencia a körsebesség és a hullámhossz hányadosa, tehát 87,2 Hz.

$$\lambda = \frac{c}{f} = 0,0125 \text{ m}$$

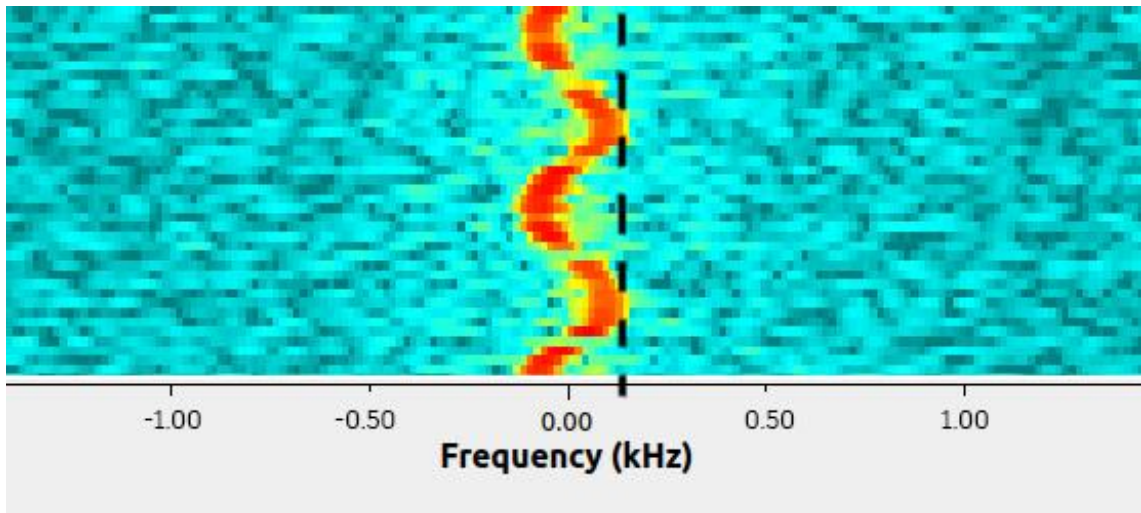
$$f_D = \frac{v_k}{\lambda} = 87,2 \text{ Hz}$$

20 másodpercig mértem folyamatosan és az adatokat többféleképpen feldolgoztam GNU Radio-val. Bináris formátumban rögzítettem, egy bash script segítségével, ahol paraméterként megadható a felvétel hossza másodpercben. A bináris fájlt a GNU Radio-val beolvasom, komplex formátummá alakítom, végzek az adatokon egy decimálást, aluláteresztőn szűröm és ábrázolom. Folyamatosan olvasva időben haladva megjelenítettem az I és Q csatornát. A 3. ábráról leolvasható, hogy a két jel amplitúdója egyforma nagyságú, kettő között 90° fázistolás tapasztalható. Tehát a sztereó bemenet szimmetrikus, nem szükséges szoftveres súlyozás.



3. ábra: Az I és Q csatorna időtartományban

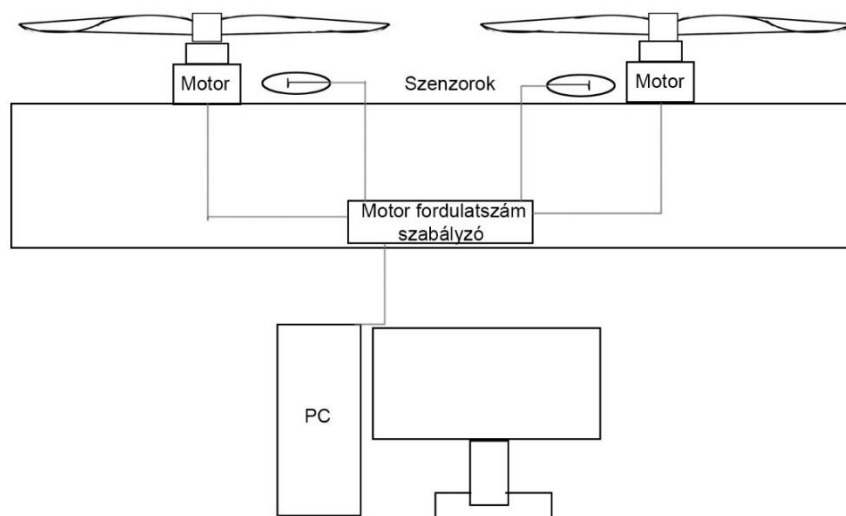
A vízésdiagrammon pedig leolvasható a gömb sebessége. Ez Doppler frekvenciában mérhető, a 4. ábra alapján a legnagyobb mért frekvencia 120 Hz körül volt. Ez a legszélső pont kerületi sebessége, az előre meghatározott Doppler Frekvencia körülbelül 4/3 szorosa. Eszerint az eredmény helytálló, hiszen a legszélső ponthoz tartozó sugár 4/3 szorosa a gömb középpontjához tartozó sugárnak.



4. ábra: A sárkány sebességének leolvasása vízésésdiagrammról


3.2 Érzékenység szintbeli különbségre

Továbbiakban a méréseket valódi drón propellerekkel végeztem, az előző méréshez képest nagyságrenddel magasabb frekvencián. A propellereket egy villanymotor hajtja akkumulátorral, és egy Arduino vezérli. Soros porton lehet neki adatokat küldeni a forgatási frekvenciát illetően. Hz mértékegységet használok a fordulatszám méréséhez. Az Arduino egy szabályzót is megvalósít, folyamatosan monitorozza a frekvenciát és jó pontossággal tartja a kívánt értéket.




5. ábra: A propeller forgató teszt pad blokkvázlata


Az elektromágneses hullám a távöltérben síkhullámnak tekinthető, nem érzékeny a radar és a céltárgy távolságához képest kicsi eltérésekre. Azonban a laborban a méréseket közlelről végeztem, ahol már számolni kell a beesési szöggel, a hullámfront domborultsága miatt. Ennek ellenére érdemesebb közelebről vizsgálni, mert jobb dinamikatartomány érhető el, ideálisabb eredményt kapok, jobban megfigyelhetőek a sajátosságok. Tehát ügyelni kell, a jó szintbeli beállításra, hogy a céltárgy és a radar egy vonalban legyen, különben a mérés hamis eredményekre vezet. Alábbiakban a 7. és 8. ábrán szemléltetem, mekkora eltérések keletkehetnek I és Q csatornánként.



6. ábra: A radar közel és távoltere



7. ábra: A radar és a céltárgy nem egy magasságban van



8. ábra: A radar és a céltárgy egy magasságban van

4 A gépi tanulás (ML)

Napjainkban forradalmi számítástechnikai ágazatnak számít a mesterséges intelligencia fejlesztése és alkalmazása. Segítségével olyan feladatok valósíthatók meg, amelyek korábban nem. Ilyen például a kép-és beszéd felismerés. A lehetséges alkalmazások listája folyamatosan bővül, radaros területeken is egyre nagyobb számban alkalmazzák, egyre több tanulmány születik a témában. Olyan részletek elemezhetők vele, amik egy ember számára vizuálisan nem. Több paramétert mérlegelve gyorsan és egyre jobb valószínűséggel történik helyes céltárgy klasszifikáció.

4.1 A mesterséges intelligencia alapja és tanulási technikáinak típusai

A mesterséges intelligencia jelentése, az évek során jelentős változáson ment keresztül. Mivel maga a fogalom nem jól definiált, egy egyszerűbb neurális hálótól a mesterségesen létrehozott tudatig bármire használható. A modern szakirodalom gépi tanulást felhasználó algoritmusok összességét érti mesterséges intelligencia alatt. [11]

A gépi tanulás nagyon sok algoritmust foglal magában. A tanulás úgy történik, hogy egy rendelkezésre álló adathalmazból épít fel a program valami olyan tudást, egy rendszert, egy döntési fát, tehát egy modellt, amit fel tud használni az adott probléma megoldására. Emellett új bejövő adatokról tud következtetéseket levonni, vagy magát az adathalmazt tudja új szemszögből elemezni. Mindenképpen szükség van mérésekre, adatokra, ami alapján a mesterséges intelligencia összefüggőségeket és különbségeket találhat. A szükséges adat mennyiségi és minőségi feltételei természetesen drasztikusan változnak az egyes algoritmusok között. [11]

Tanítás szempontjából négy különböző irányt különböztetünk meg. Ezek különböző mértékben igényelnek emberi felügyeletet, előre meghatározott döntési sémákat.

Az első bemutatott módszer a **felügyelt**. Ekkor előre meghatározzuk a helyes bemenet-kimenet kombinációkat. Az algoritmus feladata, hogy találjon egy függvényt, ami később új adatokra is alkalmazható lesz. Tipikusan klasszifikációs feladatokra alkalmazzák, ahol a lehetőségek száma korlátolt. Ha folytonos paramétereket szeretnénk

mérni, akkor regresszióknak nevezzük a folyamatot, mikor a végpontok között egy függvénykapcsolatot teremtünk.

Ezzel szemben a **nem felügyelt** módszer esetében nem határozunk meg előre helyes kimeneteket, az algoritmusra bízunk, hogy több rétegben elemezze az adathalmazt. Csoportokba rendezi a halmazt, mélyebb összefüggéseket, trendeket keres az intelligencia.

Előbbi kettő módszer keveréke a **fél felügyelt** tanulás. Érdekes ezt a módszert alkalmazni, kevés rendelkezésre álló adat esetén. Jobb eredményt érhetünk el ekkor, mintha csak a megkötött párokhoz ragaszkodnánk. Előszeretettel használják ezt a metódust szöveg felismerésre, fordításra vagy különböző csalások észrevételére.

A **megerősítő** módszer nem adatokat használ a tanításra. Folyamatos visszajelzésre van szüksége az algoritmusnak a környezettől, hogy tudja mi a helyes. A fejlesztő jutalmazza vagy bünteti a döntést, így javítja teljesítményt. Nagyon hasznos tud lenni komplex rendszerek fejlesztésénél, ahol lehetőség van a megfelelő környezet kialakítására, ilyenek az önvezető autós rendszerek, robotika vagy logisztika. [11]

Tehát a tanulási módszereknek alapvetően három közös célja van: a klasszifikáció, a regresszió és a dimenzió csökkentés, jellemző tanulás (feature learning).

4.2 Felhasznált algoritmusok

A **Lineáris Regresszió** a legegyszerűbb matematikai modell. Ez lényegében egy egyenest illeszt pontokra. 2D esetben egyszerűen leírható $y = ax + b$ képlettel, ahol x a bemeneti paramétereket jelöli, y pedig a keresett értéket. Az algoritmus optimalizálja a és b értékeit. Ugyan így alkalmazható több dimenziós esetben is.

Nagyon elterjedt és egyszerű módszer továbbá a **Support Vector Machine** (SVM) algoritmus. Bináris klasszifikációra a legtöbbet használt eljárás. A lényege, hogy egy vagy több olyan hipersíkot határoz meg az adatpontokat tartalmazó sokdimenziós térben, ami a lehető legtávolabb van a két kategória pontjaitól. A sík távolsága egy kategóriától az adott kategória legközelebbi pontjának távolságával. Ennek maximalizálása a cél. [11]

Másik egyszerű séma a **döntési fa** (decision tree) felépítése. Ez egy bináris fa, „ha-akkor” kapcsolatokkal. Ez egy felügyelt tanítási módszer, klasszifikációra és regresszióra is használható. Korlátozni kell esetekként a fa mélységét, mert előfordulhat

a túltanulás állapota, ami miatt az ismert adathalmazt túl mélyre menő részletekig elemzi és ezek a szempontok nem lesznek előnyösek, mikor új adat érkezik.

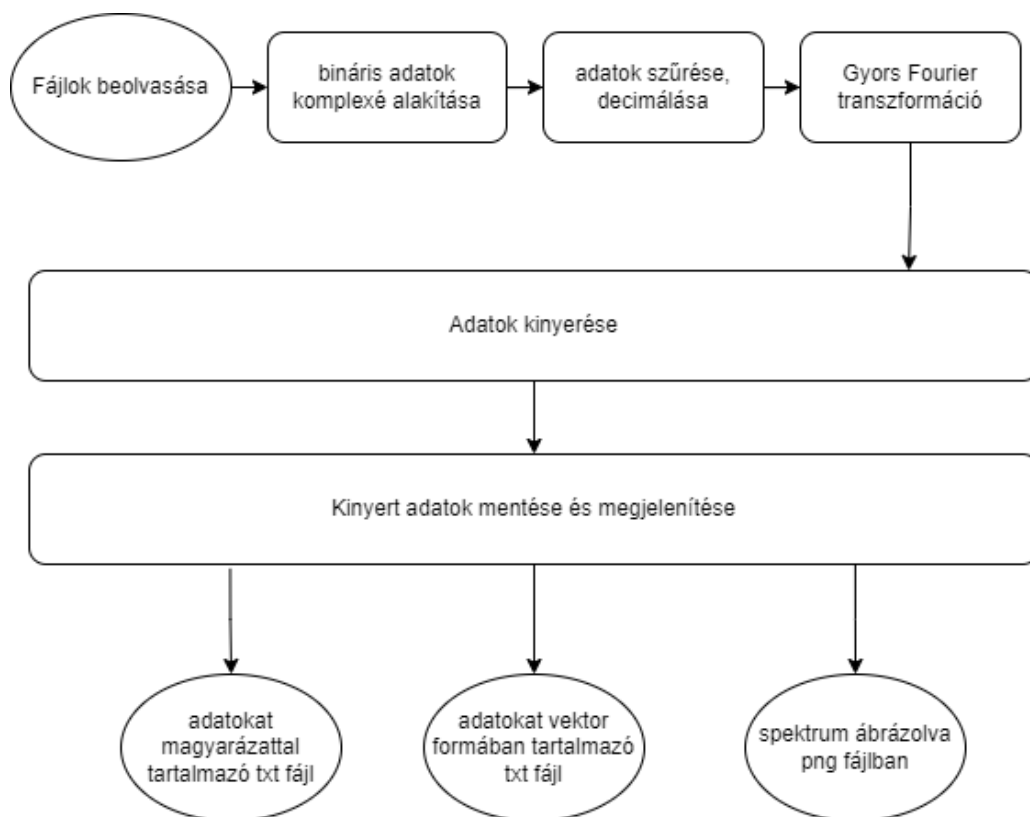
A **mesterséges neurális hálózatok** (Artificial Neural Network - ANN) az emberi agy működésének mintájára épülnek fel. Egyik alap építőeleme a neuron. A bemeneti értékeket súlyozottan összegzi aztán egy nemlineáris függvényvel alakítja át kimeneti értéké. Három fő rétegből épül fel ez a hálózat, ezek a bemeneti, rejtett és kimeneti rétegek. Változó számú neuront tartalmazhatnak a rétegek, és akár több rejtett réteget is. Ahol több mint 1 rejtett réteg van, azt nevezzük mély tanulós hálónak. A kimeneti neuronok száma a meghatározandó paraméterek számával egyenlő. Alapvetően minden szomszédos réteg összes neuronja között összeköttetés van, ami általában egyirányú. Back propagation módszerrel tanítható, ami a kimenetektől visszafelé indulva történik és a súlyozás mértékét optimalizálják. Ez egy nagyon számításigényes feladat.

