

Univerzita Pardubice
Fakulta elektrotechniky a informatiky

Disertační práce
Zpracování radarového signálu s využitím
 μ -Dopplerova efektu

Doktorand

Ing. Josef Jordán

Doktorský studijní program

P0788D060001 Elektrotechnika a informatika

Školitel

doc. Ing. Jan Pidanič, Ph.D.

Školitel specialista

Ing. Karel Juryca, Ph.D.

Prohlášení autora

Prohlašuji:

Práci s názvem Zpracování radarového signálu s využitím μ -Dopplerova efektu jsem vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

Byl jsem seznámen s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnicí Univerzity Pardubice č. 7/2019 Pravidla pro odevzdávání, zveřejňování a formální úpravu závěrečných prací, ve znění pozdějších dodatků, bude práce zveřejněna prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 20.10.2025

Ing. Josef Jordán

Poděkování

Velice rád bych poděkoval svému školiteli panu doc. Ing. Janu Pidaničovi, Ph.D., a školiteli specialistovi panu Ing. Karlu Jurycovi, Ph.D., za jejich cenné rady, odborné vedení a podporu v průběhu mého studia. Zvláštní poděkování patří také mému bývalému profesorovi panu prof. Ing. Pavlu Bezouškovi, CSc., za jeho inspirativní přístup a cenné podněty, které ovlivnily můj odborný rozvoj. Mé poděkování rovněž směřuje společnosti Eldis Pardubice, s.r.o., která mi umožnila realizovat tuto práci a vytvořila k tomu potřebné podmínky. Na závěr bych rád poděkoval své rodině a přátelům za jejich podporu a trpělivost během celého mého studia.

Anotace

Tématem disertační práce je separace μ - Dopplerova spektra z radarového signálu a jeho analýza za účelem využití při klasifikaci objektu. V první části této práce je popis Dopplerova a μ - Dopplerova jevu, postup separace a dekompozice μ - Dopplerova spektra signálů, odražených od radarových objektů s rotujícími částmi, zejména od nepilotovaných vzdušných cílů s malou a fluktuující efektivní odraznou plochou. Byly vypracovány počítačové modely signálů, odražených od vybraných objektů a byla ověřena jejich použitelnost s využitím experimentálních dat, získaných z vlastních experimentů. Dále byly porovnány různé metody odhadu μ - Dopplerova spektra odraženého radarového signálu a pro účely klasifikace sledovaného objektu byla zvolena nejvhodnější z nich. Na základě tří vybraných objektů byla ověřena využitelnost radarových spekter pro jejich klasifikaci, a to porovnáním s modelovými spektry prostřednictvím neuronových sítí.

Klíčová slova

Radar; Dopplerův jev; μ - Dopplerovo spektrum; Signálové zpracování; Metody spektrální analýzy; Intrapulzní modulace; Modely signálů, odražených od rotujících předmětů; Dron; Jízdní kolo; Ventilátor;

Title

Radar signal processing using μ - Doppler effect.

Abstract

The subject of this thesis is the separation of the μ - Doppler spectrum from the radar signal and its analysis for use in object classification. The first part of the thesis describes the Doppler and μ - Doppler phenomena, the separation procedure, and the decomposition of μ - Doppler spectra of signals reflected from radar objects with rotating parts, particularly unmanned aerial targets with small and fluctuating radar cross-sections. Computer models of signals reflected from selected objects were developed, and their applicability was verified using experimental data from our own experiments. Furthermore, different methods for estimating the μ - Doppler spectrum of the reflected radar signal were compared, and the most suitable one was selected for classifying the observed object. Finally, the possibility of using their radar-derived spectra for classification is verified on three selected objects by comparing them with the spectra of models of these objects by neural network.

Keywords

Radar; Doppler effect; μ - Doppler spectrum; Signal processing; Spectrum analysis methods; Intrapulse modulations; Modelling the signal scattered by rotating objects; Drone; Bicycle; Fan;

Obsah

Obsah.....	5
Seznam zkratek a označení	8
Seznam symbolů	11
Seznam obrázků	14
Seznam tabulek	19
1 Úvod	20
1.1 Motivace	22
1.2 Cíle disertační práce	23
1.3 Originalita řešení a přínosy disertační práce	24
1.4 Struktura disertační práce	25
2 Současný stav poznání	26
2.1 Příklady komerčně úspěšných řešení.....	27
2.1.1 Radarový systém – ELVIRA®	27
2.1.2 Rádiový systém – ZDTECH.....	28
2.1.3 Optický systém SPEED-MR	29
2.1.4 Akustický systém CTRL+SKY	29
2.2 Úvod do měření signálu pro impulsní a FMCW radary	31
2.2.1 Impulsní radary	31
2.2.2 FMCW radary	31
2.2.3 Shrnutí požadavků, výhod, nevýhod impulsních a FMCW systémů	32
2.3 Zpracování signálu a metodika analýzy μ - Dopplerova jevu	32
2.3.1 Návrh radarového systému a sběr dat	32
2.3.2 Časově-frekvenční reprezentace a transformace signálu.....	33
2.3.3 Potlačení rušení, clutteru a šumu.....	33
2.3.4 Extrakce příznaků a klasifikace	33
2.3.5 Kognitivní optimalizace a iterace	33

2.4	Podrobná rešerše současných radarových systémů	33
2.5	Shrnutí požadavků na radarové systémy	35
3	Úvod do problematiky primárních radarových systémů	37
3.1	Popis RS z pohledu signálového zpracování	37
3.1.1	Primární zpracování	38
3.1.2	Sekundární zpracování	39
3.1.3	Terciální zpracování	39
3.2	Popis parametrů primárního radaru	39
3.3	Radarová rovnice	44
4	Modely radarového signálu, spektrální analýzy, vlivy pozorovaných cílů a prostředí	45
4.1	Model vysílaného signálu	45
4.2	Metody zpracování ve spektrální oblasti	53
4.2.1	Diskrétní Fourierova transformace (DFT):.....	56
4.2.2	Metody vycházející z DFT	57
4.2.3	Metody odhadu spektra, složeného z harmonických funkcí a šumu..	60
4.3	Modely pozorovaných cílů	66
4.3.1	Ventilátor	67
4.3.2	Dron	68
4.3.3	Jízdní kolo	70
4.4	Model odrazu signálu od překážky	71
4.5	Částečný odraz vlny na rozhraní prostředí	75
4.6	Model šíření signálu volným prostorem	77
5	Popis měřicího řetězce	78
5.1	Softwarově řízené rádio (SDR)	79
5.2	Směšování vysílaného signálu.....	79
5.3	Výstupní filtrace.....	80
5.4	Výstupní zesílení	80

5.5	Vstupní filtrace.....	80
5.6	Zpracování signálu	80
5.7	Analýza blízké a vzdálené zóny	81
6	Modely μ- Dopplerových spekter a porovnání s naměřenými daty	83
6.1	Ventilátor	84
6.1.1	Porovnání reálných měření a simulovaných dat	84
6.2	Dron	86
6.2.1	Parametry modelu.....	86
6.2.2	Porovnání reálných měření a simulovaných dat	88
6.3	Jízdní kolo	90
6.3.1	Porovnání reálných měření a simulovaných dat	90
7	Rozbor výsledků	92
7.1	Dron	92
7.2	Kolo.....	95
7.3	Ventilátor	96
8	Klasifikace	100
	Závěr	106
	Literatura	108
	Vlastní publikace a výstupy VaV	114
	Příloha A: Měřená data – DRON	115
	Příloha B: Měřená data – VENTILÁTOR	119
	Příloha C: Měřená data – JÍZDNÍ KOLO	126
	Příloha D: Stavba Neuronové Sítě	103

Seznam zkratek a označení

μ - Doppler	Mikro- Doppler
ACF	Auto-Corelation Function (Autokorelační funkce)
ADS	Automatic Dependent Surveillance
AM	Amplitudová Modulace
AMTI	Adaptive MTI
APES	Amplitude and Phase Estimation
AR	Autoregresivní
ASC	Amplitude Spectra Capon estimation
ATx, ARx	Vysílací a přijímací antény
CA-CFAR	Cell Averaging CFAR
CAS	Collision Avoidance System
CFAR	Constant False Alarm Rate
CW	Constant Wave
DFT	Discrete Fourier Transform (Diskrétní Fourierova Transformace)
DIY	Do It Yourself
FFT	Fast Fourier Transform (Rychlá Fourierova Transformace)
FLAMENCO	FLAt lobes MatchEd filter Nonlinear frequenCy mOdulation (Nelineární frekvenční modulace s plochým průběhem postranních laloků autokorelační funkce)
FMCW	Frequency Modulation Constant Wave (Frekvenční modulace v trvalém provozu)
GO-CFAR	Greatest Of CFAR
LFM	Linear Frequency Modulation (Lineární frekvenční modulace)
LO	Lokální Oscilátor
LSS	Low Slow Small
Mix	Mixer (směšovač)

MTD	M ovig T arget D etection
MTI	M oving T arget I dentification
MUSIC	MU ltiple SI gnal C lassification
NLFM	N on- L inear F requency M odulation (Nelineární frekvenční modulace)
OSCFAR	O rdered S tatistics CFAR
Pitch	Pohyb kolem příčné horizontální osy
PET	Polyethylene Terephtalate
PP	Polypropylene
PS	Polystyrene
PRF	P ulse R epetition F requency (Opakovací kmitočet impulzů)
PSD	P ower S pectral D ensity (Výkonová spektrální hustota)
Roll	Pohyb kolem podélné osy
SDR	S oftware D efined R adio (Softwarové radio)
SLS	S ide L obe S uppression (potlačení postranních laloků)
SNR	S ignal to N oise R atio (poměr výkonu signálu k výkonu šumu)
STFT	S hort T ime F ourier T ransform (Krátkodobá Fourierova Transformace)
UAV	U nmanned A erial V ehicle (nepilotovaný vzdušný prostředek)
X-band	Frekvenční pásmo 8 GHz – 12 GHz
Yaw	Pohyb kolem příčné vertikální osy
CNN	C onvolutional N eural N etwork
TCN	T emporal C onvolutional N etwork
PCA	P rincipal C omponent A nalysis
LDA	L inear D iscriminant A nalysis
k-NN	k -Nearest N eighbors
SVM	S upport V ector M achine

DTW	D ynamic T ime W arping
SSIM	S tructural S imilarity I ndex
L1-LDA	L inear D iscriminant A nalysis
GRU	G ated R ecurrent U nit
ACGAN	A uxiliary C lassifier G AN
GAN	G enerative A dversarial N etwork

Seznam symbolů

c	Rychlost světla
t_k	Doba ke k -tému cíli
$R(t_k)$	Šikmá vzdálenost ke k -tému objektu
δR	Chyba měření vzdálenosti
δt	Chyba měření času
δv_r	Chyba radiální rychlosti
v_r	Radiální rychlost
P_p	Přijatý výkon
G_v, G_p	Zisky vysílací a přijímací antény
f_v^2, f_p^2	Anténní charakteristika vysílací a přijímací antény
σ	Efektivní odrazná plocha odrážejícího objektu
φ, θ	Azimut, Elevace
λ	Vlnová délka
R	Vzdušná vzdálenost
L	Atmosférické ztráty
ε_0	Permitivita vakua
μ_0	Permeabilita vakua
ε_r	Relativní permitivita
μ_r	Relativní permeabilita
Ψ	Fáze signálu
ω_0	Úhlový kmitočet vysílané vlny
t	Čas
f_d	Dopplerův posuv kmitočtu
R_n	Vzdálenost n -té části odrážejícího objektu
$s_n(t, R_n)$	Signál, odražený od n -té části objektu
$u_n(R_n)$	Absolutní hodnota komplexní obálky signálu $s_n(t, R_n)$

$A(t)$	Absolutní hodnota komplexní obálky celkového odraženého signálu
$\Psi_1(t)$	Okamžitá fáze komplexní obálky celkového odraženého signálu
$\Psi_2(t)$	Fáze komplexní obálky signálu, odpovídajícího μ - Dopplerovu efektu
$\Phi(t)$	Okamžitá fáze modulovaného signálu
B	Efektivní šířka pásma
κ	Bezrozměrný koeficient, pro nastavení šířky hlavního laloku autokorelační funkce
$f(t)$	Okamžitý kmitočet vysílaného impulzu
f_s	Vzorkovací kmitočet
T_s	Vzorkovací perioda
τ_0	Délka vysílaného impulzu
r	r -tý vzorek impulzu
K	Počet vzorků vysílaného impulzu
t_r	Diskrétní čas
x_m, y_m, z_m	Souřadnice m -tého odrazného bodu
E_s	Odražené elektrické pole
E_{dop}	Dopadající elektrické pole
A_m	Komplexní skalár charakterizující velikost odrazu a jeho fázi
M	Počet rotorů
N	Počet lopatek
f_y, f_z	Frekvence otáčení v ose y, z
l_b	Délka jedné lopatky
\mathbf{L}	Matice souřadnic bodů tvořících cíl
Γ	Koeficient odrazu
Z_0	Vlnová impedance okolního prostředí
Z_1	Vlnová impedance materiálu cíle
$R_{no}(t)$	Vzdušná vzdálenost k odražečům v okamžiku t

$x(t)$	Vyslaný signál
v_n	Rychlost n – tého odražeče
f_0	Nosná frekvence
f_{mf}	Mezifrekvenční kmitočet
RF	Radio Frequency
ϑ	Úhel mezi jednotlivými lopatkami rotoru
θ_m	Náhodná počáteční fáze natočení m – té vrtule
f_m	Úhlová frekvence m – té vrtule
n	Pořadí listu ve vrtuli
\mathbf{R}_0	Vektor dopadu vyslané vlny k cíli
$\mathbf{V}_{r1}, \mathbf{V}_{r2}$	Vektor velikosti a směru rychlosti otáčení vrtule
k, l, m	Rozměry vstupní datové matice do neuronové sítě
p	Celkový počet dat vstupujících do neuronové sítě
\hat{y}_i	Predikovaná značka i – tého data
y_i	Skutečná značka i – tého data
$Loss$	Ztrátová funkce
C	Počet tříd
p_i	Predikovaná pravděpodobnost že vstupní data patří do i – té třídy
$\mathbf{A}_{ii}, \mathbf{A}_{ij}$	Vybrané hodnoty v matici záměn
P	Míra úspěšnosti klasifikace

Seznam obrázků

Obr. 1: Radarový systém – ELVIRA	27
Obr. 2: Rádiový systém – ZDTECH	28
Obr. 3: Optický systém SPEED-MR	29
Obr. 4: Akustický systém CTRL+SKY	30
Obr. 5: Četnost kmitočtových pásem (vlevo), četnosti použitých modulací (vpravo)	34
Obr. 6: Četnost μ - Dopplerovského zpracování (vlevo), typ antény (vpravo)	34
Obr. 7: Četnost optických systémů (vlevo), četnost publikací IEEE (vpravo)	35
Obr. 8: Odraz od vodivé koule – Raylei-Mie diagram	36
Obr. 9: Blokové schéma signálového zpracování	37
Obr. 10: Typy cílů v radarovém prostředí	40
Obr. 11: Ukázka měření šikmé dálky	40
Obr. 12: Vysílač A, přijímač C a odražející objekt B (vpravo)	42
Obr. 13: Blokový model simulátoru odražené vlny od zájmového cíle	45
Obr. 14: Okamžitá fáze a frekvence	47
Obr. 15: Spektra signálů	47
Obr. 16: Spektrogram FLAMENCO (vlevo), Taylor (vpravo)	48
Obr. 17: Funkce neurčitosti FLAMENCO (vlevo), Taylor (vpravo)	49
Obr. 18: Vliv Dopplerova posuvu na tvar korelační funkce, $F_d = 0$ Hz. FLAMENCO (vlevo), Taylor (vpravo)	49
Obr. 19: Vliv Dopplerova posuvu na tvar korelační funkce, $F_d = 0.5$ MHz. FLAMENCO (vlevo), Taylor (vpravo)	50
Obr. 20: Vliv Dopplerova posuvu na tvar korelační funkce, $F_d = 1$ MHz. FLAMENCO (vlevo), Taylor (vpravo)	50
Obr. 21: Srovnání ACF obou funkcí	51
Obr. 22: Měřicí řetězec pro určení vlivu reálného systému na ACF	52
Obr. 23: Ukázka komplexní obálky přijatého signálu Taylor (vlevo), FLAMENCO (vpravo)	52
Obr. 24: Autokorelační funkce (vlevo), detaily stejných autokorelačních funkcí (vpravo)	53
Obr. 25: Bodový odražeč	54
Obr. 26: Spektrogram testovacího signálu	55
Obr. 27: Metoda DFT, První úsek (vlevo), druhý úsek (vpravo), Délka $FT = 64$	57