Végül a **K-legközelebbi-szomszéd** algoritmusra (K-Nearest Neighbors K-NN) is szeretnék kitérni. A lényege, hogy egy ismeretlen adat érkezésekor veszi annak K db legközelebbi szomszédját. [11] Számos metrika alkalmazható, többféle geometriai elrendezés és halmaz a kategóriák között. Megadjuk, hogy mekkora halmazban vizsgálja meg a szomszédokat az azonosítandó adat környezetében. Az algoritmus azzal a kategóriával azonosítja, amelyből a legtöbb található a szomszédok között. Az eredmény nagyban függ a halmaz méretének megválasztásától.

5 Spektrum elemzési algoritmus

Ahhoz, hogy osztályozni tudjunk céltárgyakat, rendszerezett, feldolgozott adatokra lesz szükségünk. A vett spektrum nem minden komponense hordoz magában érdemi információt. Egy bizonyos amplitúdó szint alatt nem is érdemes elemezni, a tüskéket és azok egymáshoz viszonyított arányát lesz célszerű vizsgálni.

Írtam egy programot python nyelven, ami képes a nyers fájlokat beolvasni és kimeneteként kilistázni az általam érdekesnek vélt paramétereket. Persze ezen paraméterek listája bővíthető. Mindemellett képes kép formájában is ábrázolni a jel spektrumát. Az eredményeket külön txt fájlba és png formátumban is elmenti, a későbbi egyszerűbb visszakövethetőség érdekében. Két txt fájlt generálok, az egyiket embereknek értelmezhető formában, ahol szöveges magyarázatokat is fűzök a paraméterekhez. A másik fájl sortörésekkel elválasztva tartalmazza a számszerű karakterisztikus adatokat, mint egy vektor. Utóbbi formátumot kifejezetten a mesterséges intelligencia tanítására szánom.



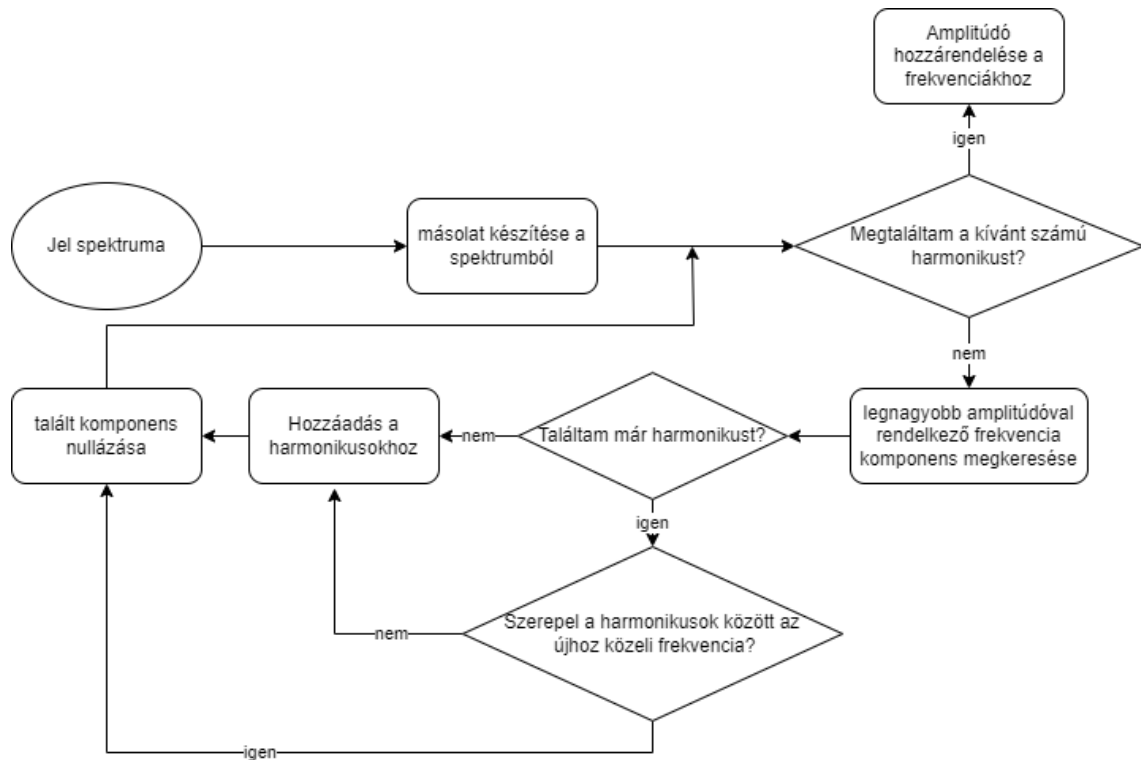
9. ábra: A karakterisztika elemző kód folyamatábrája

A bináris fájlokat beolvasom és rögtön komplexé alakítom. Ez a lépés elengedhetetlen a további vizsgálatokhoz, ugyanis, ha kihagynám, akkor egy szimmetrikus spektrumot kapnék, ami nem írná le helyesen a céltárgy mikro-Doppler jelenségeit. Ablak függvényt alkalmazok a jelen, aluláteresztőn szűröm és decimálom, ezt követően a gyors Fourier transzformálom. Az ablakméret paraméterrel megadható.

Gyakorlatban a céltárgytól nem várható el, hogy mindig ugyanakkora távolságban és szögben legyen a radarhoz képest. Az egyértelmű, ha közelebb van, több rádióhullámot ver vissza, ha hosszabb, akkor is, valamint az anyag minőségéből adódóan is lesznek különbségek. Viszont, ha csak az alapján próbálnánk következtetni, hogy melyik objektum visszavert energiája nagyobb, könnyen tévedhetnénk. Előfordulhat, hogy egy közelebbi, de kisebb reflexiós képességű propeller több energiát reflektál a radar szerint, mint egy távolabbi, ám ha egyforma távolságból néznénk, nagyobb reflexiójú. Ezen tények okán normalizálom a spektrumot a legnagyobb komponenshez mérve. Tehát minden frekvencia komponens amplitúdója 0 és 1 közé esik.

A méréshez minden esetben adódik zaj, ennek egy fajtája a Gauss-féle fehér zaj. Mivel ennek amplitúdója jelentősen kisebb, mint a jelé, ezért úgy eliminálom, hogy ami nem éri el a normalizált spektrum maximális amplitúdójának 5%-át, azt nullával teszem egyenlővé. Az így kapott spektrum tisztább lesz, vonalas jellegű. A zajszűrés szintje paraméteresen állítható, az 5%-ot tapasztalati úton választottam meg.

A spektrumban fellelhető tüskék várhatóan a forgási frekvencia többszörösei lesznek. Ezek a harmonikusok, amiket úgy keresek meg, hogy első lépésben lemásolom a spektrumot. A másolatban megkeresem a legnagyobb értékű komponenset. Megjegyzem az ehhez tartozó frekvenciát és nullázom a korábbi maximumot. Így következő iterációban a második legnagyobb csúcsot fogja megtalálni, és így tovább. Azonban ügyelni kell arra, hogy a csúcs melletti adatpontok is közelíteni fogják a csúcsot, nem pontosan túske szerű a spektrum. Ehhez beépítettem egy hibakezelést, ami nem veszi figyelembe a csúcs környezetét. A ciklus addig fut, amíg a kívánt számú harmonikust megtalálta. Ezután az eredeti spektrumban, ami a másolásnak köszönhetően nem változott, megkeresem a harmonikus frekvenciákhoz tartozó amplitúdó értékeket.



10. ábra: Harmonikusok megkeresésének folyamatábrája

Érdeemes még megvizsgálni, hogy pozitív és negatív Doppler frekvenciákon, hogy alakul az amplitúdó, azaz mennyi energiát hordoz a jel. Ezt ezen komponensek integrálásával számolom ki és vetem össze. Emellett a teljes spektrum energiáját is eltárolom.

Gyakorlatilag elég csak a spektrum azon részét ábrázolni, ahol megtalálható az első adott számú harmonikus. Egyébként egy szemmel nehezen kiértékelhető ábrát kapnék, ahol középen sűrűn szerepelnének a tüskék és a széleken, az ábra több mint felében csak zaj szerepelne. Az ábrázolási limitet javasolom a legnagyobb frekvenciájú számon tartott harmonikus másfélszeresére venni.

Végül a kapott eredményeket eltárolom fájlokban. A keletkező fájlok, a bemeneti fájl formátumhoz módosított nevét viselik. A kimenet alkalmas emberi és gépi feldolgozásra, értelmezhetőségre.

6 Az MI tanítása

6.1 Tanító adat formátuma

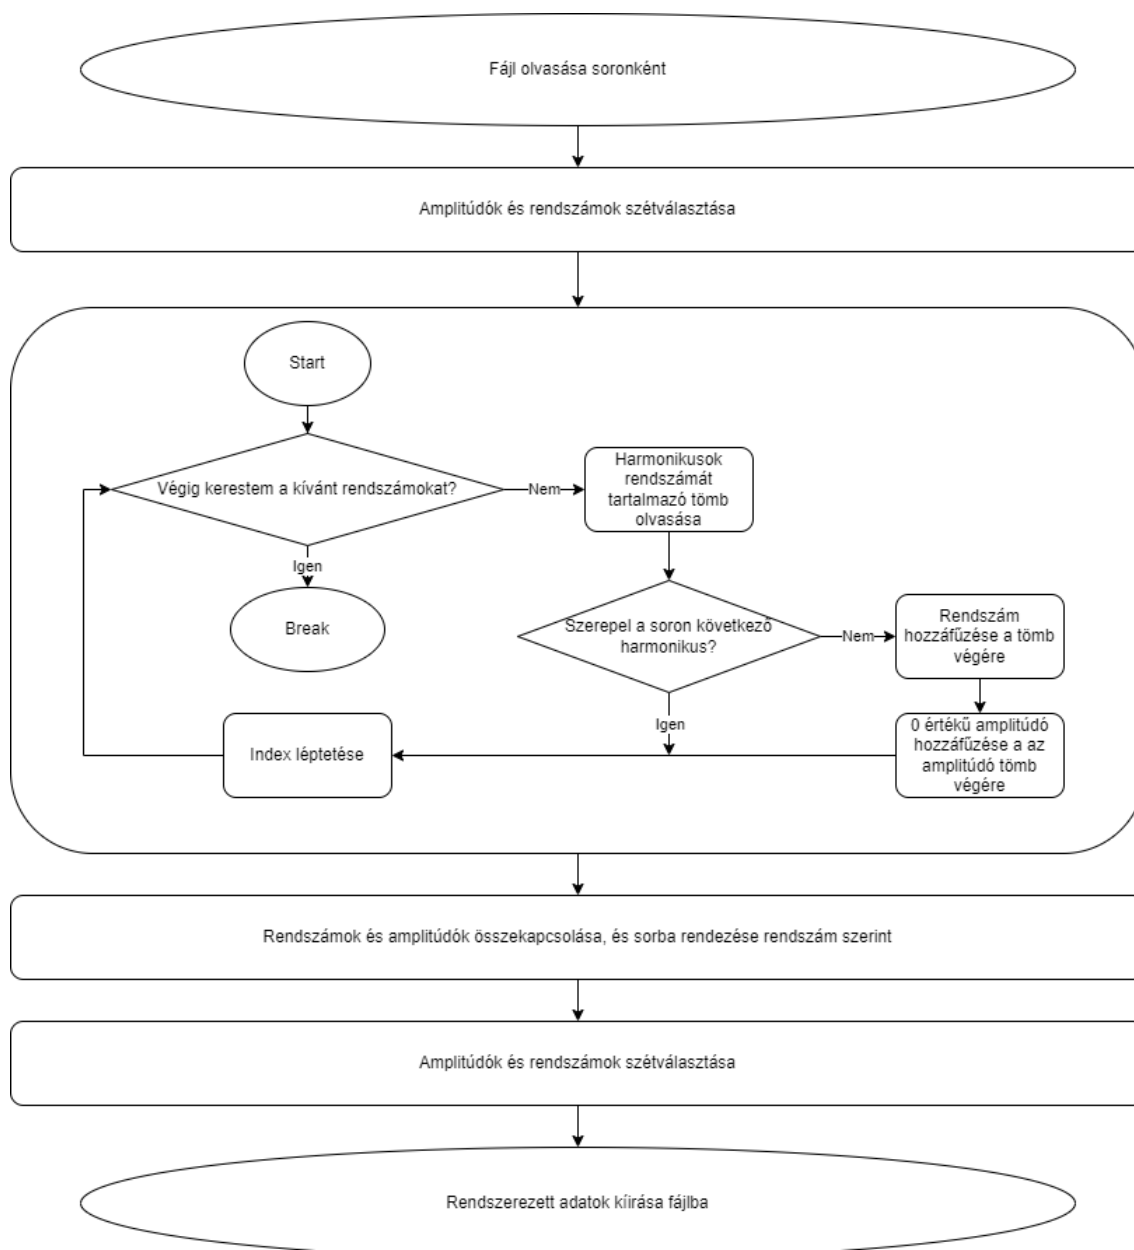
A gépi tanulás egyik, ha nem a legfontosabb feladata a tanító adatok megfelelő formátumának kidolgozása. A gépnek szüksége van egy rendszerezett, előszűrt, felcímkézett adathalmazra, amire modelleket illeszthet. Ennek kiválasztását végzi a 5. fejezetben taglalt spektrum elemzési program. Ennek a programnak a kimenete rugalmasan változtatható a kutatási eredmények függvényében. Hogy egységes formátumra alakítsam az előző program kimenetét, külön erre a célra létre hoztam egy adat formázó programot.

Ez a program egy egységes formátummá alakítja a beérkező adatokat, tulajdonképpen egy táblázatot tölt ki a megfelelő adatokkal. Ehhez szükséges egy protokoll, ami kellő rugalmasságot és konzisztenciát biztosít a két program között. Ez a következő szabályokat jelenti. A spektrum karakterisztikus tulajdonságait leíró vektor pontosan egy sorba kerül. A sor eleje szögletes zárójelek között tartalmaz két összekapcsolt listát. Ebben a párok első tagja a harmonikus számát, a második az amplitúdóját jelenti. Ezután következik a fordulatszám és a többi adat vesszővel elválasztva. Azaz a végére olyan paraméterek kerülnek, amit nem a spektrumból számol ki az elemző program, hanem amik a mérés során, mint külső paraméter ismertek, ezek meghatározása a feladat az MI számára. Ezek közé tartozik például a propeller anyaga.

Későbbiekben taglalt megfigyelés alapján, a fordulatszám változása nem befolyásolja jelentős mértékben a spektrumot. Így a forgási frekvenciával normálhatom a csúcsok helyének frekvencia értékét. Tehát lehetőségem van a forgási frekvencia harmonikusait összevetni. Azaz összemérhetem egy 20 Hz-es szénszállas propeller paramétereit egy 30 Hz-en forgó műanyagéval.

Mivel nem minden harmonikus jelenik meg minden spektrumban és ez mérésenként eltérő, ki kell egészítenem a hiányzó harmonikusok helyét 0-val. Egy táblázatot töltök ki, amiben -10. és +10. közötti egész harmonikusok szerepelnek, illetve a 0,5., ami a forgási frekvencia fele, ha esetleg megjelenik.

A program létrehozza kimenete gyanánt ezt a táblázatot, ami teljesen egységes, alkalmas arra, hogy egy mesterséges intelligenciát tanítsak vele.



11. ábra: Adatformázás folyamatára

6.2 AI tanítása felső szinten

Alkalmazott AI algoritmustól függetlenül van a gépi tanulásnak egy általános folyamata. A rendelkezésre álló rendezett adathalmazt első lépésben be kell olvasni egy megfelelő kezelhető formában. Ennek optimális módja a Pandas könyvtár használata. Ez egy adatbázis, táblázatkezelő bővítménye a Pythonnak, amit gyakorlatban elterjedten alkalmaznak. Tehát én is a könyvtár beépített függvényeit használom a kódomban.

Az adathalmaz szerkezete úgy épül fel, hogy az oszlopok jelentik az attribútumokat és a sorok az egyes eseteket. Az oszlopokra címkével lehet hivatkozni, szaknyelven az attribútumokkal. Nagy adathalmazok esetén érdemes a fontosnak vélt

oszlopokra korlátozni a táblázatot, a nem releváns adatokat ezzel el lehet hanyagolni gyorsítva és javítva a gépi tanulást.

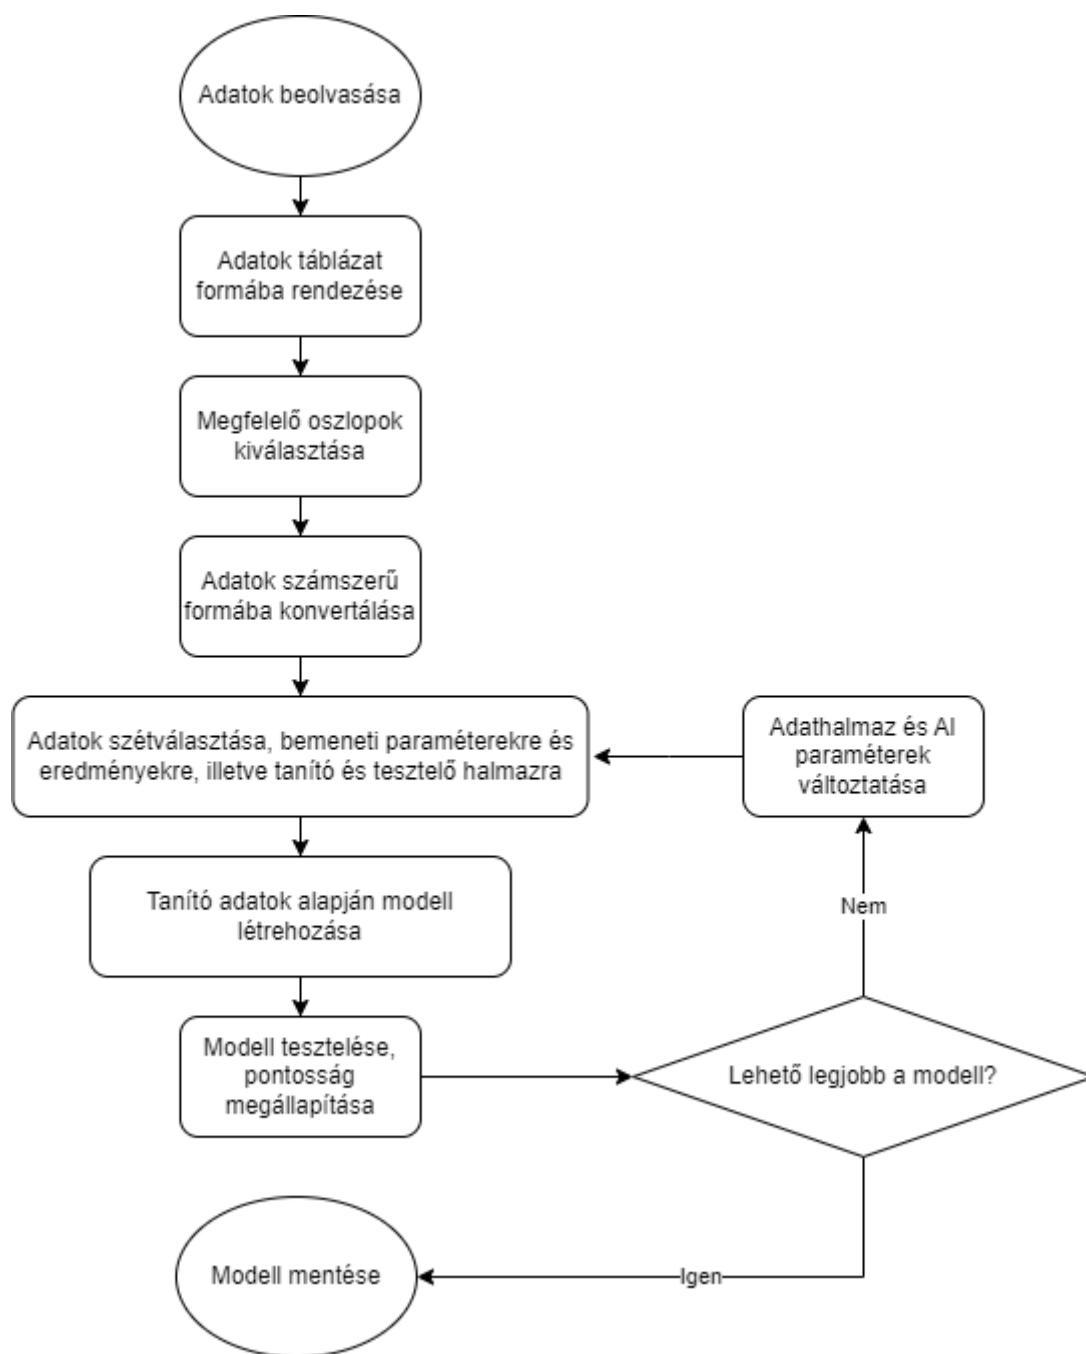
Fontos megjegyezni, hogy a gépi tanulási algoritmusok lényegében matematikai modellek, amik számokkal működnek. Ezért, ha az adatok között szerepel szöveg típusú, azt mindenképpen helyettesíteni kell számokkal. Ez megvalósítható egy egyszerű kézzel írt függvénnyel, ami egyszerű, ha jól ismerjük és átlátjuk az adathalmazt. Egyébként használható erre egy előre definiált függvény, ami automatikusan elvégzi ezt az átalakítást.

Az adatokat szét kell választani tanító és tesztelendő halmazra. Ez random választással megtehető, amennyiben egyforma jelentőséget szentelünk minden adatnak. Általában 80-90% szokott lenni a tanító adat aránya a teljeshez képest, a maradék adat pedig a teszt adat.

Mint egy függvényt érdemes elképzelni az adathalmazt, ezért X és Y vektorokra bonthatjuk szét a becsléshez használt paramétereket és a keresett értéket. 2D esetben keressük azt az $f(x)$ függvényt, ami a legjobb közelítéssel X helyén Y -t adja. Gyakorlatban ez a folyamat a sok bemeneti paraméter miatt egy több dimenziós probléma.

Felső szinten nézve a tanítás úgy történik, hogy egy fekete dobozba betápláljuk a tanító adatokat és a kimeneten kapunk egy függvényt, ami várhatóan jó becslést ad a legtöbb esetben. Nevezhetjük ezt a probléma modelljének. Ezt a modellt összehasonlíthatjuk a valósággal. A tesztalazzal a tanulás során nem találkozunk a modellt, csak a tesztelés során, vagyis független eredménynek tekinthető. A modell kiszámítja Y értékét a bemenetek alapján, amit ellenőrizhetünk a valós megoldással. A találati arányt százalékban szokás megnevezni.

Lehetséges, hogy ha többször elvégezzük a tanítást más eredményeket kapunk. Ez azért van így, mert más adatokon tanult a gép, a teszt adatok éppen jobban vagy kevésbé illeszkedtek a modellbe. Az algoritmusok rendelkezhetnek változtatható paraméterekkel, mint például K legközelebbi szomszéd esetén, mekkorára válasszuk K -t, vagy mekkora határt hagyjunk egy SVM számára. Az elméletileg legjobb modellt érdemes elmenteni és újabb példákon is tesztelni.



12. ábra: AI tanítás folyamata

6.3 Az AI használata anyag klasszifikációra

Az előbb leírtaknak megfelelően generáltam egy frekvencia független adathalmazt. Ez több, mint 100 mérés eredményeit tartalmazta. A célom az volt, hogy kiderítsem talál-e valamelyik alapvető algoritmus összefüggéseket az anyagra jellemzően. Azt az eredményt kaptam, hogy sem a lineáris regresszió, sem az SVM vagy a K-legközelebbi szomszéd algoritmus nem talált egyértelmű összefüggést. A találati arányok 50-60% valószínűség körül ingadoztak. Ennek oka lehet, hogy a mérések nem

pontosan ugyanabban a beállításban történtek. A centiméter nagyságú elmozdulás erősebb változást okoz a spektrumban, mint ami az anyag tulajdonságára jellemző. Erre a jelenségre a mérések és megfigyelések fejezetben még kitérek. Ennek a hibának a megoldására két út lehetséges. Elfogadjuk, hogy egy laboratóriumi mérési elrendezésben keletkezett adatokon tanítjuk az AI. Ebben az esetben megtanulhat különbséget tenni. Azonban a mérés nehezen lesz megismételhető és új esetben ez a megoldás nem fog működni. A másik út, hogy több paramétert jegyünk fel a mérés során, nagy precizitással meghatározva a propeller radarral mért koordinátáit. Ez egy több ezres nagyságrendű adatbázis létrehozását veheti igénybe, hiszen a koordináták térbeli volta miatt hatványozott lehetőség áll rendelkezésre, mindemellett ezeket meg kell ismételni a különböző anyagból készült propellerekkel. Ennyi adat feldolgozásához nagy erőforrásokra van szükség mind emberileg, mind számítási oldalról.

Más megközelítésből alkalmas lehetne az AI például fordulatszám becslésére. Ez ugyan megtehető determinisztikus módon, ahogyan arra nyújtok későbbiekben lehetőséget, de a példa kedvéért bemutatom pár algoritmus hatékonyságát erre a feladatra.


6.4 Fordulatszám meghatározás mesterséges intelligenciával

Egy új probléma megoldása, más megközelítési módszert és eszközöket igényel. Az előző feladatban az adatokat frekvenciafüggetlenné tettem és csak az amplitúdóval foglalkoztam. A döntési lehetőség bináris volt, a megoldás csak szén vagy műanyag lehetett. A fordulatszám meghatározása nem bináris feladat, az eredmény a pozitív racionális számok halmazán elméletileg bármi lehet. Az adathalmaz mindenképpen magában kell foglalja a csúcsok helyét Hz-ben, ez szükséges feltétele az elemzésnek.

A regressziós folyamat során a problémát csak a harmonikusok frekvenciájára szűkítettem, az amplitúdókkal nem foglalkoztam. Az adatok előkészítését végző program tehát kiválogatta az első 12 legmagasabb csúcsához tartozó frekvenciát és ezt közölte a kimeneten. Ehhez hozzáfűztem utolsó oszlopban a valódi frekvenciát. 152 mérést dolgoztam fel ilyen módon és hoztam létre ezekhez a regressziós adatvektort.


Lineáris regressziós algoritmussal elemeztem ki elsőnek az adathalmazt. A frekvenciák ekkor amplitúdó szerint csökkenő sorrendben követték egymást. Ebben a sorrendben a pontok nem illeszkednek egy egyenesre, a becslés nem működött eredményesen. Átdolgoztam az adathalmazt és növekvő sorrendbe rendeztem a

frekvenciákat. Így az egymást követő pontok nagyjából egy egyenesre estek, amire már alkalmazható lehet a lineáris regressziós eljárás nagyobb sikerrel.



13. ábra: Egy mérés spektrumának csúscsaihoz tartozó frekvenciák növekvő sorrendben

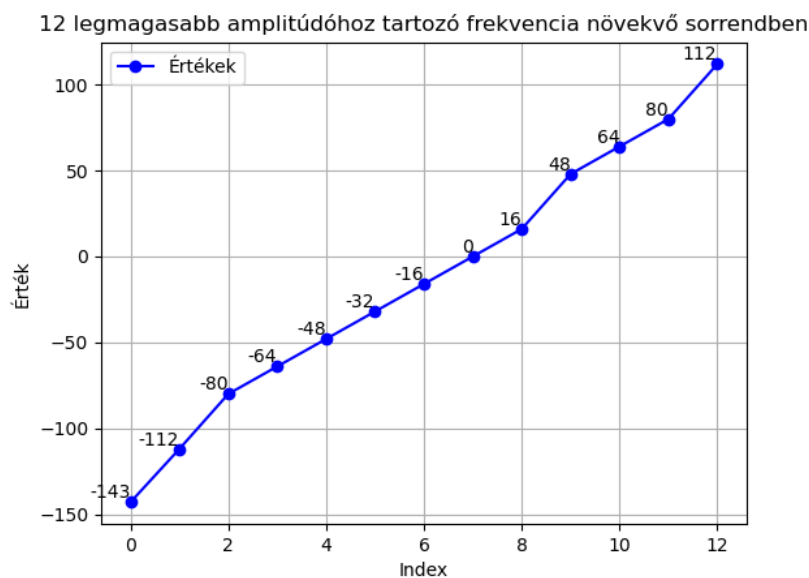
A lineáris regresszió egy $y = ax + b$ feladatot old meg egyszerűen megfogalmazva, azaz ehhez a modellhez egy ilyen jellegű adatvektor való. A forgási frekvencia a meredekséggel van összefüggésben. Az algoritmus által becsült számot egészre kerekítettem és összehasonlítottam hány Hz fordulatszámmal tér el a valós eredményektől.