Obr. 28: Bartlettova metoda, První úsek (vlevo), druhý úsek (vpravo), $K = 4$	58
Obr. 29: Welchova metoda, První úsek (vlevo), druhý úsek (vpravo), $L = 4$, $D = 0.7$	59
Obr. 30: Bl-Tu metoda, První úsek (vlevo), druhý úsek (vpravo), Délka FT = 64	60
Obr. 31: CAPON estimátor, První úsek (vlevo), Druhý úsek (vpravo), $K = 64$	61
Obr. 32: Yule-Walkerova metoda, První úsek (vlevo), Druhý úsek (vpravo), $p = 64$	63
Obr. 33: Burgova metoda, První úsek (vlevo), Druhý úsek (vpravo), $p = 64$	63
Obr. 34: Modifikovaná kovarianční metoda, První úsek (vlevo), Druhý úsek (vpravo), $p = 32$	64
Obr. 35: MUSIC metoda, První úsek (vlevo), Druhý úsek (vpravo), řád modelu $N = 8$	65
Obr. 36: Tří lopatkový odražeč.....	67
Obr. 37: Bodová reprezentace ventilátoru.....	68
Obr. 38: MATRICE-600 PRO (vlevo), DIY Dron (vpravo)	68
Obr. 39: Bodová reprezentace DIY dron (vlevo), MATRICE (vpravo).....	69
Obr. 40: Jízdní kolo	70
Obr. 41: Bodová reprezentace jízdního kola	71
Obr. 42: Ukázka geometrie sledovaného objektu	72
Obr. 43: Ukázka 2D projekce dronu.....	73
Obr. 44: Pohled na dron z boku (vlevo), průběh velikosti efektivní odrazné plochy σ [dBsm] v závislosti na úhlu pozorování (vpravo).....	74
Obr. 45: Pohled na lopatky ventilátoru z boku (vlevo), průběh velikosti efektivní odrazné plochy σ dBsm v závislosti na úhlu pozorování (vpravo).....	74
Obr. 46: Pohled na jízdní kolo z boku (vlevo), průběh velikosti efektivní odrazné plochy σ [dBsm] v závislosti na úhlu pozorování (vpravo).....	75
Obr. 47: Šíření signálu volným prostorem.....	77
Obr. 48: Blokové schéma měřícího pracoviště	78
Obr. 49: Měřící pracoviště	79
Obr. 50: Teoretický tvar spektrogramu ventilátoru	84
Obr. 51: Spektrogram měřeného objektu (Vlevo), spektrogram simulace (Vpravo)	85
Obr. 52: Boční pohled na spektrogram měřeného objektu (Vlevo), simulace (Vpravo)	86

Obr. 53: Teoretický tvar spektrogramu: Průběhy funkce Sm, nt podle (45), $N = 3$, $M = 4$. Tečkové elipsy upozorňují na místa s vysokou nebo naopak s nízkou hustotou křivek.....	87
Obr. 54: Spektrogram měřeného objektu (Vlevo), spektrogram simulace (Vpravo) – $PRF = 6000$	88
Obr. 55: Boční pohled na spektrogram měřeného objektu (Vlevo), simulace (Vpravo)	89
Obr. 56: Odraz vlny od vrtule dronu.....	89
Obr. 57: Teoretický tvar spektra jízdního kola	90
Obr. 58: Spektrogram měřeného objektu (Vlevo), spektrogram simulace (Vpravo)	91
Obr. 59: Boční pohled na spektrogram měřeného objektu (Vlevo), simulace (Vpravo)	91
Obr. 60: Ukázka orientace osy vysílání a měřeného objektu, pohled z boku (bokorys)	92
Obr. 61: Měření 1 – $fz = 14.8$ Hz (Vlevo), měření 2 – $fz = 28.1$ Hz (Vpravo) ..	93
Obr. 62: Měření 1 – $fz = 53.2$ [Hz] (Vlevo), měření 2 – $fz = 85.8$ [Hz] (Vpravo)	93
Obr. 63: Dron typu MATRICE-600 PRO – $\theta = 90^\circ$ (vlevo), spektrogram (vpravo)	94
Obr. 64: Dron typu MATRICE-600 PRO – $\theta = 82^\circ$ (vlevo), spektrogram (vpravo)	94
Obr. 65: Dron typu MATRICE-600 PRO – $\theta = 75^\circ$ (vlevo), spektrogram (vpravo)	95
Obr. 66: Ukázka orientace osy vysílání a osy měřeného objektu, pohled se shora (půdorys)	95
Obr. 67: Měření 1 – $\varphi = 10^\circ$ (vlevo), měření 2 – $\varphi = 30^\circ$ (vpravo)	96
Obr. 68: Měření 3 – $\varphi = 50^\circ$ (vlevo), měření 4 – $\varphi = 90^\circ$ (vpravo)	96
Obr. 69: Ukázka orientace osy vysílání a osy měřeného objektu, pohled ze shora (půdorys)	97
Obr. 70: Ukázka experimentálního měření ventilátoru	97
Obr. 71: Měření 1 – $\varphi = 0^\circ$ (vlevo), měření 2 – $\varphi = 30^\circ$ (vpravo)	98
Obr. 72: Měření 3 – $\varphi = 60^\circ$ (vlevo), měření 4 – $\varphi = 90^\circ$ (vpravo)	98
Obr. 73: Měření 5 – $\varphi = 120^\circ$ (vlevo), měření 6 – $\varphi = 150^\circ$ (vpravo).....	99
Obr. 74: Architektura neuronové sítě	101
Obr. 75: Proces učení sítě	103

Obr. 76: Matice záměn pro validační data ze simulátoru (vlevo), matice záměn pro měřená data (vpravo).....	105
Obr. 77: DYI – Měření 1 - $fz = 14.8$ Hz, $\theta = 15^\circ$ (Vlevo), DYI – Měření 2 - $fz = 28.1$ Hz, $\theta = 15^\circ$ (Vpravo).....	115
Obr. 78: DYI – Měření 3 - $fz = 53.2$ Hz, $\theta = 15^\circ$ (Vlevo), DYI – Měření 4 - $fz = 85.8$ Hz, $\theta = 15^\circ$ (Vpravo).....	115
Obr. 79: MATRICE600-PRO – Měření 5 - $fz = 10.8$ Hz, $\theta = 15^\circ$ (Vlevo), MATRICE600-PRO – Měření 6 - $fz = 14.8$ Hz, $\theta = 15^\circ$ (Vpravo).....	116
Obr. 80: MATRICE600-PRO – Měření 7 - $fz = 8.8$ Hz, $\theta = 15^\circ$ (Vlevo), MATRICE600-PRO – Měření 8 - $fz = 19.7$ Hz, $\theta = 15^\circ$ (Vpravo).....	116
Obr. 81: MATRICE600-PRO – Měření 9 - $fz = 21.7$ Hz, $\theta = 15^\circ$ (Vlevo), MATRICE600-PRO – Měření 10 - $fz = 24.8$ Hz, $\theta = 0^\circ$ (Vpravo).....	117
Obr. 82: MATRICE600-PRO – Měření 11 - $fz = 23.8$ Hz, $\theta = 0^\circ$ (Vlevo), MATRICE600-PRO – Měření 12 - $fz = 22.9$ Hz, $\theta = 6^\circ$ (Vpravo).....	117
Obr. 83: MATRICE600-PRO – Měření 13 - $fz = 20.7$ Hz, $\theta = 15^\circ$ (Vlevo), MATRICE600-PRO – Měření 14 - $fz = 21.6$ Hz, $\theta = 15^\circ$ (Vpravo).....	118
Obr. 84: MATRICE600-PRO – Měření 15 - $fz = 25.1$ Hz, $\theta = 15^\circ$ (Vlevo), MATRICE600-PRO – Měření 16 - $fz = 26.1$ Hz, $\theta = 15^\circ$ (Vpravo).....	118
Obr. 85: Měření 1 - $fy = 17.23$ Hz, s krytem - $\varphi = 45^\circ$ (vlevo), Měření 2 - $fy = 17.23$ Hz, bez krytu - $\varphi = 45^\circ$ (vpravo).....	119
Obr. 86: Měření 3 - $fy = 17.23$ Hz, bez krytu - $\varphi = 0^\circ$ (vlevo), Měření 4 - $fy = 17.23$ Hz, bez krytu - $\varphi = 10^\circ$ (vpravo).....	119
Obr. 87: Měření 5 - $fy = 17.23$ Hz, bez krytu - $\varphi = 20^\circ$ (vlevo), Měření 6 - $fy = 17.23$ Hz, bez krytu - $\varphi = 30^\circ$ (vpravo).....	120
Obr. 88: Měření 7 - $fy = 17.23$ Hz, bez krytu - $\varphi = 40^\circ$ (vlevo), Měření 8 - $fy = 17.23$ Hz, bez krytu - $\varphi = 45^\circ$ (vpravo).....	120
Obr. 89: Měření 11 - $fy = 17.23$ Hz, bez krytu - $\varphi = 80^\circ$ (vlevo), Měření 12 - $fy = 17.23$ Hz, bez krytu - $\varphi = 90^\circ$ (vpravo).....	121
Obr. 90: Měření 9 - $fy = 17.23$ Hz, bez krytu - $\varphi = 50^\circ$ (vlevo), Měření 10 - $fy = 17.23$ Hz, bez krytu - $\varphi = 60^\circ$ (vpravo).....	121
Obr. 91: Měření 13 - $fy = 17.23$ Hz, bez krytu - $\varphi = 100^\circ$ (vlevo), Měření 14 - $fy = 17.23$ Hz, bez krytu - $\varphi = 110^\circ$ (vpravo).....	122
Obr. 92: Měření 15 - $fy = 17.23$ Hz, bez krytu - $\varphi = 120^\circ$ (vlevo), Měření 16 - $fy = 17.23$ Hz, bez krytu - $\varphi = 130^\circ$ (vpravo).....	122

Obr. 93: Měření 17 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 140^\circ$ (vlevo), Měření 18 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 150^\circ$ (vpravo)	123
Obr. 94: Měření 19 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 170^\circ$ (vlevo), Měření 20 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vpravo).....	123
Obr. 95: Měření 21 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 22 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vpravo).....	124
Obr. 96: Měření 23 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 24 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vpravo).....	124
Obr. 97: Měření 27 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vlevo)	125
Obr. 98: Měření 25 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 26 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vpravo).....	125
Obr. 99: Měření 1 – $\varphi = 10^\circ$ (vlevo), Měření 2 – $\varphi = 30^\circ$ (vpravo).....	126
Obr. 100: Měření 3 – $\varphi = 40^\circ$ (vlevo), Měření 4 – $\varphi = 50^\circ$ (vpravo).....	126
Obr. 101: Měření 5 – $\varphi = 60^\circ$ (vlevo), Měření 6 – $\varphi = 80^\circ$ (vpravo).....	127
Obr. 102: Měření 7 – $\varphi = 90^\circ$ (vlevo), Měření 8 – $\varphi = \text{náhodný}^\circ$ (vpravo).....	127
Obr. 103: Měření 9 – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 10 – $\varphi = \text{náhodný}^\circ$ (vpravo)	128
Obr. 104: Měření 11 – $\theta = \text{náhodný}^\circ$ (vlevo), Měření 12 – $\varphi = \text{náhodný}^\circ$ (vpravo).....	128
Obr. 105: Měření 13 – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 14 – $\varphi = \text{náhodný}^\circ$ (vpravo).....	129
Obr. 106: Měření 15 – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 16 – $\varphi = \text{náhodný}^\circ$ (vpravo).....	129
Obr. 107: Měření 17 – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 18 – $\varphi = \text{náhodný}^\circ$ (vpravo).....	130

Seznam tabulek

Tab. 1: Parametry systému ELVIRA	27
Tab. 2: Parametry systému ZDTECH.....	28
Tab. 3: Parametry systém SPEED-MR.....	29
Tab. 4: Parametry systému CTRL+SKY	30
Tab. 5: Parametry simulace	53
Tab. 6: Ostatní parametry simulace	54
Tab. 7: Skóre jednotlivých metod	65
Tab. 8: Parametry ventilátoru.....	67
Tab. 9: Parametry DIY dronu	69
Tab. 10: Parametry MATRICE-600 PRO	69
Tab. 11: Parametry jízdního kola.....	70
Tab. 12: Materiálové parametry	76
Tab. 13: Parametry vysílaného signálu	79
Tab. 14: Nastavení sítě	103

1 Úvod

Radarové systémy jsou jedním z klíčových prvků moderních sledovacích technologií, které se využívají v mnoha oblastech lidské činnosti. Tyto systémy využívají elektromagnetické vlny k detekci objektů a k určení jejich kinematických a dynamických parametrů (např. poloha, rychlost, zrychlení a další vlastnosti). V praxi se setkáváme s různými druhy radarových systémů, které se dělí na radary aktivní– vysílají vlastní signál a radary pasivní– pracují jen se signály vysílanými či odraženými jinými objekty. K aktivním radarům patří primární a sekundární radary. Primární radary vysílají signál a přijímají jeho odrazy od okolních předmětů [1]. Sekundární radary vysílají kódovaný signál a přijímají pouze odpovědi od objektů, které jsou vybaveny tzv. odpovídačem (transpondérem). Sekundární radary pracují pouze se spolupracujícími objekty. Výhodou těchto radarů je, že z odpovědi od zájmových cílů je získávána celá řada dalších informací [1]. Naproti tomu primární radary se využívají v situacích, kdy je potřeba detekovat také nespolečující zájmové objekty, např. terénní objekty nebo meteorologické útvary, případně objekty protivníka.

Primární radary určují vzdálenost odrazejšího objektu ze zpoždění signálu na dráze vysílač-cíl-přijímač. Směr je určen na základě vlastností antény. Rychlost cíle je stanovena na základě tzv. Dopplerova jevu, který je založen na změně frekvence přijímaného signálu oproti signálu vysílanému způsobeného pohybem cíle.

Cíle jsou charakterizovány zpravidla komplexními tvary, z nichž některé části mohou být pohyblivé (např. vrtule letadla, vrtulníku, dronu, nebo kola pozemních vozidel). Tento „vlastní“ pohyb části cíle způsobí tzv. μ - Dopplerův jev, tj. spektrogram odraženého signálu bude obsahovat kromě (obvykle dominantního) odrazu od trupu, pohybujícího se specifickou rychlostí, ještě odrazy od jeho pohybujících se částí. Tato část spektra se nazývá μ - Dopplerovo spektrum.

Jedním z primárních využití radarů je zabezpečení letecké dopravy a protivzdušné obrany, které vyžadují přehled o pohybu všech objektů (cílů) ve vymezeném vzdušném prostoru (zájmovém prostoru). Díky rostoucí hustotě letového provozu a jeho částečného uvolnění pro neprofesionální uživatele (např. malá soukromá letadla, ultralehká letadla, vírníky nebo soukromé drony), vyžaduje také použití primárních radarů, schopných detekovat tyto, většinou nespolečující objekty.

V posledních letech získávají stále větší význam bezpilotní vzdušné prostředky, známé pod označením UAV, zkratkou anglického názvu Unmanned Aerial Vehicle [2]. Tyto prostředky, často nazývané drony, lze využívat v řadě průmyslových, zemědělských i vědeckých aplikací k získávání přehledu o stavu rozsáhlých objektů, terénu a porostu, o situaci v dopravě i k dopravě předmětů na kratší vzdálenosti

apod. Lze je ovšem využít i k teroristické nebo bojové činnosti, protože jsou schopny provádět operace, které mohou ohrožovat bezpečnost zájmových objektů. Drony mohou sloužit k monitorování citlivých oblastí, shromažďování informací, rušení komunikačních systémů, nebo dokonce přímo ohrožovat fyzickou bezpečnost osob či majetku.

Vlastností primárních radarů, na rozdíl od sekundárních, je taková, že mezi přijatými signály jsou vedle odrazů od zájmových cílů také odrazy od ostatních nezájmových objektů, které vytvářejí takzvaný clutter (pozadí). Tyto odrazy se snažíme potlačit, abychom mohli detekovat cíle zájmové. Které objekty považujeme za zájmové a které za nezájmové ovšem závisí na vymezení funkce konkrétního radaru. Například pro meteorologický radar jsou zájmovými objekty meteorologické útvary jako jsou oblaka, mlha, déšť, sněžení, kroupy, vrstvy vzduchu o různé teplotě, vlhkosti apod. Clutterem jsou pro ně létající objekty jako letadla, vrtulníky, UAV nebo pozemní objekty jako budovy, porosty, nebo pozemní vozidla případně plavidla. Naopak pro radary pro letový provoz nebo protivzdušné ochrany jsou zájmovými objekty všechny uvedené létající objekty, ale i ptáci, kteří mohou ohrožovat letecký provoz v blízkosti letiště. Clutterem jsou pak pro ně všechny pozemní objekty i meteorologické útvary. U pozemních bojišťových radarů by k zájmovým objektům ještě patřila i pozemní vozidla nebo osoby, případně velké pozemní zbraně nebo úkryty protivníka.

Při detekci objektů na dálku a určování jejich polohy mají radary nespornou výhodu před metodou optického pozorování, protože do značné míry nejsou závislé na stavu atmosféry, tedy na počasí. Kromě toho jsou schopny poskytovat přehled o objektech v celém vymezeném prostoru s přijatelnou dobou obnovy informace. Naproti tomu optické systémy s vysokou rozlišovací schopností v úhlech mohou dobře klasifikovat a identifikovat cíle, avšak pro detekci ve větších prostorech se nehodí. Proto se často tyto systémy kombinují, přičemž radary zajišťují detekci a lokalizaci objektů a optický systém pak provádí jejich klasifikaci a případně identifikaci.

V této práci se zaměřuji na detekci a klasifikaci zájmových objektů s rotujícími částmi, nacházejících se jak na zemském povrchu, tak ve vzdušném prostoru pomocí primárních radarů. Pro klasifikaci je zde využita část spektrogramu odraženého signálu poznamenanou μ -Dopplerovým jevem.

1.1 Motivace

S rychlým rozvojem technologie bezpilotních vzdušných prostředků vzniká stále více jejich praktických implementací, což však zároveň představuje potenciální bezpečnostní hrozbu pro letiště a další citlivé oblasti, například v souvislosti s rizikem teroristických útoků. Objevuje se tedy také potřeba ochrany důležitých prostor (např. prostor letiště, elektrárny, vojenská centra atd.) a zařízení před nežádoucím pronikem nebo i přiblížením těchto objektů. Základním prvkem této ochrany je detekce, lokalizace, klasifikace a identifikace takového zájmového objektu. Jak už bylo řečeno v úvodu, radary mají jisté výhody např. před optickými systémy, které je předurčují k detekci a lokalizaci, zatímco optické systémy jsou výrazně úspěšnější v klasifikaci a identifikaci již detekovaných a lokalizovaných objektů. Přesto je podstatně výhodnější, pokud radar může vykonávat alespoň částečnou klasifikaci (třeba i s vyšší pravděpodobností záměny), aby se omezilo zbytečné předávání nezájmových objektů optickému systému ke klasifikaci a následné identifikaci. Tento postup pak poskytne optice větší časový prostor pro práci s užitečnými cíli, a tak pomůže zlepšit kvalitu klasifikace a zvýšit kapacitu celého systému.