14. ábra: eltérés a valós frekvenciától lineáris regressziós algoritmussal

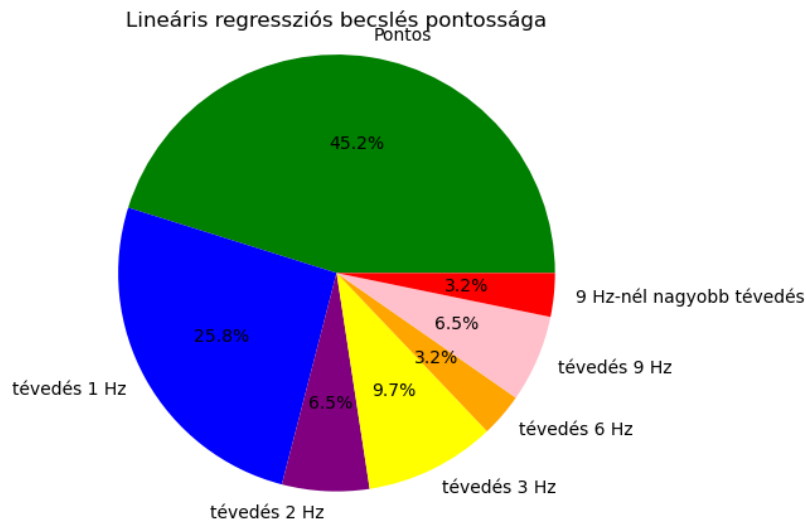
Látható, hogy az esetek 87%-ban a tesztalmazon 5 Hz pontosságon belül becsült az AI, és 77%-ban 3 Hz-en belül. A tesztadatok a teljes adatbázis egy ötödét tették ki a tanító adatokkal szemben. A sikeresség függ a tanító adatok és a tesztadatok elosztásától, a tanítási folyamatot többször megismételve a legjobb modellt érdemes megtartani.

Mivel az adatok előkészítése során, csak a csúcsokat jegyeztem fel, a 0 Hz-es komponens nem került rögzítésre. Azaz a negatív és pozitív oldali első harmonikus között kétszer akkora ugrás lesz, mint a legtöbb egymást követő szám között. Hozzáadtam ezt az értéket az adatvektoromhoz, így lineárisabb függvényt kaptam.



15. ábra: Egy mérés spektrumának csúcsaihoz tartozó frekvenciák növekvő sorrendben a 0 Hz komponenssel kiegészítve


Elvárásaimnak megfelelően ez a lépés az előfeldolgozás során hozzájárult a becslés javításához. A pontos becslés valószínűsége a 7-szeresére nőtt, 3 Hz-en belüli pontosság valószínűsége pedig 87%-ra javult. Előfordultak nagyobb tévedések továbbra is ugyan, tehát a modell nem hibátlan.



16. ábra: Eltérés a valós frekvenciától lineáris regressziós algoritmussal – az adatvektor tartalmazza a 0 Hz frekvenciát


A lineáris regressziós becslés alkalmas lehet a probléma megoldására, jó valószínűséggel megtalálja a forgási frekvenciát. Amennyiben nem törekszünk tökéletesen pontos becslésre, hanem elfogadunk egy hibahatárt, a gyakorlatban egy jól alkalmazható eljárás lehet.

Azonnali becsléseket is meglehet valósítani vele. A radar felveszi a céltárgy spektrumát egy rövid időintervallumban. Ebből az előfeldolgozó program előállítja az adatvektort és átadja a betanított algoritmusnak, ami elvégzi a predikciót.



17. ábra: Fordulatszám becslés automatizálásának folyamata

Példaképpen teszteltem milyen eredményekkel jár, ha ezt az adathalmazt egy SVM típusú algoritmussal teszteltem. Ekkor az eredmények szélsőségesebbek lettek, vagy jó pontossággal eltalálta a megoldást vagy sokkal nagyobbat tévedett a modell. 20 Hz tévedés is előfordult ezzel a módszerrel, ami már a valós frekvencia kétszerese is könnyen lehet. A pontos becslés valószínűsége vetekszik a lineáris modellel, viszont a 3-5 Hz-en belüli pontosság kevésbé tartható.

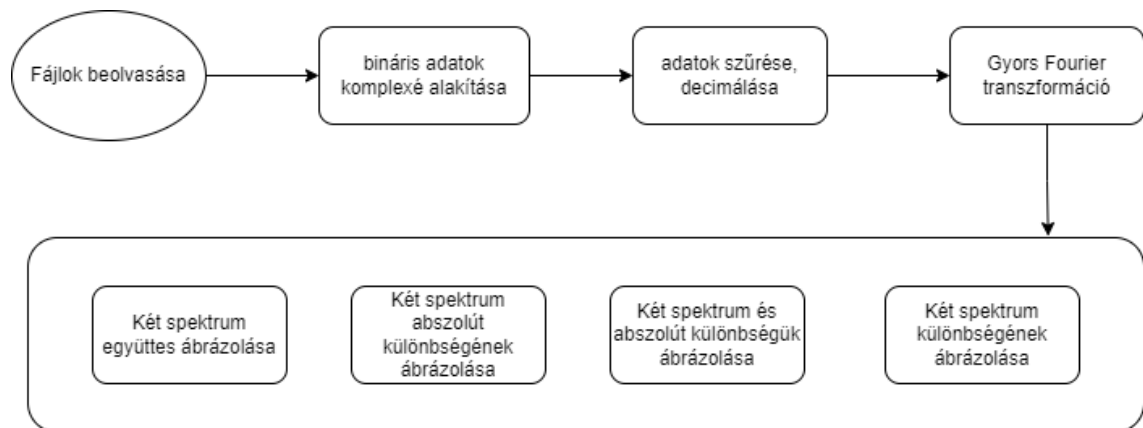


18. ábra: Eltérés a valós frekvenciától SVM algoritmussal

7 Mérések és megfigyelések


7.1 Szénszállas és műanyag propeller összehasonlítása

Az adatok feldolgozásához írtam egy kódot Pythonban, ami a bináris adatokat dolgozza fel, komplex számokká alakítja, szűri, gyors Fourier transzformálja és ábrázolja. Egyszerre két spektrum ábrázolása is lehetséges a könnyebb összehasonlíthatóság végett.




19. ábra: Összehasonlító kód folyamatábrája

A spektrum számítása az 5. fejezetben bemutatott módon történik, azzal a bővítéssel, hogy a program két fájlra is elvégzi a szűrési és transzformálási lépéseket. Az ábrázolásra többféle lehetőséget is implementáltam, hogy minél szemléletesebb legyen.




20. ábra: Szén és műanyag propeller egyszerre ábrázolva

A spektrum egyensúlya a pozitív komponensek felé tolódott mind a két céltárgy esetén. Azonban szénszállas esetén sokkal hangsúlyosabb az első harmonikus, mint a többi. Műanyag propellernél a legnagyobb komponens a negyedik harmonikus, ezt követi a második és csak ezután jön az alapharmonikus. A spektruma a műanyagnak sokkal zajosabb, megjelennek a forgási frekvencia felének többszörösein is komponensek. Emellett sokkal lassabb a lecsengése pozitív oldalon. Az összes energia a komponenseket integrálva kétszer annyi műanyag, mint szénszállas esetén. Ábrázoltam az abszolút különbségét a két spektrumnak, amiből azt állapítottam meg, hogy pozitív frekvenciákon jelentősebb eltérés mutatkozik.



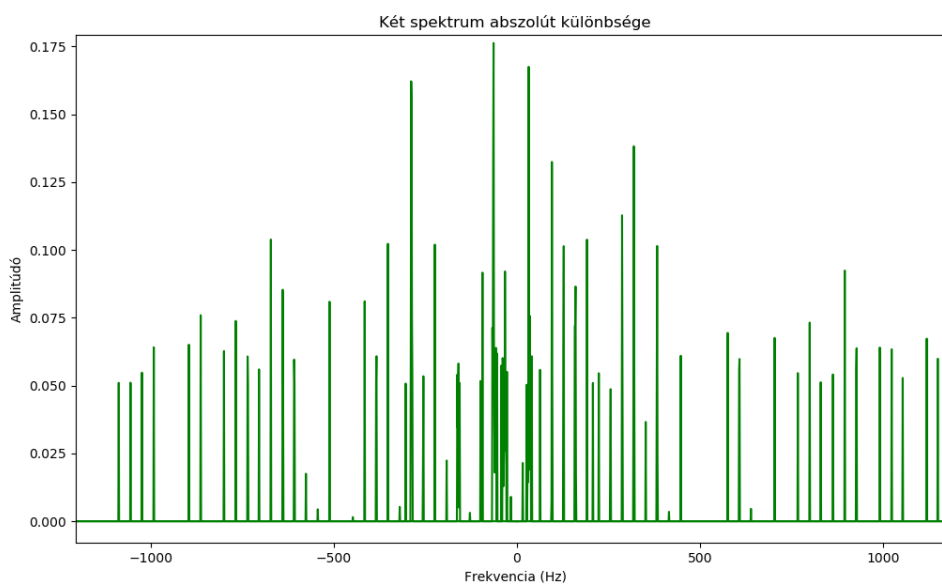
21. ábra: Szénszállas és műanyag spektrum abszolút különbsége

Ellenőriztem egy másik propeller párral is az eredményeket. A propellerek formája és mérete megváltozott az előző méréshez képest. A korábbi megfigyelések nem teljesültek maradéktalanul az új céltárgyakra.




22. ábra: Egy másik szénszállas-műanyag propellerpár spektruma

Ez a két spektrum sokkal jobban hasonlít, a műanyag esetén megszűnt a zajosság. Tehát az előző mérés zajossága a propeller formájának köszönhető, mintsem anyagának.



23. ábra: Egy másik szénszállas-műanyag propellerpár spektrumának abszolút különbsége



24. ábra: Szénszállas és műanyag harmonikusai

Külön-külön is ábrázoltam a spektrumokat, harmonikus tartalom szerint. Az 5. fejezetben taglalt kódom a legnagyobb frekvenciájú harmonikushoz igazítja az ábrázolási tartományt. Minden esetben ugyan annyi, első x számú legnagyobb, amplitúdójú komponenst jegyzem föl. Ha 10 csúcsot keresek meg, akkor a 10 fogja meghatározni az ábrázolási tartományt. Vagyis nem kizárt, hogy egyik esetben ez magasabb frekvencián fordul elő, mint máskor. Kiváló példa erre a 24. ábra. A műanyag spektrumának ábrázolásához sokkal szélesebb átfogás kellett, közel kétszer akkora. Észrevehető, hogy a köztes harmonikusokon kisebb amplitúdók fordulnak elő. A lecsengése tovább tart és némi hullámzást mutat.


7.2 Fordulatszám meghatározás

Az eredmények értelmezésének szempontjából fontos megjegyezni, hogy a méréseket két szárnyú propellerekkel végeztem. Tehát a radar szemszögéből nézve egy fordulat alatt kétszer következik be ugyan az a pozíció, vagyis kétszeres frekvenciát érzékel. Ezt a feldolgozás során figyelembe veszem, tehát az eredmények a tényleges fordulatszámot mutatják Hz-ben.

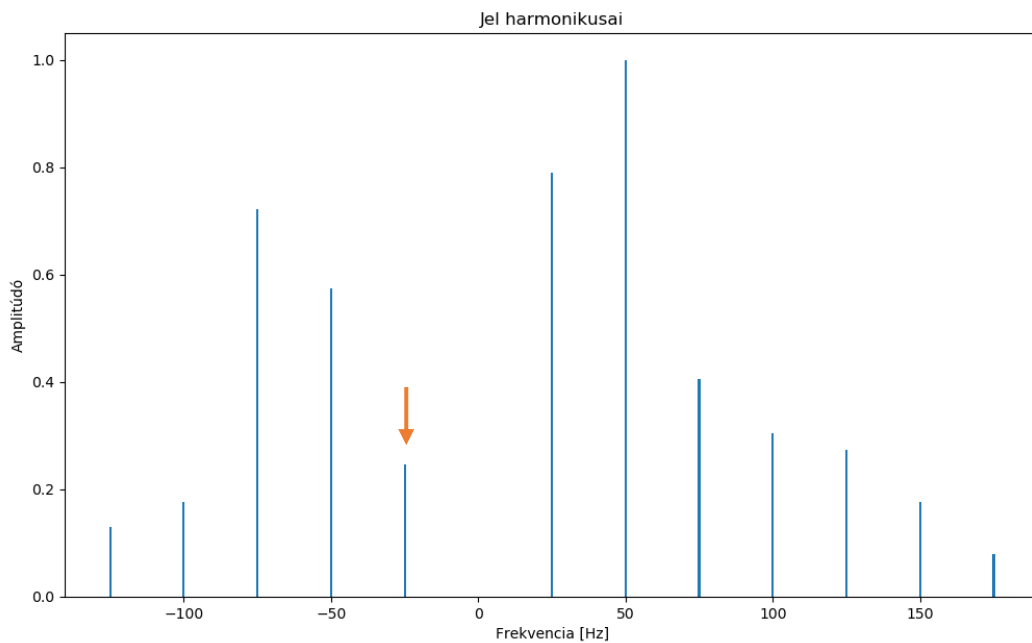
A frekvencia számítás meghatározásához sok mérést végeztem a laboratóriumban. Ezen mérések során a fordulatszámot, a propellerek típusát és az elhelyezkedést változtattam. Utóbbi minimális mértékben ugyan, mégis jelentős különbségeket tudott okozni a spektrumban.

Elméletben azt vártam, hogy a forgási frekvencia lesz a legkimagaslóbb túske a spektrumban. Ez a propeller geometriájától és forgásától függően a pozitív és a negatív tengelyen is előfordulhat. Az elmélet csak ideális esetben igaz. Ekkor a radar és a céltárgy

tökéletesen egy magasságban van, oldal irányban is a tengelyük egy vonalban van. Amint változás történik a maximum helye változik. Szinte minden esetben változott, és nem a forgási frekvencia lett a legdominánsabb komponens, hanem annak ± 2 - 3 -szorososa.




25. ábra: Ideális pozícióban mért propeller harmonikusai 25 Hz forgási frekvencia mellett



26. ábra: Ideálistól eltérő pozícióban mért propeller harmonikusai 25 Hz forgási frekvencián

Ennek a bizonytalanságnak a függvényében a maximális komponens helye alapján nem lehet érdemi becslést tenni. Következő feltevés az volt, hogy a -1-es tuskét, tehát a távolodó oldalon az első kimagasló frekvenciát veszem alapul. Ez a módszer az esetek körülbelül 90%-ában működött. Előfordult azonban, hogy megjelent egy túske ennek a frekvenciának a felénél is. Azaz a két szárny eltért, és külön érzékelt a Doppler radar az egyik forgását, ami a valódi forgási frekvencián történt. Az átalakításom miatt, azonban ez a forgási frekvencia fele, tehát az eredmény hamis lenne.

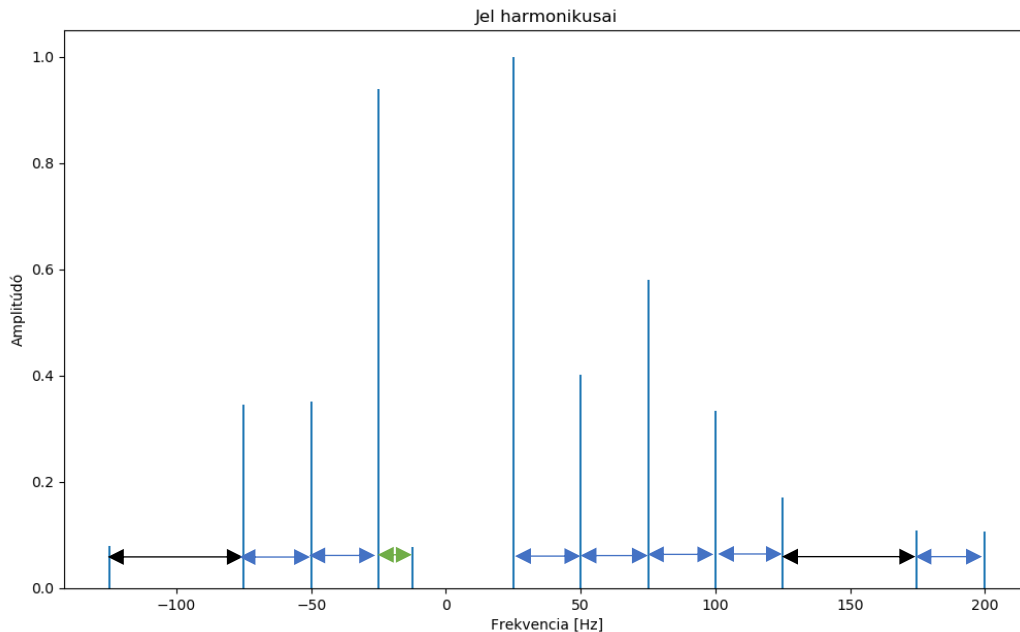


27. ábra: 25 Hz frekvenciával forgatott propeller harmonikusai

Ez a probléma felveti a kérdést, hogy érdemes-e összehasonlítani az első két túske nagyságát, illetve mi lehet az univerzális döntési határ. Ez egy túl komplikált és érzékeny módszer lenne, amiben megnőne a hiba valószínűsége. Ezért új megközelítést választottam.

Előbbi megközelítés helyett, amikor az amplitúdóból próbáltam következtetni, ezúttal a frekvenciákra, azon belül is az egymáshoz képesti különbségünkre koncentráltam. Ehhez frekvencia szerint növekvő sorrendbe rendeztem a kijelölt komponenseket, amik az első N csúcsot jelentik a spektrumban. Kerekítettem egész számra az értékeiket, majd feljegyeztem az egymás melletti frekvenciák különbségét. Megnéztem, mi volt az az eltérés, ami a leggyakrabban előfordult. Elméletem beigazolódott, ez nem volt más, mint a forgási frekvencia. Több mint ötven mérésen teszteltem az algoritmust, amik között előfordult olyan eset is, amikor a propeller

forgássíkját változtattam. Az összes esetben helyesen meghatározta a forgási frekvenciát a program.



28. ábra: Egymás melletti harmonikusok frekvenciakülönbségei


Az eredmény megbízhatósága miatt, ezt a paramétert alapvető karakterisztikus adatnak tekintem. Tehát a tanító vektor részének veszem a sorba rendezett csúcsok mellett.

7.3 Forgási frekvencia hatása


Vizsgálatom fő célja az volt, hogy kiderítsem milyen szinten befolyásolja a fordulatszám változása a spektrumot, illetve annak egyszerűsített, csak a harmonikusokat tartalmazó változatát. Ez fontos szempont, hiszen, ha befolyásolja, akkor nem lehet elkülöníteni ezt a paramétert a gépi tanítás során, ha pedig nem, akkor frekvencia függetlenül lehetséges bármilyen összehasonlítás.

A méréseket egymás után végeztem, a mérési elrendezés helyzetének változtatása nélkül egy egységben. 20 és 40 Hz között 5 Hz lépésközzel növelve rögzítettem felvételeket a propellerekről. A mérést megismételtem egy kis mértékben eltérő pozícióban is, ami pár centi elmozdítást jelent, hogy éppen ne legyen ideális helyen. Harmadjára pedig fordított irányítottágú propellerekkel is végeztem méréseket.

Minden esetben hasonló eredményt kaptam. Enyhe hatása van a forgási frekvencia változásának, növekedésével általánosan gyorsabban csökkennek a harmonikusok amplitúdói. Ez a változás azonban még nem rontja a karakterisztika hasonlóságát. Ha egy harmonikus nem jelenik meg, akkor az a frekvencia változtatásával sem fog. Fontos megjegyezni, hogy az első N legmagasabb harmonikust tekintem karakterisztikus adatnak. A többedik harmonikusok között egyre kisebb a különbség, így az utolsóként beválogatott harmonikusok félre vezetőek lehetnek, ha itt jelenik meg eltérés. Erre példa a 30. ábrán látható. A magyarázat, hogy ha eggyel több harmonikust vennék figyelembe, akkor nem lenne különbség. Mind a kettő szerepelne, minden frekvencián a képen. Viszont néhány spektrum esetén ezek a sokadik harmonikusok már zaj szinten szerepelnek, tehát nem érdemes N számot nagyra választani. Tapasztalataim szerint az első 10 harmonikus ideális választás.



29. ábra: Egy szénszállas propeller harmonikusai különböző frekvencián forgatva




30. ábra: Egy műanyag propeller harmonikusai különböző frekvencián forgatva

7.4 Helyfüggés

Különböző mérések ugyanarról a céltárgyról szemlátomást igen nagy szórást mutattak. A különbséget az előző fejezet eredményei alapján a frekvencia változtatása nem okozhatja, attól kvázi független.

Ebben a részben megvizsgálom, és szemléletes példákkal bemutatom, a céltárgy radarhoz viszonyított helye miképpen befolyásolja az eredményeket. Továbbra is a normált csúcsokat ábrázolom frekvencia függetlenül.


A mérést úgy állítottam össze, hogy a céltárgy a radar két antennájának középpontjához képest, ennek a két antenna síkjára merőleges vonalban és azonos szintben helyezkedjen el. Minden mérés során ellenőriztem, hogy a reflexió ne vigye telítésbe a rendszert. A céltárgyat, azaz a 30 Hz frekvenciával forgatott propellert 2 m távolság körül, 5 cm lépésközzel helyeztem mérésenként odébb. A kísérletet megismételtem oldal irányú helyváltoztatással is, szintén 5 cm lépésközzel. A méréshez szénszállas és műanyag propellert is használtam.



31. ábra: Műanyag propeller mikro-Doppler karakterisztikájának távolságfüggése

A31. ábra alapján megállapítható, hogy a rendszer nagyon érzékeny a távolságra. Annak változtatásával nem arányosan változnak az egyes komponensek, sem folyamatos csökkenés, vagy növekedés nem figyelhető meg. Például a maximális komponens helye sem állandó. Egyedül közös pont az összes spektrumban, hogy ugyan az a rendszámú, jelen esetben -5. komponens nem jelenik meg.

Szemléltetésképpen két 5 cm távolságra lévő karakterisztikus képet is bemutatok, amin jól látszik, hogy a változások nagyságrendje nem elhanyagolható. A céltárgy arrébb mozdításával egy-egy komponens a duplájára nőhet vagy a felére csökkenhet.



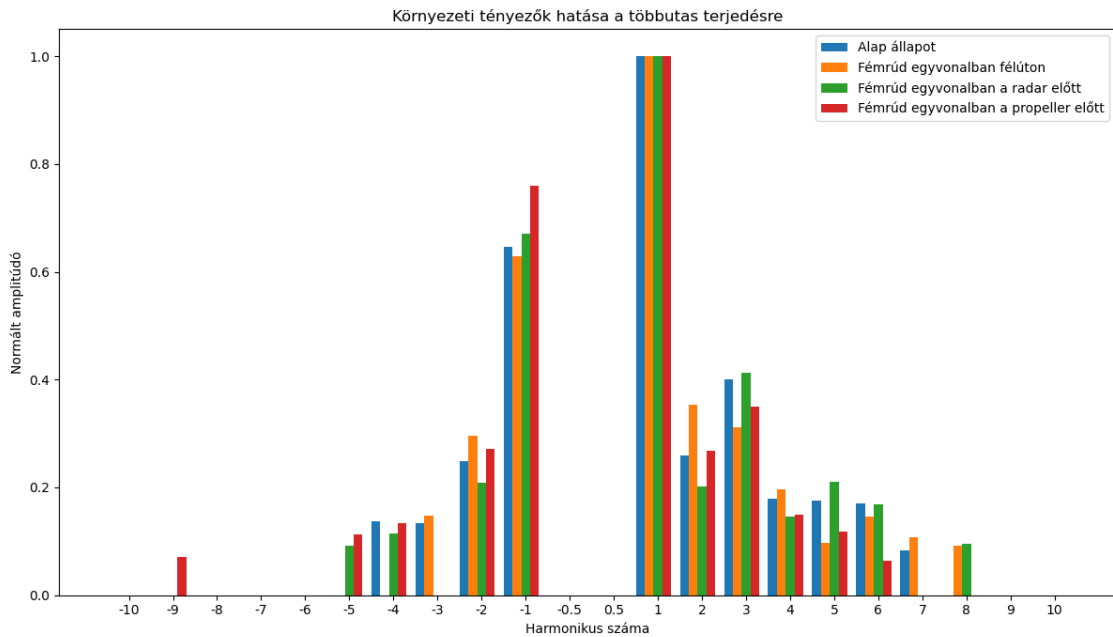
32. ábra: Szénszállás propeller mikro-Doppler karakterisztikájának távolságfüggése

Illetve a komponensek egymást követő menetében is történhet változás. Például a csúcsok menete 205 cm távolságban a következőképpen változott: -4 és -1 között fokozatosan növekedtek az amplitúdók. Míg 5 centiméterrel távolabbról mérve, ez nem igaz, a -3-as komponens alacsonyabb, mint a -4-es.

7.5 Környezeti tényezők hatása – többutas terjedés

A méréseket egy laboratóriumi szobában végeztem, ami nincsen reflexiómentesítve. A mérés célja az volt, hogy felmérjem a környezet megváltoztatása miképpen befolyásolja az eredményeket. A radar és a propeller közelében megváltoztattam néhány tárgy helyét és kiértékeltem a látottakat.


Elsődleges modellem egy fémrúd volt. Ez egy hengeres felület, jó reflexióval rendelkező felszínnel az anyagi tulajdonsága miatt. Elhelyeztem ezt a rudat félúton egy vonalban a radar és a propeller között, illetve egyszer a radarhoz, másodszor a propellerhez közelebb. A lényeg, hogy mindhárom esetben a közvetlen rálátást korlátozta.




33. ábra: Közvetlen rálátás korlátozása egy fémrúddal

Az útba helyezett fémrúd megváltoztatta pár százalékban a komponensek arányát. Ez a változás 10-20% alatti, pozitív és negatív irányban is történik. A maximális komponens helyét nem befolyásolta.

Ezután megfigyeltem, hogy ha a közvetlen rálátást nem rontja, de a közelben helyezkedik el, akkor okoz-e torzítást. A 34. ábra szerinti elrendezésben, az ott feltüntetett rálátási szögekben azt tapasztaltam, hogy ebben az esetben is történik némi változás a komponensek arányában. Távolabbra helyezve a rudat, annak hatása kevésbé érvényesült az alacsonyabb harmonikusokon.



34. ábra: Zavaró tárgy a mérési környezetben




35. ábra: Fémrúd közvetlen rálátásban és a közelben

Következőnek emberek hatását vizsgáltam, melynek eredményeképp kiderült, hogy az emberi test teljes mértékben árnyékolja a mérést, amennyiben az korlátozza a közvetlen rálátást. A spektrumon csak zaj volt ekkor látható. Ha egy ember a fenti fémrúddal végzett méréshez hasonlóan, nem közvetlenül a radar és a propeller előtt helyezkedik el, azzal enyhe mértékben befolyásolhatja a mérést.

Hasonló eredményeket produkált a sík fémtest és egy kis műanyag ventilátor is. Ezeket szintén oldaltérben vizsgáltam. Egyik eset sem befolyásolta olyan nagy mértékben a harmonikusok arányát, mint az előző fejezetben tárgyalt propeller helyzete, de megállapítható, hogy a többutas terjedésnek van hatása a spektrumra. Pár elem

megváltoztatása kis változásokat okoz, legfőképpen a közvetlen rálátási vonal közelében. A harmonikusok közül a -2 és 2-es számú a legérzékenyebb a környezetre megfigyeléseim alapján. A 36. ábra szerint egy sík fém felület orientációfüggően befolyásolhatja az eredményeket a legnagyobb mértékben. Tehát érdemes a közelből eltávolítani az ilyen tárgyakat.




36. ábra: Közelben elhelyezett zavarok hatása

7.6 Két propeller együttes spektruma

Miután az előző fejezetekben körül jártam, hogy egy propeller spektrumából milyen információkat lehet leszűrni, a következőkben azt vizsgálom, hogyan hat két propeller egymásra, milyen komponensek fognak feltűnni a spektrumban és miképp becsülhető a fordulatszáma külön a propellereknek. Mindezt különféle esetekben teszem, más elrendezéseket választva.

7.6.1 Egymás melletti elrendezésben




37. ábra: Két propeller egyidejű vizsgálata egymás melletti elrendezésben


A mérési elrendezésnél arra ügyeltem, hogy a lehető legszimmetrikusabb legyen, lehetőleg a radar egyforma szögben lássa mind a két propellert. Azonban itt meg kell jegyezni, hogy az erős irány és távolságfüggő tulajdonság miatt, tökéletesen nem igen lehet kiegyenlíteni. A radar ezúttal is azonos magasságban helyezkedett a propellerekkel.

Elsősorban két paraméter változtatásával vizsgáltam az előbb felvázolt rendszert. Eltérő fordulatszámokon forgattam a propellereket, és ezen fordulatszámok többszöröseit vártam a spektrumban. Olyan esetet is mértem, amikor az egyik propeller fordulatszáma a másik kétszerese. Ezt követően megváltoztattam az egyik motor forgásirányát egy fázisfordítással a rotor előtt. Így össze tudom hasonlítani, hogy látható-e, hogy azonos vagy ellentétes irányban forognak.

Elvárásaimnak megfelelően mind a két fordulatszám leolvasható a spektrumról. A radar a hozzá képest bal oldali propellert érzékelt intenzívebben, ezért mindig ennek a harmonikusai a dominánsabbak a spektrumban. Ezt szemlélteti a 38-39. ábra.




38. ábra: Bal oldal: 20 Hz, jobb oldal: 30 Hz



39. ábra: Bal oldal: 30 Hz, jobb oldal: 20 Hz


Megjegyezném, hogy az alsó ábrán nagyobb relatív különbség tapasztalható a harmonikusok között. A 30 Hz-es baloldali propeller lényegesen több jelet ver vissza, mint a lassabban forgó jobb oldali. Fordított esetben kisebb a különbség, az irányhatás dominál.