S ohledem na výše uvedené hrozby se nabízí myšlenka rozšířit schopnosti stávajících přehledových (přistávacích) radarů, které jsou běžnou součástí letištní infrastruktury, o schopnost detekovat a rozpoznávat bezpilotní prostředky. Tyto radary bývají optimalizovány především pro detekci a sledování klasických pilotovaných letadel, nicméně jejich modernizace nebo doplnění o pokročilé algoritmy zpracování signálu – například analýzu μ -Dopplerova spektra – umožní alespoň částečně rozlišovat malé pohyblivé cíle, jako jsou drony. Díky této integraci lze zajistit základní úroveň klasifikace již na radarové úrovni bez nutnosti masivního zásahu do stávající infrastruktury. Výsledkem je efektivnější využití existujících prostředků, lepší situace v oblasti včasné reakce na potenciální hrozby a zajištění bezpečnosti řízeného vzdušného prostoru.

Vedle rozboru spektrogramu μ -Dopplerova signálu pohyblivých součástí cíle lze pro klasifikaci cílů radarem využít i rozbor trajektorie cíle. Metoda využívající trajektorii vyžaduje podstatně delší časový interval než metoda dopplerovská, a proto je vhodné využít ji spíše k potvrzení prvního odhadu z dopplerovské metody. Všechny výše uvedené důvody představují mou motivaci pro výběr tématu disertační práce věnované zlepšení klasifikačních schopností radarů na základě μ -Dopplerova jevu.

Pro klasifikaci cíle je nutná jeho spolehlivá detekce a poté správné určení jeho polohy. V případě dvou i více blízkých cílů, což je v případě dronů velmi častý případ, je důležité i jejich vzájemné rozlišení. Detekci, klasifikaci a rozlišení dvou blízkých cílů ovlivňuje celá řada faktorů.

- Jedním z nich je výběr vhodné modulační funkce vysílaného signálu. Požadavky na vysílaný signál jsou následující:
 1. Vhodné autokorelační vlastnosti – úzké maximum autokorelační funkce a nízké postranní laloky
 2. Odolnost vůči Dopplerovu posuvu
 3. Konstantní obálka signálu

Typickými příklady nejčastěji používaných modulací jsou takzvané frekvenční modulace – FM a jejich podskupiny lineárních a nelineárních frekvenčních modulací (LFM, NLFM). Oblasti zlepšení vlastností NLFM modulací se v této práci budu dále věnovat.

- Další faktory potom jsou:
 1. Délka vysílaného pulzu
 2. Frekvenční zdvih
 3. Nosná frekvence

1.2 Cíle disertační práce

Cílem disertační práce je vytvoření nových postupů klasifikace zájmových cílů s využitím μ - Dopplerova jevu na základě vytvořených modelů odražených signálů od zájmových objektů a jejich porovnání s experimentálně naměřenými daty.

K dosažení tohoto cíle bylo nutno realizovat následující dílčí cíle:

- Provést analýzu metod odhadu μ - Dopplerova spektra přijatého signálu a vybrat výpočetně optimální metodu s dostatečnou rozlišovací schopností, robustní vůči Dopplerovu posuvu i šumu.
- Vytvořit zjednodušené počítačové modely signálu odraženého od vybraných objektů a ověřit je experimentálně. K tomu, aby bylo možno taková detailní měření provádět, bylo nutno vybrat objekty, které lze měřit v laboratorních podmínkách.
- Vytvořit neuronovou síť, která je schopna porovnat výsledky modelování a měření odražených signálů a vyhodnotit míru jejich shody.

1.3 Originalita řešení a přínosy disertační práce

Za hlavní přínosy své disertační práce považuji:

A) Nalezení nové nelineární frekvenční vnitropulzní modulace vysílaného signálu FLAMENCO (**FLA**t lobes **M**atch**E**d filter **N**onlinear frequen**C**y **m**Odulation) s vhodným tvarem funkce neurčitosti, jejíž autokorelační funkce má velmi plochý průběh postranních laloků s vysokým potlačením. Korelační funkce FLAMENCO je robustní vůči Dopplerově posuvu přijímaného signálu i vůči dodatečné filtraci. To umožňuje velmi kvalitní separaci cílů v prostoru i dopplerovskou filtraci signálů, odražených od blízkých cílů. Tento výsledek práce považuji za originální a zároveň využitelný i u dalších impulzních radarů s vnitropulzní modulací.

Přínosem práce je komplexní porovnání metod odhadu výkonové spektrální hustoty (PSD), zahrnující postupy založené na diskrétní Fourierově transformaci (Bartlettova, Welchova a Blackman-Tukeyho metoda), optimalizované filtraci (ASCE), AR modelech náhodného signálu (Yule-Walkerova, kovarianční, modifikovaná kovarianční a Burgova metoda) a na rozkladu kovarianční matice signálu (MUSIC). Na základě tohoto srovnání byla určena metoda nejlépe vyhovující požadavkům dané aplikace.

B) Vývoj metody umožňující klasifikovat cíle s rotujícími částmi na základě μ -Dopplerova spektrogramu odraženého signálu. Vytvoření modelu odraženého signálu, který umožní generovat odražený signál za různých podmínek (např. různé natočení cíle, trajektorie, poloha atd.) a pro různé metody zpracování přínos A) a následné odhadnutí tvaru jeho výkonového spektra (PSD). Na základě tohoto modelu bude vytvořena knihovna spekter významných zájmových objektů.

C) Na základě vytvořené knihovny spektrogramů byl navržen klasifikační algoritmus založený neuronové síti, který klasifikaci objektu k určité třídě na základě PSD. Funkčnost tohoto postupu jsem ověřil na třech vybraných objektech. Tento krok také považuji za originální.

1.4 Struktura disertační práce

Úvodní část práce (kapitola 1, 2, 3) představuje motivaci a cíle výzkumu, včetně vymezení originality a přínosů zvoleného řešení. V práci jsou popsány současné technologie a systémy pro detekci UAV. V návaznosti na parametry těchto produktů jsou formulovány požadavky na radarové systémy.

V teoretické části (kapitola 4) je vysvětleno zpracování radarových signálů, včetně matematických modelů, které popisují Dopplerovy a μ -Dopplerovy jevy. Další kapitoly se věnují modelům signálů, šíření a odrazu vln, včetně metod spektrální analýzy.

Praktická část (kapitola 5, 6, 7) práce obsahuje popis měřicího řetězce, kde klíčovou roli hraje Software Defined Radio (SDR). Následuje porovnání modelů μ -Dopplerových spekter pro různé objekty, jako je dron, ventilátor a jízdní kolo, s reálnými daty získanými měřeními. V rámci této části jsou uvedeny konkrétní parametry modelů s detailními rozbory výsledků. V kapitole 8 se věnují klasifikaci vybraných objektů podle jejich μ -Dopplerova spektra.

2 Současný stav poznání

V současné době je aktuálním tématem otázka zvýšení úrovně ochrany letového provozu. Klasifikátory používají různé vlastnosti, jimiž se jednotlivé cíle liší a které lze danými prostředky indikovat. U radarů jsou klasifikátory založené obvykle na Dopplerově efektu nebo na sledování dráhy cíle. Rádiové systémy, využívají detekci komunikace mezi UAV a pilotem a k následné klasifikaci provádí rozbor těchto vysílaných signálů. Optické systémy porovnávají sledovaný objekt s obrazy z rozsáhlé knihovny objektů. Každý z těchto systémů disponuje určitými výhodami a nevýhodami.

Pro jejich detekci lze použít odlišné technologie. Jedná se o:

- Rádiové systémy

Velmi často používanou skupinou klasifikátorů jsou systémy založené na „odposlechu“ rádiové komunikace. Jedná se o velmi jednoduché a levné systémy, které naslouchají rádiové komunikaci mezi UAV a operátorem. Díky tomuto je možné velmi snadno detekovat a klasifikovat takovýto cíl. Problém nastává ve chvíli, kdy cíl operuje v takzvaném "rádiovém klidu" na základě naprogramování trasy letu dopředu a vyslání cíle, bez intervence operátora. Tento systém rovněž není schopný, ze zřejmých důvodů, detekovat ptactvo.