40. ábra: Egyforma frekvenciával forgó propellerek különböző és egyező irányban

A fázis fordítás után az egyforma sebességgel forgó propellerek spektruma úgy változott, mintha tükröztem volna a 0 tengelyre. 30 Hz-en forgattam mind a kettőt, ez tisztán látszik a spektrumon is.


7.6.2 Egymás takarásában




41. ábra: Két propeller egyidejű vizsgálata egymás mögötti elrendezésben

A méréshez úgy állítottam be a propellereket, hogy egy vonalba essenek a radar szimmetriatengelyével. A méréseket az előző pontban leírt szisztéma szerint végeztem.

Ebben az esetben is megjelenik a spektrumban mind a két propeller fordulatszáma és azok többszörösei. Annyiban különbözik viszont, hogy ezúttal minden esetben a nagyobb frekvenciával forgó komponens dominált a spektrumban, függetlenül attól, hogy az volt a közelebbi vagy a távolabbi. Ebből arra következtetek, hogy a távolságra kevésbé érzékeny a radar, mint az irányra. Illetve relatív több energiát ver vissza egy propeller, ha gyorsabban forog. A mérés folyamán a relatív különbséget körülbelül 10%-kal befolyásolta a távolság, de ennél sokkal erősebb hatása volt a frekvenciának, így mind a két ábrán a gyorsabb komponens a nagyobb.




42. ábra: Közeli: 20 Hz, távoli: 30 Hz



43. ábra: Közeli: 30 Hz, távoli: 20 Hz

Hogy egyforma vagy különböző irányban forogtak, az ebben az esetben a +1-es harmonikuson okozott számottevő különbséget, illetve az alacsonyabb rendszámú harmonikusokon. A -1-es harmonikus domináns mind a két esetben.



44. ábra: Két 30 Hz frekvenciával forgatott propeller spektruma azonos és különböző forgásirány mellett

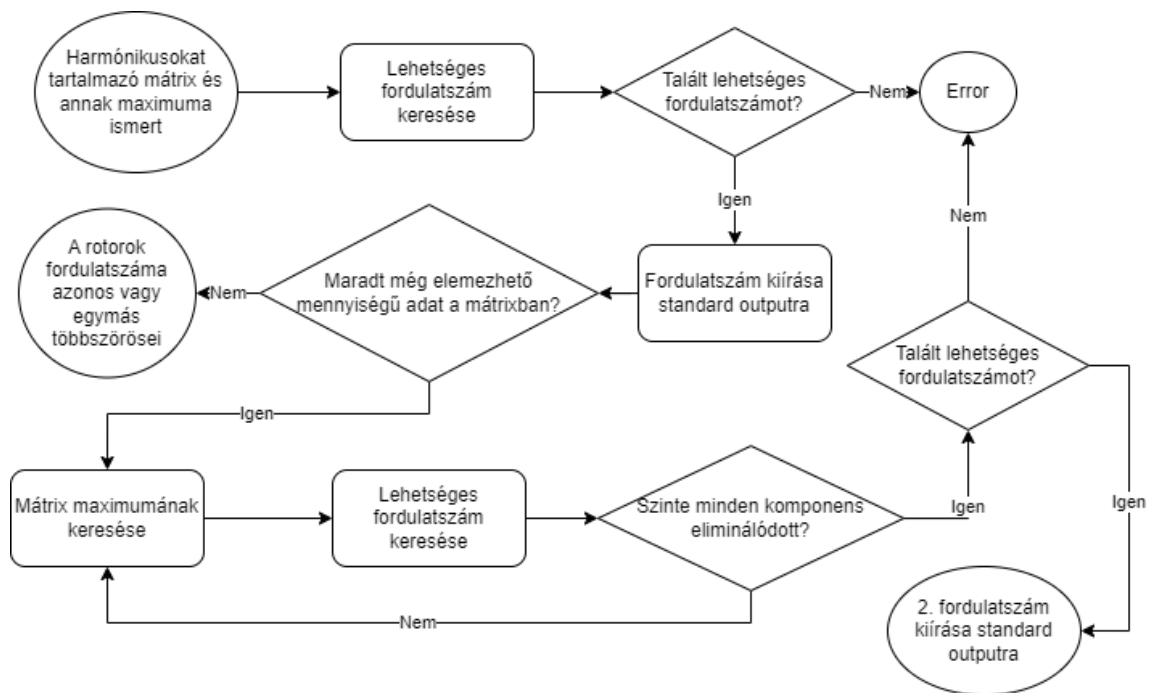
7.6.3 Két propeller fordulatszámának becslése

Az egypropeller példához hasonlóan ebben az esetben is a spektrum csúcaiból indulok ki, amikről feltételezem, hogy a fordulatszám harmonikusai. Viszont 2 propeller esetén nem használható a korábban használt módszer, mely szerint a frekvenciák közötti távolságot vizsgálom. Például, ha egy 20 és 30 Hz-es fordulatszámokkal rendelkező rendszert vizsgálok, akkor többek között a $\pm 20, 30, 40, 60, 80, 90 \dots$ Hz frekvenciákon várok csúcsokat. A komponensek távolsága ekkor 10-20 Hz. Ebből közvetlenül nem derül ki mind a kettő fordulatszám. A példába szerint a korábbi módszer kiválasztaná a 10 Hz-et, ami helytelen lenne. Ha lenne egy 20 és 40 Hz-es fordulatszám, akkor a különbségek 20-ra adódnának, nem látszana, hogy a másik frekvenciája több.

Az új algoritmus a maximumokból indul ki. Ebben előfordulhat hiba, hogy esetleg a maximum nem az első harmonikusra adódik, de némi körültekintéssel ezt ki lehet küszöbölni.

Tehát előre meg kell határozni egy spektrum csúcsait, azaz harmonikusait tartalmazó mátrixot. Ennek meg kell keresni a maximum amplitúdóval rendelkező komponensét és ennek a frekvenciáját feljegyezni. Ezzel érdemes lehet egyből normálni az amplitúdókat, de nem szükséges. A mátrix frekvencia paraméterét külön vektorba rendezem az egyszerűbb kezelhetőség miatt. Meghívom a fordulatszám kereső

függvényt, amely működését később részletezem. Ennek a kimenete vagy error vagy egy szám és egy mátrix lehet. Előbbi a becsült fordulatszám, a második az eredeti mátrix az első fordulatszám nélkül. Ezt a mátrixot ábrázolni is lehet, hogy meggyőződjünk a program helyes működéséről. Ha az elején nem talál semmit, akkor a mérés hibás lehetett, ilyen példa nem fordult elő méréseim során. Miután megtalálta az algoritmus az első fordulatszámot, ezt kijelzi a felhasználónak. Megvizsgálom, hogy a fordulatszám törlése után mennyi elem maradt a mátrixban. Abban az esetben, ha túl kevés, valószínű, hogy a két propeller fordulatszáma megegyezett vagy egymás többszöröse. Eközött nem lehet különbséget tenni. Csak akkor látszódná a különbség, ha először a magasabb fordulatszámút találná meg és utána a fele akkora nagyságút a maradékban. Fordított esetben nem látszik a különbség.

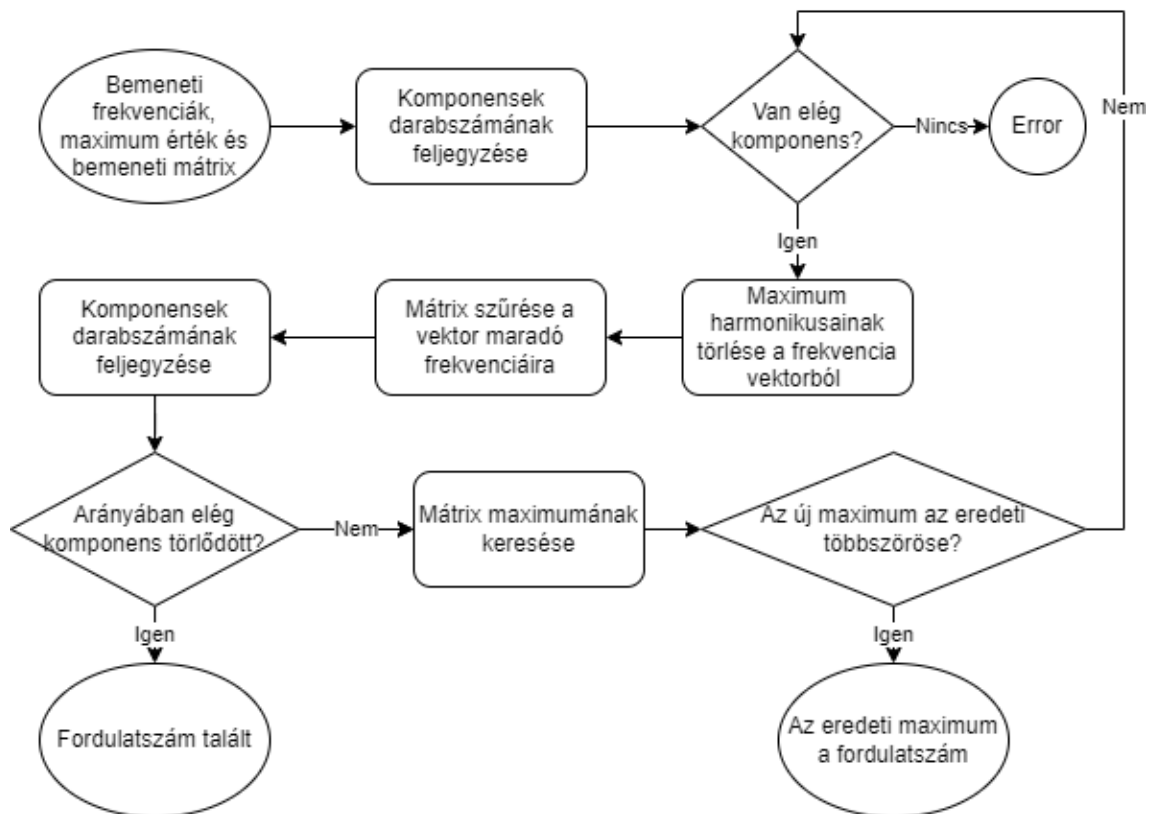


45. ábra: 2 frekvencia kereső algoritmus

Egyébként, ha elég sok komponens maradt, akkor újra meg kell keresni a maximumot és végrehajtani az előbbi folyamatot. Szükséges ellenőrizni, hogy biztosan elég komponens eliminálódott a folyamat során.

A fordulatszám kereső függvény úgy működik, hogy a korábban említett bemeneti paraméterekből megszámolja a mátrix számosságát. Ellenőrzi, van-e elég elem, majd kitörli egy függvény segítségével a frekvencia vektorból a maximum többszöröseit. Hiba határként 1 Hz eltérést engedek meg, tehát 1 Hz sugarú körben törlöm az adatokat. A mátrixot összevetem a vektorral, és csak azokat az amplitúdó-frekvencia párokat tartom

meg, amik a szűrt vektorban is maradtak. Feljegyzem az elimináció utáni mátrix darabszámát, majd összevetem a korábbi méretével. Azt várom, hogy a két fordulatszám közel egyforma arányban jelenjen meg a harmonikusok között. Mivel véges méretű a mátrix, nem várom el, hogy ez pontosan teljesüljön. Döntési küszöbnek én a 40%-os elimináció arányt választottam. Ha ennyi elem nem törlődött, akkor feltételezem, lesz egy jobb megoldás. A csökkentett mátrixnak megkeresem a maximumát. Előfordulhat, hogy az új találat az előző többszöröse lesz. Például 20 és 40 Hz esetén, tegyük fel, megtalálta a 40-et első maximumként. Ha ezzel eliminál, akkor ez az arány nem biztos, hogy teljesül és elvetné a jó eredményt. 20 Hz többszörösei kétszer olyan gyakran fordulnak elő ugyanis a mátrixban. Lehet, hogy a 40 egy második harmonikusa a fordulatszámnak, de az ideális esetet feltételezem alapból. Tehát, ha kiderül, hogy az új maximum a régi többszöröse, akkor a régit ismerem el eredményként. Ha nem, akkor visszatérek arra a lépésre, hogy ellenőrzöm a mátrix nagyságát, maradt-e még elég adat.




46. ábra: Fordulatszám kereső függvény

A kódolás során a döntési szinteket tapasztalati úton hangoltam be. Egy 28 mérésből álló halmazon finomítottam, míg nem az összes eredmény hibátlan lett.


Hibátlan abban az esetben, amennyiben elfogadjuk, hogy az egyforma és a többszörös fordulatszámok között nem minden esetben lehet különbséget tenni.

A következő példák szemléltetik az algoritmus menetét, hogyan változik a harmonikusokat tartalmazó mátrix. Első példának egy 20-30 Hz-es propellerpár példáját mutatom be.




47. ábra: 20-30 Hz propeller pár csúcsai a spektrumban

A kezdeti ábrán látszik mind a 20 csúcs, amit a spektrumból megkerestem. Leolvasható innen a maximumhoz tartozó fordulatszám. Ezt a továbbiakban egészre kerekítem, hiszen a valóságban sem tökéletesen konstans ez az érték.




48. ábra: 30 Hz többszöröseinek törlése után a spektrum csúcsai

Látható, hogy jelentős számú komponens eltűnt, mikor töröltem az előbbi frekvencia többszöröseit. Az új maximum szintén az ábrán jelölve van. Következő lépésben ezzel eliminálok és végezetül egy pár elemes mátrix maradt. Ezek az elemek keverési termékek, előfordulásuk esetenként eltérő. Jelen esetben maradt egy -45 Hz-es komponens és egy 235 Hz-es. Olyanra is volt példa, hogy minden eliminálódott.




49. ábra: Megmaradt komponensek a fordulatszámok többszöröseinek törlése után

Az algoritmus hibakezelésére is mutatok egy példát, miért ez a sok feltétel a programban. Tehát az alábbi esetben az első ciklus rendben működött, eliminálta a fordulatszámot. A következő maximum viszont, egy magasabb harmonikus. 30 helyett a 90-et választja ki, és a függvény szerint ez a helyes. Ezt a döntést még egyszer a fő programrészben felülvizsgálom és ha úgy ítéli az algoritmus, hogy túl sok komponens maradt, akkor még egyszer lefuttatja a keresési ciklust. Ezután kellően sok elem törlődött és inkább ezt válassza valós megoldásként helyesen.




50. ábra: 25-30 Hz propeller pár csúcsai a spektrumban




51. ábra: 25 Hz többszöröseinek kizárása után

Mikor egy egyforma fordulatszámú példát vizsgálok, az első elimináció után megfigyazkodik a mátrix mérete. A maradék adat nem releváns további frekvencia keresésre.