- Radarové systémy

Radarové systémy, jakožto podskupina rádiových systémů, založené na dopplerovském klasifikátoru. Jejich výhoda je taková, že je můžeme použít i za zhoršených meteorologických podmínek (např. zhoršená viditelnost). Primární nevýhodou tohoto způsobu klasifikace zájmového objektu je nutnost dobré odrazivosti cíle. μ - Dopplerovy jevy (detailněji popsány v kapitole 2.5) mohou být v případech s nízkou odrazivostí vrtulí detekovatelné jen na krátkou vzdálenost. V tomto případě klasifikace cíle také nebývá tak detailní, jako při optické metodě.

- Optické systémy

Výhoda optického systému spočívá v tom, že za příznivých meteorologických podmínek je možné zájmové cíle klasifikovat s vysokou úspěšností. Toto je možné považovat za hlavní přínos optických klasifikačních systémů. Nevýhodou tohoto přístupu je obtížnost lokalizace cíle ve velkém rozsahu úhlů. Překážkou je také špatná viditelnost, například mlha nebo déšť.

- Akustické systémy

Akustické klasifikační systémy pro detekci dronů a UAV dokážou pracovat pasivně, často nabízejí 360° pokrytí a lze je snadno integrovat do stávajících řešení. Jejich hlavní nevýhodou je však omezený dosah a velká závislost na okolním prostředí, což

platí především pro hlučné městské aglomerace nebo nepříznivé meteorologické podmínky. Dalším problémem je možnost falešných poplachů způsobených zdroji zvuku podobnými rotoru dronů a obtížná identifikace konkrétních typů UAV bez rozsáhlé databáze akustických signatur.

2.1 Příklady komerčně úspěšných řešení

Níže jsou vybrány příklady úspěšných komerčních řešení nastíněných v kapitolách 2.1.1, 2.1.2, 2.1.3 a 2.1.4.

2.1.1 Radarový systém – ELVIRA®

ELVIRA® je radarový systém vyvinutý společností Robin Radar. Hlavním účelem tohoto systému je detekce a sledování dronů. Systém je koncipován pro použití v městském prostředí plném překážek, pohybujících se objektů a velkého množství rušivých bezdrátových rádiových zařízení [3]. Základní parametry tohoto systému jsou uvedeny v Tab. 1.

Tab. 1: Parametry systému ELVIRA

Parametr	Hodnota	Jednotka
Druh modulace	FMCW	-
Frekvenční pásmo	8700 – 9650	MHz
Vysílací výkon	4	W
Krytí v azimutu	360	°
Rozlišení v dálce	0.6	m
Dosah	5000	m

Ukázka takového systému je na Obr. 1.



Obr. 1: Radarový systém – ELVIRA

2.1.2 Rádiový systém – ZDTECH

Jedná se o integrovaný systém pro detekci UAV. Tento systém využívá pasivní, rádiovou technologii. Pokrytí v azimutu je 360° a v elevaci 90° s detekčním dosahem až 3 000 m. Provozní frekvenční pásmo tohoto systému je v rozsahu (300 MHz – 6 000 MHz), včetně komunikačních pásem 2.4 GHz, 5.8 GHz, 800 MHz a 900 MHz [4]. Základní parametry tohoto systému jsou v Tab. 2.

Tab. 2: Parametry systému ZDTECH

Parametr	Hodnota	Jednotka
Druh modulace	FMCW	-
Frekvenční pásmo	300 – 6000	MHz
Krytí v azimutu	360	°
Krytí v elevaci	90	°
Rychlost frekvenčního skenu	480	MHz · s ⁻¹
Dosah	3000	m

Ukázka takového systému je na Obr. 2.



Obr. 2: Rádiový systém – ZDTECH

2.1.3 Optický systém SPEED-MR

SPEED-MR je optický systém pro dlouhodobé a velmi vzdálené pozorování. Nabízí panoramatické skenování a volitelnou detekci pohyblivých cílů, a to až do vzdálenosti 25 km [5]. Základní parametry tohoto systému jsou v Tab. 3.

Tab. 3: Parametry systém SPEED-MR

Parametr	Hodnota	Jednotka
Maximální dosah	25000	m
Krytí v azimutu	360	°
Krytí v elevaci	90	°
Infračervené spektrum	0.9–1.7	μm
Zorné pole – široké	63 x 48	°
Zorné pole – úzké	2.3 x 1.8	°
Laserový zaměřovač	ANO	–

Ukázka takového systému je na Obr. 3.



Obr. 3: Optický systém SPEED-MR

2.1.4 Akustický systém CTRL+SKY

Akustický systém CTRL+SKY od společnosti TerraHexen, lokalizuje zdroje zvuku v trojrozměrném prostoru, aniž by vyžadoval přímou viditelnost. Je schopen klasifikovat objekty, například rozlišovat mezi drony a jinými zdroji zvuku. [6]. Základní parametry tohoto systému jsou v Tab. 4.

Tab. 4: Parametry systému CTRL+SKY

Parametr	Hodnota	Jednotka
Maximální dosah	200	m
Počet mikrofonů	8	–
Lokalizace v elevaci – 3D	ANO	–
Klasifikace UAV	ANO	–
Detekce bez přímé viditelnosti	ANO	–

Ukázka takového systému je na Obr. 4



Obr. 4: Akustický systém CTRL+SKY

2.2 Úvod do měření signálu pro impulsní a FMCW radary

V této kapitole je uveden popis principu měření přijatého signálu pro dva nejrozšířenější typy radarových systémů, a to impulsních a FMCW. Nejprve představím základní funkční principy obou metod a poukážu na klíčové rozdíly mezi nimi. Přestože se budu věnovat oběma přístupům, stěžejní část zbytku této práce bude zaměřena především na systémy impulsní.

2.2.1 Impulsní radary

Impulsní radary vysílají impulsní signál, pomocí kterého měří vzdálenost k cíli na základě časového zpoždění mezi vysláním a příjmem odrazu. Pro sledování μ -Dopplerova jevu je nutné, aby byl takovýto radar nakonfigurován s dostatečně vysokou opakovací frekvencí pulzů (PRF). Dostatečně vysoká PRF je nutná k zajištění jednoznačnosti měření kmitočtu μ -Dopplerových jevů.

Hlavní požadavky na impulsní radary ve vztahu k μ -Dopplerovým jevům:

- **Rozlišení v dálce:** Je dáno šířkou pásma B :

$$\Delta R = \frac{c}{2 \cdot B} \quad (1)$$

U radarů, které nepoužívají vnitropulzní modulaci je rozlišovací schopnost v dálce svázána se šířkou pulzu τ a platí:

$$\Delta R = \frac{c\tau}{2} \quad (2)$$

- **Rozlišení v Dopplerově kmitočtu:** Je závislé na délce koherentního intervalu (CPI – Coherent Processing Interval). Nejmenší rozlišitelná dopplerovská frekvence je přibližně rovna $1/CPI$. Rozlišení v rychlosti je pak dáno:

$$\Delta v \approx \frac{\lambda}{2 \cdot CPI} \quad (3)$$

2.2.2 FMCW radary

Pro rozlišovací schopnosti v dálce i v rychlosti platí stejné vztahy (1) a (3) jako u impulsních radarů. FMCW radary vysílají kontinuální signál, jehož frekvence se postupně mění (tzv. „chirp“). Díky vysílání trvalého signálu potřebují pro stejný dosah nižší okamžitý výkon než radary impulsní. Rozdíl mezi frekvencí vysílaného a přijímaného signálu nese informaci jak o vzdálenosti, tak o rychlosti cíle. FMCW systémy pak vyhodnocují pouze tuto rozdílovou (relativně nízkou) frekvenci, tzv. „beat frequency“, z níž lze následnými časově-frekvenčními transformacemi zjišťovat také Dopplerovské spektrum odraženého signálu. Celková šířka pásma B může být velká, díky rozmítání frekvence, takže tyto radary mohou dosáhnout velmi

dobrého rozlišení v dálce. Rozlišení v rychlosti je omezeno dobou vymezenou na sledování cílů v jedné úhlové rozlišovací buňce.

Hlavní požadavky na FMCW radary ve vztahu k μ -Dopplerovým jevům:

- **Rozlišení v dálce:** Je definováno frekvenčním zdvihem chirpu B , dáno rovnicí (1).
- **Rozlišení v Dopplerově kmitočtu:** Je závislé na počtu chirpů N_c a délce jednoho chirpu τ_c . Rozlišení v rychlosti a v Doppleru je pak dáno:

$$v \approx \frac{\lambda}{2 \cdot N_c \tau_c} \text{ a } f_D = \frac{1}{N_c \tau_c} \quad (4)$$

2.2.3 Shrnutí požadavků, výhod, nevýhod impulsních a FMCW systémů

V této kapitole jsou porovnány vybrané typy radarových systémů z hlediska jejich schopnosti detekovat a analyzovat μ -Dopplerovy jevy. Zaměření je především na rozdíly mezi impulsními a FMCW radary, jejich výhody a nevýhody ve vztahu k této problematice. Impulsní radary se vyznačují vysokým špičkovým výkonem, který usnadňuje detekci μ -Dopplerových jevů na velkou vzdálenost. Jejich nevýhodou je však omezená frekvence opakování pulzů (PRF), která v závislosti na charakteru pozorovaného cíle může vést k nedostatečnému vzorkování μ -Dopplerových jevů ve spektrogramu a tím i k výskytu aliasingu. Naproti tomu citlivost FMCW (a obecně všech CW) radarů trpí přeslechy z vysílače do přijímače, jejichž postranní laloky mohou maskovat slabé (vzdálené) cíle. Proto mají CW radary obecně malý dosah (maximálně 10 až 20 km), bez ohledu na vysílaný výkon. To umožňuje použít vysoký opakovací kmitočet s nímž lze dosáhnout širokého pásma Dopplerových kmitočtů. K potlačení vzdálených silných cílů se u FMCW radarů obvykle používá střídání strmosti modulace kmitočtu v následujících odbězích (chirpech).

2.3 Zpracování signálu a metodika analýzy μ -Dopplerova jevu

V průběhu posledních dvou desetiletí vzniklo rozsáhlé spektrum studií zaměřených na různé oblasti spojené s μ -Dopplerovými jevy, včetně teoretických základů [7], [8], návrhu a optimalizace radarových systémů [9]–[11], metodik zpracování dat pro klasifikaci cílů [12],[13], potlačování rušení a clutteru [14], a kognitivních přístupů k adaptaci celého procesu v reálném čase [15].

2.3.1 Návrh radarového systému a sběr dat

Návrh radarového systému zahrnuje volbu mezi impulsním a FMCW režimem, přičemž je třeba zohlednit požadavky na rozlišení, frekvenční pásmo a energetické požadavky. Důležité je nastavení parametrů, jako je opakovací frekvence impulzů a rychlost chirpu, které umožňují detekci rychlých změn v pohybu, jež vytvářejí

μ - Dopplerovy jevy. Sběr dat musí být systematický, přičemž zahrnuje výběr měřených objektů, kalibraci radarového systému, záznam a archivaci dat, stejně jako dokumentaci a metadata, které jsou klíčové pro následnou analýzu.

2.3.2 Časově-frekvenční reprezentace a transformace signálu

Transformace přijímaného signálu do časově-frekvenční oblasti je klíčová pro analýzu μ - Dopplerova jevu. Nejčastěji se používá STFT (Short Time Fourier Transform), která poskytuje spektrogram ukazující vývoj frekvenčních komponent v čase. Avšak pevná velikost okna u STFT omezuje rozlišení buď v čase nebo ve frekvenci. Pro lepší rozlišení se využívají pokročilejší metody, jako jsou Bartlettova metoda, Welchova metoda a Blackman-Tukyeova metoda. Dále jsou dostupné pokročilé metody založené na odhadu spektra složeného z harmonických funkcí, jako je ASCE, autoregresivní metody a metody využívající rozkladu kovarianční matice (jako např. MUSIC[16], [17]).

2.3.3 Potlačení rušení, clutteru a šumu

V reálných podmínkách je nutné počítat s rušením z více zdrojů a s nežádoucími odrazy (clutter). Speciální postupy, například histogramová analýza v časově – frekvenční oblasti či adaptivní prahování, pomáhají oddělit užitečné μ - Dopplerovy složky. Kognitivní radarové přístupy navíc umožňují upravit parametry vysílaného signálu pro optimalizaci poměru signál-šum v přítomnosti dynamického rušení [18], [19].

2.3.4 Extrakce příznaků a klasifikace

Po získání spektrogramu je klíčová extrakce příznaků, jako je šířka postranních pásem, periodičita, amplitudová modulace a energetické rozložení v čase a frekvenci. Tyto příznaky se následně používají v klasifikačních modelech, které mohou být od tradičních metod, jako je SVM (Support Vector Machine), až po pokročilé modely hlubokého učení. Schopnost odlišit jemné rozdíly v μ - Doppleru zvyšuje úspěšnost rozlišení cílů, jako jsou lidé, rotory nebo pozemní vozidla [20]–[22].

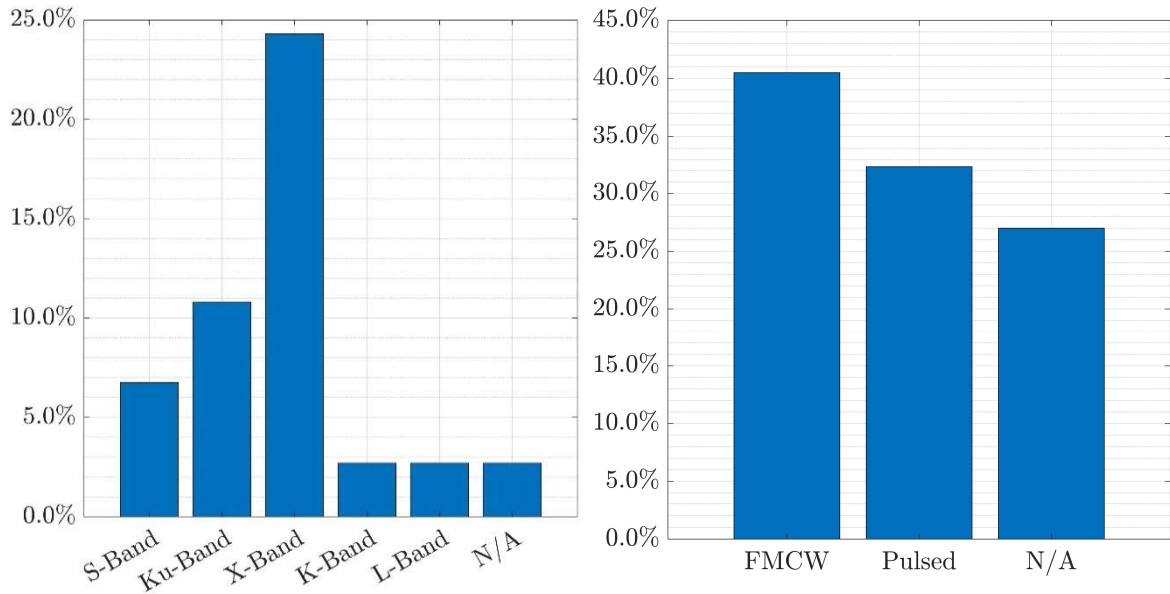
2.3.5 Kognitivní optimalizace a iterace

Kognitivní přístupy umožňují iterativně upravit parametry radarového vysílání na základě zpětné vazby ze signálového zpracování reálného radarového systému. Tato adaptivní optimalizace maximalizuje citlivost radarového systému a zároveň minimalizuje energetické nároky či vliv rušení od ostatních systémů [23]–[28].


2.4 Podrobná rešerše současných radarových systémů

Tato kapitola obsahuje rešerši a následnou analýzu zdrojů věnující se pulsním radarovým systémům z pohledu používaných technologií z veřejně dostupných

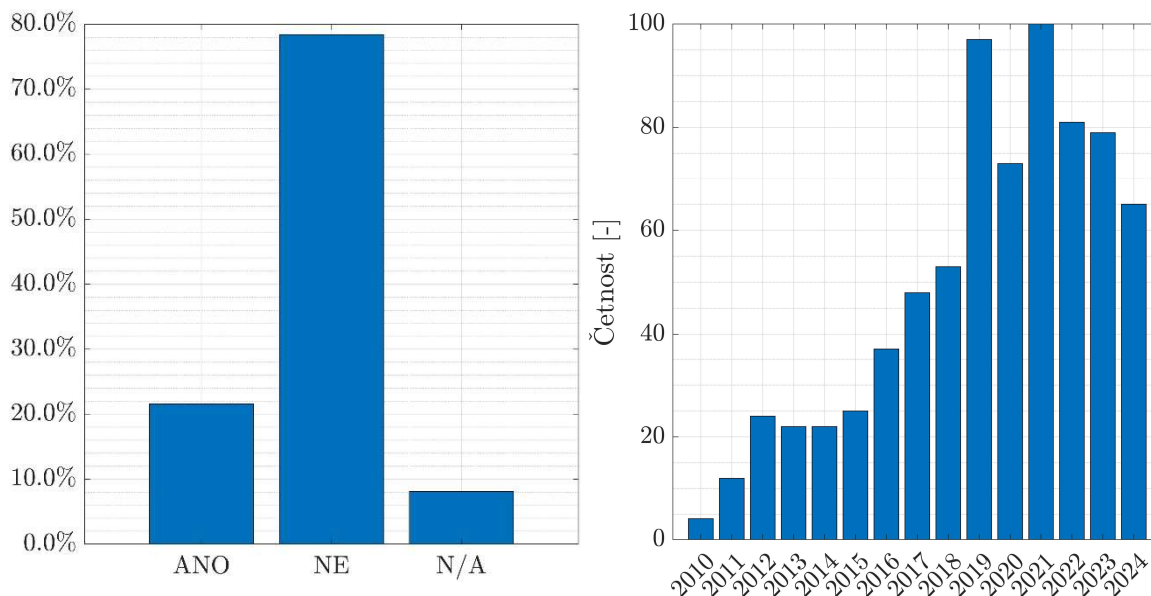
zdrojů. Na základě veřejně dostupných informací jsem vypracoval podrobnou rešerši parametrů těchto systémů. Celkem bylo porovnáno 37 různých radarových systémů od různých výrobců z celého světa. Zaměřil jsem se na následující parametry: Kmitočtové pásmo, druh modulace, μ - Dopplerovo zpracování signálu, typ antény a podpora optickým systémem. Dále jsem provedl rešerši četnosti vydaných publikací v letech 2010–2024, které obsahovaly následující klíčová slova: *micro*, *Doppler*, *classification*, *radar* [29]. Výsledky těchto rešerší jsou ukázány na obrázcích 5, 6 a 7.