52. ábra: Egyforma fordulatszámú propellerek harmonikusai




53. ábra: A megmaradt komponensek 1 elimináció után (30-30 Hz)

Hasonló dolog történik a többszörös frekvenciák esetén. Itt a maximum komponens 20 Hz volt, tehát az elimináció után a 40 Hz-es párja is törlődött. A megmaradt egy elem (30 Hz) nem alkalmas további keresésre.



54. ábra: 20 és 40 Hz es propellerek harmonikusai

7.7 Egy valós drón spektruma rögzített állapotban



55. ábra: Mérési elrendezés rögzített drónnal

A méréshez egy DJI Phantom 4 Pro+ típusú drónt vettem alapul. Ez a drón négy propellerrel rendelkezik, amelyek műanyagból készültek. Egy kisebb méretű drón, általános felhasználásra, azaz nem alkalmas teher hordozásra, illetve drón irányító versenyekre. Méretéből adódóan a stabilitása nem elég nagy ahhoz, hogy 10-20 km/h-ás széllelkések mellett egyhelyben maradjon. Ez a radar érzékenysége mellett okoz ingadozásokat a spektrumban.

Ahhoz, hogy minél stabilabb helyzetben rögzíthessek felvételeket a drónról egy asztalhoz rögzítettem. A rögzítések legfeljebb pár centi helyváltozást engedtek, ahogy próbált felemelkedni a drón. A radar magasságát a propellerek szintjéhez igazítottam.


Mivel ez egy valós drón, és nem egy propeller forgató tesztapad, így se nem tudom szabályozni a propellerek pontos fordulatszámát, se nem tudom a pontos pillanatnyi értéket. A drón szabályozója maga végzi az utasításoknak megfelelően a rotorok szabályozását, erről nem küld visszajelzést a felhasználónak. Ha az irányító fel akar emelkedni, növeli a fordulatszámot, fordított esetben csökkenti, horizontális helyváltoztatáshoz pedig külön változtatja a forgási sebességeket, így teremtve meg az oldal irányú hajtóerőt. Egyhelyben történő lebegéshez nyugodt időben egy nagyjából konstans fordulatszámot tart. A drón szabályozója próbálja a széllelkéseket kiegyenlíteni,

de teljes mértékben nem tudja. Ezeket a bizonytalanságokat mindenképp számításba kell venni a mérés során.


A folyamatos változtatások miatt új megközelítési módot kell választani a gyors Fourier transzformációhoz. Eddig a laboratóriumi körülmények között, mikor a propellerek fordulatszáma jóformán nem fluktuált, segített az a megközelítés, hogy minél több mintát átlagoltam. Konkrétan a 65 536 minta alapján számítottam ki a spektrumot. A felvétel bitsebessége 44100 bps volt, ez a paraméter a radar beépített tulajdonsága. Én magam az ablakméret változtatásával tudok kísérletezni. Minél több mintát rögzítetek, a beérkezett energia is annál nagyobb lesz. A jobb összemérhetőség végett normáltam a spektrumokat a maximális komponenshez. Ilyen módon a laboratóriumi mérésekre nem bírt jelentős hatással az ablakméret, a fordulatszám és a harmonikusai jól kivehetők. A nagyobb méret több fordulatot átlagol, tehát jobban leírja a forgás általános jellegzetességeit.

Ezzel szemben a valós drón fordulatszáma nem konstans. A változás abban nyilvánul meg, hogy ha több mintát átlagolunk, akkor több spektrumkomponens is megjelenik. Egyszerre látni a spektrumban honnan hova gyorsult a rotor. Kisebb ablak rövidebb időintervallumot foglal magába, így a változás is kisebb, inkább mutatja a pillanatnyi állapotot.

A fenti (56.) ábrán látható, hogy a drón változtatta a fordulatszámát. Itt az ablakméret 65 536 minta volt. Ugyanakkor az ezt követő 57. ábrán egy szintén 65 536 mintaszámú spektrum látható, a különbség, hogy a drón a felvétel alatt stabilabb fordulatszámot tartott.




56. ábra: Változó fordulatszám hatása a spektrumra 65 536 minta mellett




57. ábra: Közel konstans fordulatszám hatása a spektrumra 65 536 minta mellett

Ha a változó spektrumát kisebb ablakmérettel vizsgálom, jobban kivehetők a harmonikusok. Persze, ha csökkentem a minták számát a tuskék egyre kevésbé lesznek tüköseszerűek és kiszélesednek. Túl kis ablakot ezért nem érdemes választani, nem feltétlenül javítja egy szint alatt a becslést. Tapasztalataim szerint 4096 minta méret alkalmas lehet egy drón vizsgálatához.



58. ábra: Változó fordulatszám hatása a spektrumra 4096 minta mellett




59. ábra: Változó fordulatszám hatása a spektrumra 512 minta mellett

2 hatványai szerint növeltem az ablakméretet és úgy elemeztem egy felvételt, amiről feltételeztem, hogy a drón változtatta a rotor sebességét. Kis ablakmérettel kezdtem, ezen a maximum komponens helye 34 Hz-re adódott. A fordulatszámokkal csak abszolútértékben foglalkozom jelen esetben. Ahogy növeltem az ablakméretet és nagyobb időegységet átlagoltam a maximum helye növekedett. A kezdeti 512 minta, 34 Hz-ről, 38 Hz-re nőtt 4096 minta alatt. Megkértszereztem az intervallumot és a maximum helye 51 Hz lett, következő lépésben pedig 70. Ebből arra következtetek, hogy a

fordulatszám gyorsult, illetve, hogy a gyorsabb forgás több energiát jelent és az a komponens fog leginkább kiemelkedni a spektrumból. A mintában az alacsonyabb frekvenciák is beleátlagolódtak, de a maximum helye növekedett, azaz nagyobb súlyt kapott a magasabb forgási frekvencia.


7.8 Egy valós drón mérése a levegőben




60. ábra: Mérési elrendezés repülő drónnal

A méréshez az előzőleg használt, DJI Phantom 4 Pro+ típusú drónt használtam. Ezúttal a radarhoz állítottam a drón repülési magasságát és nem fordítva. A távolságot szemmértékre igyekeztem tartani biztonsági okokból. A mérés egy nyitott téren zajlott, nem voltak a közelben reflexiót okozó zavartárgyak. A szél átlagosan 5-10 km/h erősségű volt, előfordultak esetenként ennél nagyobb széllesek. A drón kilengése ennek függvényében fél-egy méter is lehetett, nyugodtabb pillanatokban pár centiméter.

Az előző esethez hasonlóan ezúttal is megvizsgáltam az ablakméret hatását. Ezúttal még drasztikusabb esetek is előfordultak, a 65 536 minta mellett a spektrum egyáltalán nem hasonlított a laboratóriumi esetre. Ilyen magas mintaszám abszolút alkalmatlan a repülő drón elemzésére. Csak viszonylag ideális esetben lesz ilyen beállítás mellett értelmezhető a spektrum.




61. ábra: Repülő drón spektruma 65 536 mintaszám mellett nem ideális esetben



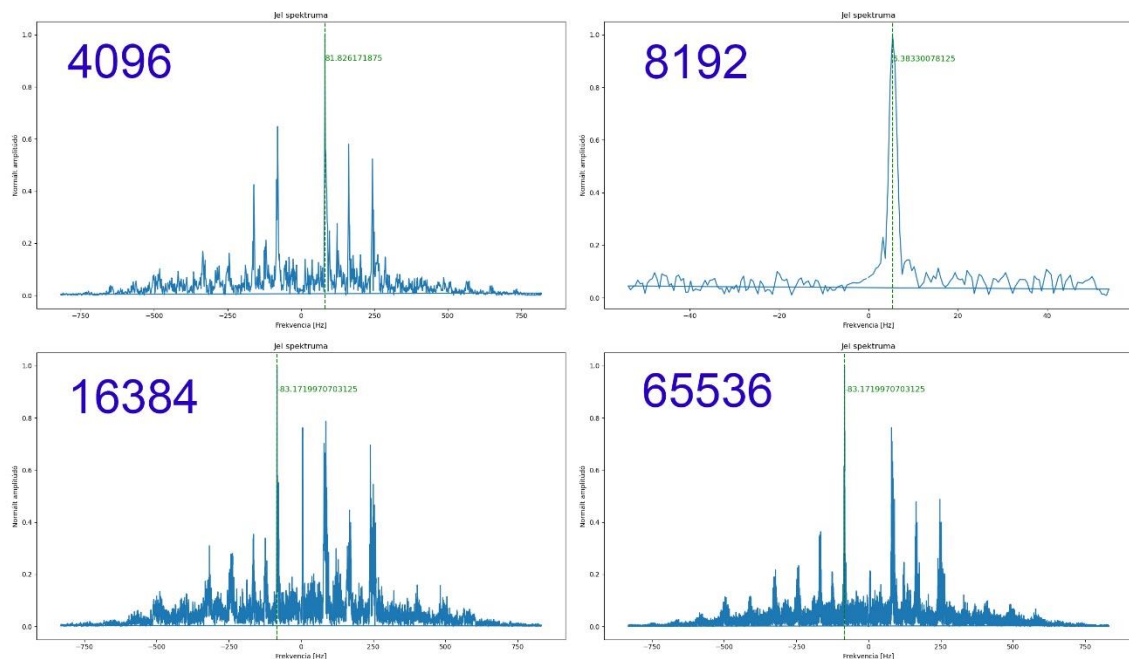
62. ábra: Repülő drón spektruma 65 536 mintaszám mellett kedvezőbb esetben

A mintaszám csökkentésével ezúttal is jobb becslés tehető a drón spektrumára. Az első példa esetén 4096 mintaszám mellett megjelentek a további csúcsok a spektrumban. A maximum helye is átkerült egy sokkal valószínűbb fordulatszámra. A 8 Hz körüli érték nem reális fordulatszám, biztosan nem tudna elég felhajtóerőt generálni, hogy lebegjen egy drón. Feltételezem, hogy a 80 Hz körüli érték, vagy annak a fele már valószínűbb pillanatnyi fordulatszám.



63. ábra: Repülő drón spektruma 4096 minta ablakmérettel

Repülő drónos esetben viszont nem tapasztaltam azt a folytonos tendenciát az ablakméret és a spektrum között. Tehát, amikor a kisebb mérettől haladtam a nagyobb felé, előfordultak anomáliák. Volt, hogy egy spektrum nagyon megváltozott, hibás lett, eltűntek róla a jellegzetes tuskék, miközben a kisebb és nagyobb mintaszámok mellett ott voltak.




64. ábra: Repülő drón felvételéből számított spektrumok különböző ablakméretekkel

7.9 Valós drón fordulatszám becslése


Igazi drón esetén, annak helyváltoztatásai miatt a fordulatszám becslése nem kivitelezhető egzakt módon. Lehetséges, hogy mind a négy fordulatszám különböző, és nem is célszerű őket egyenként megbecsülni. A forgásirányok egymás mellett különbözők, ez biztos fix paramétere a drónnak. Négy propeller esetén lesz megegyező és különböző forgásirányú propeller is.

Az én megközelítésemben egy mintázathoz igazítom a spektrumot. Feltételezek egy forgási frekvenciát, aminek köze lehet a maximális komponenshez. Ha ábrázolom ennek a többszöröseit a frekvencia tengelyen függőleges vonalakkal, azt várom, hogy a csúcsok ehhez illeszkedjenek.

Gyakori eset, hogy a maximum nem az alap fordulatszámra esik, hanem például a kétszeresére. Ilyenkor a függőleges vonalak között félúton jól kivehető tüskék sorakoznak. Ebben az esetben felére csökkenteném a raszter méretét és így kevesebb tüske marad illesztetlenül. Ennek a fordítottja, amikor sok függőleges vonal marad üresen, nem található a közelében tüske. Ilyenkor túl alacsony a feltételezett fordulatszám. Vizuálisan iterálható és becslhető ez a folyamat. Ez a módszer emberi beavatkozást igényel, nem automatizált eljárás. Megbízhatósága nagyban függ a felhasználtól, viszont észlelhetők általa különleges esetek.



65. ábra: Becsült frekvencia illesztése a spektrumra – valós frekvencia feltehetőleg kisebb



66. ábra: Becsült frekvencia illesztése a spektrumra – legnagyobb komponensek illeszkednek

Ehhez a fajta becsléshez elegendő lehet, ha csak az n számú maximumot mérjük össze. Itt kérdéses, mikor számítsuk külön csúcsnak. Két közeli csúcs előfordulhat, mert fluktuál a fordulatszám vagy mert két különböző pár Hz különbséggel forgó propellert látunk. Ilyen eseteket kérdés érdekes-e egynek venni? Mi az a határ, ami fölött releváns egy tüske figyelembevétele? A köztes komponensek keverési termékek-e vagy egy valós fordulatszámot mutatnak? Ezeknek a paramétereknek az állításával lehet a becslést finomítani.

Olyan pontosság, mint a laboratóriumi esetben elérhető volt ezúttal semmiképpen sem várható el. Nem lehet Hz-re pontosan becslést adni. Hiszen az a szám melyik propellert írná le valóban? Lehetne a leggyorsabb, valószínűleg az a legdominánsabb a spektrumban, vagy lehet a négy propeller átlaga is. Ha történik is ilyen becslés az csak egy pillanatot jellemezhetne. Amint a drón süllyed vagy emelkedik megváltozik.

Úgy próbáltam befolyásolni egy drón fordulatszámát lebegő helyzetben, hogy súlyokat szereltem rá. Mivel ez a drón nem alkalmas teherszállításra legfeljebb 250 g nehezéket erősítettem hozzá. Elméletileg, hogy nagyobb tömeget tartson a levegőben azonos időjárási körülmények között nagyobb felhajtóerőt kell generáljon, ami nagyobb fordulatszámmal érhető el.

Tömeg [g]	Maximumok [Hz]
0	80-86
50	83-90
100	85-95
150	88-100
200	90-103
250	92-107

A táblázatban a rögzített súlyokkal történő mérések adatai láthatók. A maximumok helyét rögzítettem nagyjából milyen intervallumban fordultak elő a spektrumban különböző felvételeken és ablakméretek mellett vizsgálva. A szórás több Hz, emiatt lehet, hogy egy nagyobb tömeggel lebegő drón pillanatnyilag alacsonyabb fordulatszámot tartott, mint egy plusz tömeg nélküli. Több mérést vizsgálva már látszik kapcsolat a fordulatszám és a tömeg között. Viszont ezek a súlyok önmagukban nem okoznak akkora különbséget, hogy abból biztosan következtetni lehessen rájuk. Egy csomagszállításra alkalmas drón esetén relevánsabb a feladat, hogy a fordulatszámából következtessünk a tömegére. Annak a stabilitása is nagyobb, kevésbé ingathatják meg a széllekek, egyenletesebb fordulatszám várható lebegő helyzetben.



67. ábra: Valós drón mérése

8 Összegzés

A kutatás során megállapítottam, hogy egy mikro-Doppler spektrumból meg lehet állapítani egy propeller fordulatszámát jó biztossággal. Determinisztikus módon a becslés tapasztalatom szerint teljes biztossággal megtehető. Megfelelő adatformázás, regresszió után képes egy mesterséges intelligencia függvényt illeszteni az adatokra, amivel jó közelítéssel meg tudja becsülni a frekvenciát. Erre a problémára egy egyszerű lineáris regressziós blokk is képes lehet.

Két propeller fordulatszámának becslése is lehetséges determinisztikus módom, ám ennek vannak korlátai. Az eredmény nem minden esetben egyértelmű, de kivételektől eltekintve megbízható. Valós drón átlag fordulatszáma is látható a mikro-Doppler spektrumban. Azonban, mivel ebben az esetben nem áll rendelkezésre pontos visszajelzés, a spektrumból következtetett frekvencia nem ellenőrizhető, csak közvetett módon lehet benne összefüggéseket keresni és ebből következtetni a használhatóságára.

A propellerek formája erősebb befolyással van a harmonikusok egymáshoz mért arányára, mint annak anyagi minősége. Emellett a mérési elrendezés is nagyban befolyásolja a spektrum jellegét. Ezeket összevetve csak egy nagyon sok paraméteres összetett sok elemű adathalmazon lehet érdemes összefüggéseket keresni. Ennek feldolgozására összetettebb AI-ra van szükség, mélyebb tanulást igényel.

Irodalomjegyzék

- [1] Peter Tait: *Introduction to Radar Target Recognition*, IEE Radar, Sonar and Navigation series 18, ISBN 0-86341-501-6, 2005
- [2] Pallag Sámuel, Budapest Műszaki és Gazdaságtudományi Egyetem Villamosmérnöki és Informatikai Kar: *Drón rotorok polarimetrikus RCS vizsgálata*, Szakdolgozat, 2022
- [3] Dr. Seller Rudolf, Magyar Nemzeti Közszolgálati egyetem kiadó: *A Radarmérés alapjai*, 2016
- [4] Drónokról kezdőknek blog,
https://minerkttech.blog.hu/2018/08/02/dronokrol_kezdoeknek
(elérve: 2023.03.15.)
- [5] Rubicon online: Először száll fel a Wright testvérek repülőgépe,
<https://rubicon.hu/kalendarium/1903-december-17-eloszor-szall-fel-a-wright-testverek-repulogepe>
(elérve: 2023.09.15.)
- [6] Arcanum: Asbóth Oszkár,
<https://www.arcanum.com/hu/online-kiadvanyok/Lexikonok-magyar-eletrajzi-lexikon-7428D/a-a-744F8/asboth-oszkar-746CE/>
(elérve: 2023.09.15)
- [7] Kupfer Viktória, Budapest Műszaki és Gazdaságtudományi Egyetem Villamosmérnöki és Informatikai Kar: *FM sávú analóg jelkioltó passzív radarhoz*, Szakdolgozat, 2021
- [8] IET Digital Library, *Radar Micro-Doppler Signatures: Processing and Applications*,
<https://digital-library.theiet.org/content/books/ra/pbra034e>
(elérve: 2023.03.15)
- [9] Markotics Boldizsár, Budapest Műszaki és Gazdaságtudományi Egyetem Villamosmérnöki és Informatikai Kar: *Járművek mikro-Doppler folyamatainak a vizsgálata*, Szakdolgozat, 2021
- [10] Szegedi tudományegyetem: Elektromágneses hullámok,
http://eta.bibl.u-szeged.hu/2173/2/elektromgneses_hullmok.html
(elérve: 2023.09.16.)
- [11] Budapesti Műszaki és Gazdaságtudományi Egyetem Villamosmérnöki és Informatikai Kar Szélessávú Hírközlés és Villamosságtan Tanszék: *Radar technológiában alkalmazható AI algoritmusok*, tanulmány
- [12] Python Machine Learning Tutorial,
<https://www.techwithtim.net/tutorials/machine-learning-python/linear-regression>
(elérve: 2023.09.30.)

Függelék

Spektrum és harmonikusok meghatározása

```
import sys
import copy
import struct
import numpy as np
import matplotlib.pyplot as plt
from scipy import signal
from collections import Counter

##### FÁJL OLVASÁSA ÉS KOMPLEX SZEKTRUM
LÉTREHOZÁSA#####

# bináris fájl olvasása

filename = sys.argv[1]

#print(filename)

with open(filename, "rb") as f:
    data = f.read()

# komplexé alakítás

length = len(data) // 4
cmplx_data = []
for i in range(length):
    offset = i * 4
    re, im = struct.unpack('<hh', data[offset:offset+4])
    c = complex(re, im)
    cmplx_data.append(c)

# szűrő Blackman ablakkal
n=4096*16

window = np.blackman(len(cmplx_data)) # A Blackman ablak létrehozása
data_windowed = cmplx_data * window # A jel megszorozása a Blackman
ablakkal

# fft ablak méret és a szűrő tulajdonságai

sample_rate = 44100
dec=5
new_sample_rate = sample_rate/dec
```



```

nyquist_rate = 0.5 * sample_rate
cutoff = 1000 / nyquist_rate

b, a = signal.butter(dec, cutoff, btype='low')

# szűrő alkalmazása a jelen

filtered_cmplx_data = signal.decimate(signal.lfilter(b, a,
data_windowed), dec)

# spektrum meghatározása

spec = np.fft.fft(filtered_cmplx_data, n)

##### KARAKTERISZTIKUS TULAJDONSÁGOK MEGHATÁROZÁSA
A SPEKTRUMBÓL #####

abs_spec = np.abs(spec) / np.size(spec)

#abs_spec = 20*np.log10(abs_spec)

freqs = np.fft.fftfreq(n, (2*dec)/sample_rate)

# legnagyobb amplitúdójú komponens megkeresése

max_index = np.argmax(abs_spec)
max_amp = np.max(abs_spec)
max_freq = freqs[max_index]
abs_max_freq = abs(max_freq)

# normálás a maximális komponenshez

abs_spec = abs_spec / max_amp

# zaj kizárása

for i in range(len(abs_spec)):
    if abs_spec[i] < 0.05:
        abs_spec[i] = 0

# energia kiszámítása

positive_energy = sum(abs_spec[freqs >= 0])
negative_energy = sum(abs_spec[freqs < 0])
total_energy = sum(abs_spec)

# harmonikus frekvenciák megkeresése

```

```

harmonics = []
# Másolat készítése
magnitudes = copy.copy(abs_spec)
kozeli = 0
num_peaks = 12

while len(harmonics) < num_peaks:
    kozeli = 0
    harmonic_index = np.argmax(magnitudes[1:]) + 1 # Az aktuális
    maximális magnitúdó indexe
    harmonic_frequency = freqs[harmonic_index] # Az aktuális
    maximális magnitúdóhoz tartozó frekvencia

    if len(harmonics) > 0:
        for i in range(len(harmonics)):
            if abs(harmonic_frequency - harmonics[i]) < 5 :
                kozeli = 1
        if kozeli == 0:
            harmonics.append(harmonic_frequency)
    else:
        harmonics.append(harmonic_frequency)

    magnitudes[harmonic_index] = 0 # Az aktuális maximális magnitúdó
    nullázása

# a harmonikus frekvenciákhoz tartozó amplitudók megkeresése

harmonics_amplitude = []

for i in range(num_peaks):
    harmonics_index = np.where(freqs == harmonics[i])
    harmonics_amplitude.append(abs_spec[harmonics_index])

harmonics_amplitude = [item for sublist in harmonics_amplitude for
item in sublist]

```

Lineáris regressziós tanító algoritmus

```

import pandas as pd
import sklearn
from sklearn import linear_model
from sklearn.utils import shuffle
import sys
import copy
import struct
import numpy as np
import matplotlib.pyplot as plt

```

```

from scipy import signal
from collections import Counter
import numpy as np
import copy

file_path = "ML_data_to_freqguess_sorted.txt" # A fájl elérési
útvonala

column_names = ["f1", "f2", "f3", "f4", "f5", "f6", "f7", "f8", "f9",
"f10", "f11", "f12", "freq"]

try:
    with open(file_path, 'r') as file:
        data = [line.strip().split(',') for line in file.readlines()]
        df = pd.DataFrame(data, columns=column_names)
        #print(df.head())
except FileNotFoundError:
    print(f"A {file_path} fájl nem található.")

predict = "freq"

X = np.array(df.drop([predict], 1)) # Features
y = np.array(df[predict]) # Labels

x_train, x_test, y_train, y_test =
sklearn.model_selection.train_test_split(X, y, test_size = 0.2)

linear = linear_model.LinearRegression()

linear.fit(x_train, y_train)
# acc = linear.score(x_test, y_test)
# print("Accuracy: ", acc)

# print('Coefficient: \n', linear.coef_)
# print('Intercept: \n', linear.intercept_)

# predictions = linear.predict(x_test)

# for x in range(len(predictions)):
#     print(predictions[x], x_test[x], y_test[x])

predictions = linear.predict(x_test)
predictions = [round(n) for n in predictions]

helyes = copy.copy(y_test)
helyes = helyes.astype(int)

```

```

diff = []

for j in range(len(predictions)):
    diff.append(abs(predictions[j]-helyes[j]))

# for i in range(len(predictions)):
#     print(f"Predicted: {predictions[i]}, Actual: {y_test[i]}, Diff:
#         {diff[i]}")

print(diff)

# Hányados számolása
total = len(diff)
smaller_than_3 = sum(1 for x in diff if x <= 3)
greater_than_8 = sum(1 for x in diff if x > 8)
remaining = total - smaller_than_3 - greater_than_8

# Színek, címek definiálása
colors = ['green', 'red', 'yellow']
labels = ['3 Hz-en belüli pontosság', '8 Hz-nél nagyobb tévedés', '3
és 8 Hz közötti pontosság']

# Torta diagram kirajzolása
plt.pie([smaller_than_3, greater_than_8, remaining], labels=labels,
        colors=colors, autopct='%1.1f%%')
plt.axis('equal') # Kör alakú diagram
plt.title('Lineáris regressziós becslés pontossága')
plt.show()

```

Fordulatszám becslés egy propellerre

```

# fordulatszám becslése
# becslés a frekvencia különbségek alapján

szamsorozat = copy.copy(harmonics)
szamsorozat = [round(n) for n in szamsorozat]
szamsorozat.sort()
X = []

for i in range(len(szamsorozat)-1):
    X.append(szamsorozat[i+1] - szamsorozat[i])

# Számláló létrehozása a tömb elemeinek számosságával
szamlalo = Counter(X)

# A leggyakoribb elem(ek) és előfordulási száma(ik)
leggyakoribb = szamlalo.most_common(1)

```

```
rot_freq = leggyakoribb[0][0]
```

Fordulatszám becslés két propellerre

```
##### FREKVENCIÁK SZŰRÉSE
#####

# frekvencia elimináló függvény

def eliminate_freq(tomb, szam):
    torlendo = set() # Ebben a halmazban tároljuk azokat a számokat,
    amelyeket törölni kell

    for elem in tomb:
        if elem % szam == 0 or (elem+1) % szam == 0 or (elem-1) % szam
        == 0:
            torlendo.add(elem)

    tomb[:] = [elem for elem in tomb if elem not in torlendo]

# A szűrt tömb maximumának keresése függvény

def find_max(szurt_tomb):
    legnagyobb_masodik = max(p[1] for p in szurt_tomb)

    # A legnagyobb második taghoz tartozó első tag keresése és kiírása
    for elso, masodik in szurt_tomb:
        if masodik == legnagyobb_masodik:
            max_freq = elso

    return max_freq
    break # Ha találtunk egyet, kilépünk a ciklusból

# ábrázoló függvény

def show_elm(szurt_tomb, rot_freq, diagramcim):

    x , y = zip(*szurt_tomb)

    plt.figure(figsize=(12, 7))
    plt.axvline(x=rot_freq, color="g", linestyle="--")
    plt.text(rot_freq + 0.1, 0.9, f"{rot_freq}", color="g",
    fontsize=12)
    plt.bar(x, y, width=oszlop_vastagsag)
    plt.xlabel('Frekvencia [Hz]')
```

```

plt.ylabel('Normált amplitúdó')
plt.title(diagramcim)
plt.ylim(0, 1)
plt.tight_layout()
plt.show()

# fordulatszám felismerő függvény

def find_rotfreq(to_eliminate, max_freq, matrix_out_sorted_round):

    peaks_remain = []
    peaks_remain.append(len(to_eliminate))
    max_freq1 = max_freq

    while peaks_remain[-1] > 2 :
        eliminate_freq(to_eliminate, max_freq)
        matrix_remain = [pair for pair in matrix_out_sorted_round if
pair[0] in to_eliminate]
        #show_elm(matrix_remain, 0, "Maradék frekvenciák a függvényen
belül")

        peaks_remain.append(len(to_eliminate))

        if peaks_remain[-1]/peaks_remain[-2] < 0.6 :
            rot_freq = max_freq
            return rot_freq, matrix_remain
            break
        else:
            max_freq = find_max(matrix_remain)
            #print("moduló: ", max_freq1 % max_freq)
            if (max_freq1 % max_freq) != 0 :
                return max_freq1, matrix_remain
                break

    return 0, 0

# kerekítés

harmonics_sorted_round = [round(n) for n in harmonics_sorted]
matrix_out_sorted_round = list(zip(harmonics_sorted_round,
harmonics_amplitude_sorted))

# KÉT FREKVENCIA KERESÉSE

```

```

to_eliminate = copy.copy(harmonics_sorted_round)
max_freq1=round(max_freq)

rot_freq1, matrix_remain =
find_rotfreq(to_eliminate,max_freq1,matrix_out_sorted_round)

if rot_freq1 == 0:
    print("Error")
else:
    print("rot_freq1: ", abs(rot_freq1))
    if len(matrix_remain) < 4:
        rot_freq2 = rot_freq1
        print("A két propeller fordulatszáma valószínűleg megegyezik,
vagy egymás többszörösei")
        #print("rot_freq2: ", abs(rot_freq2))
        if len(matrix_remain) > 1:
            show_elm(matrix_remain, 0, "Maradék frekvenciák")
    else:
        max_freq2 = find_max(matrix_remain)
        show_elm(matrix_remain, max_freq2, "1. elimináció után")
        rot_freq2, matrix_remain2 =
find_rotfreq(to_eliminate,max_freq2,matrix_out_sorted_round)

        while len(matrix_remain2) > 3 :
            max_freq2 = find_max(matrix_remain2)
            #show_elm(matrix_remain2, max_freq2, "2. elimináció után")
            rot_freq2, matrix_remain2 =
find_rotfreq(to_eliminate,max_freq2,matrix_out_sorted_round)

if rot_freq2 == 0:
    print("Error")
else:
    print("rot_freq2: ", abs(rot_freq2))

if len(matrix_remain2) > 1:
    show_elm(matrix_remain2, 0, "Maradék frekvenciák két
ciklus után")

```