Obr. 5: Četnost kmitočtových pásem (vlevo), četnosti použitých modulací (vpravo)



Obr. 6: Četnost μ -Dopplerovského zpracování (vlevo), typ antény (vpravo)



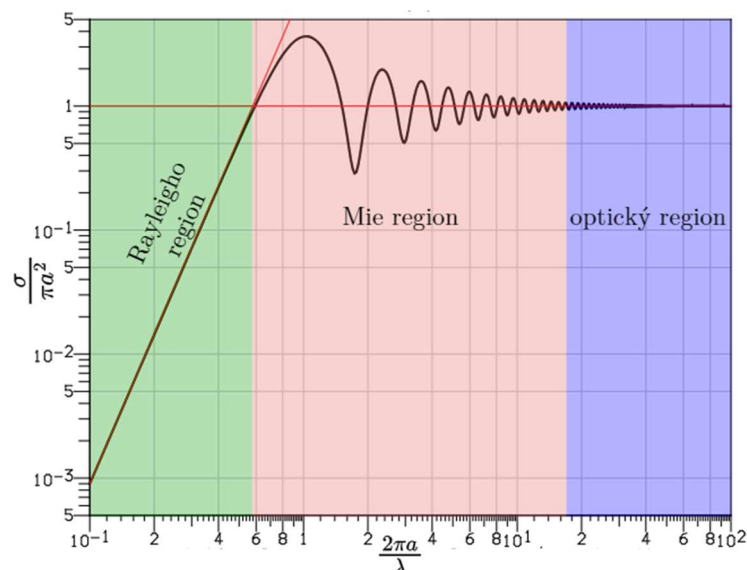
Obr. 7: Četnost optických systémů(vlevo), četnost publikací IEEE (vpravo)

Jak bylo ukázáno, většina výrobců se pohybuje s vysílacími kmitočty v pásmu X, případně v pásmu Ku. Vysoké nosné kmitočty zajišťují dobré rozlišení v dálce i v úhlu a tím i dobrou separaci zájmového objektu od okolního clutteru. Co se týče druhu modulace, tak zde převládá FMCW. Nicméně rozdíl mezi četností FMCW a pulzními systémy je 8 %. Je třeba podotknout, že tuto informaci výrobci často neuvádějí, toto je v grafech označeno jako N/A (Not/Available). V případě využití μ - Dopplerova zpracování signálu je dobře viditelný trend, kde převážná většina výrobců skutečně využívá tohoto jevu s téměř 60 % zastoupením. Z hlediska typologie anténních systémů je patrná převaha řešení s elektronickým vychylováním svazku (AESA). Poslední informací, na kterou jsem se zaměřil, byla doprovodná informace z optických senzorů. Zde téměř 80 % většina výrobců v současné době tuto schopnost nepodporuje ve svých systémech.

2.5 Shrnutí požadavků na radarové systémy

Podle radarové rovnice (16) klesá přijatý výkon odraženého signálu s kvadrátem vlnové délky. Aby byl radar schopný detekovat cíl na dostatečnou vzdálenost, je třeba tuto ztrátu kompenzovat. Toto se obvykle zajistí dostatečným vysílacím výkonem, případně ziskem antén. Snížením nosné frekvence jsme schopni dosah také zvýšit, ovšem cenou za to je snížení rozlišení v Dopplerově frekvenci. Tento závěr vyplývá z rovnice (13), kde je velikost Dopplerova posuvu přímo úměrná frekvenci nosné vlny f_0 . Vlnová délka nosné vlny má ještě další dopad na velikost odrazů. Pokud je vlnová délka podstatně větší, než rozměry odražejícího objektu (pro μ - Dopplerovy jevy to jsou listy vrtule), je jeho efektivní odrazná plocha velmi malá. Naopak, pokud jsou rozměry odražejícího objektu velké vůči vlnové délce

(tzv. optická oblast), blíží se efektivní odrazná plocha na mikrovlnných kmitočtech fyzickému průřezu objektu. Celou tuto závislost pro vodivou kouli vidíme na Obr. 8, [30].



Obr. 8: Odraz od vodivé koule – Raylei-Mie diagram

Pro dostatečně intenzivní odraz od takovéto části objektu je zapotřebí používat vlnovou délku podstatně kratší, než jsou její rozměry. V běžné praxi se setkáváme s délkami listů vrtulí UAV řádově v jednotkách, až desítkách cm. Z tohoto plynou jisté kompromisy pro volbu nosného kmitočtu. Na jednu stranu je potřeba mít nosný kmitočet vyslané vlny co nejvyšší, aby byla velká efektivní odrazná plocha listů vrtule i kvůli dobrému rozpoznání μ - Dopplerových jevů. Na druhé straně vysoký kmitočet (krátká vlnová délka) vyžaduje vyšší vysílaný výkon (16), který je omezen technologickými možnostmi výkonových zesilovačů. V době, kdy je tato práce vytvářena, je technologické optimum v pásmu X (v okolí 10 GHz). Toto tvrzení je podloženo rešerší současných výrobků. Většina těchto produktů se pohybuje právě v pásmu X. Na základě tohoto rozboru budu v této práci dále uvažovat kmitočtové pásmo X.

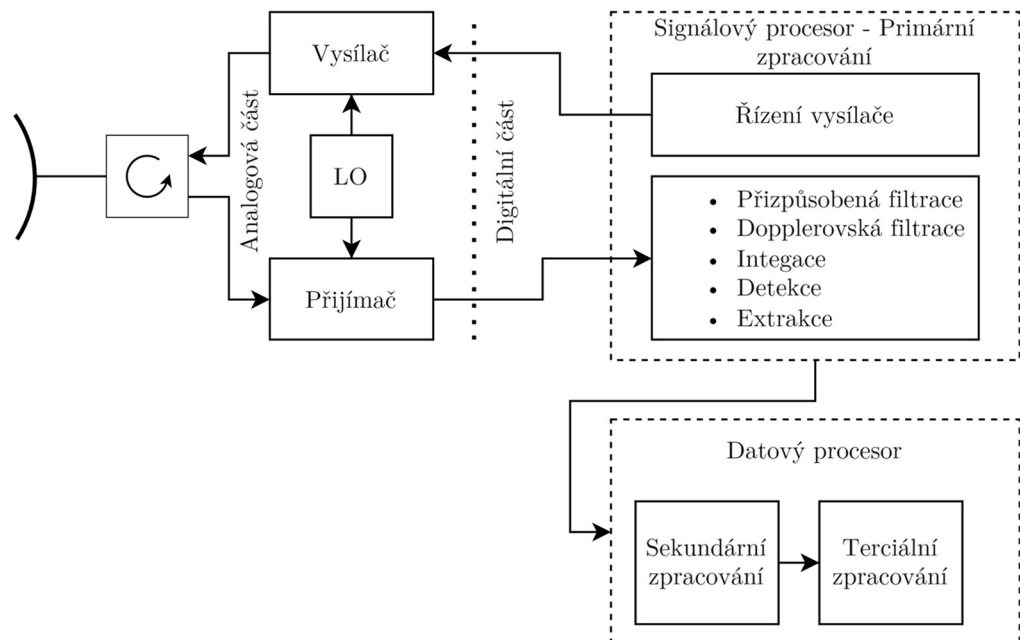
3 Úvod do problematiky primárních radarových systémů

Primární radary představují jednu ze základních technologií pro detekci a sledování objektů v zájmovém prostoru. Princip jejich fungování spočívá v tom, že vysílají elektromagnetické impulzy, které se po odrazu od objektu vrací zpět k anténě radaru. Z doby návratu signálu a jeho změn lze určit vzdálenost a rychlost.

Pro účely leteckého provozu se primární radary často používají k monitorování polohy letadel v okolí letišť a ke sledování neznámých nebo vojenských cílů. Mezi klíčové vlastnosti primárních radarových systémů patří schopnost odhalit objekt i tehdy, když nekomunikuje a není opatřen žádným elektronickým zařízením pro identifikaci [31].

3.1 Popis RS z pohledu signálového zpracování

Signálové zpracování radarového systému lze podle funkce rozdělit na tři hlavní části – primární, sekundární a terciární, přičemž z pohledu způsobu zpracování signálu obvykle rozlišujeme dvě základní kategorie: analogovou a digitální. Přesná hranice mezi těmito kategoriemi však může záviset na konkrétních technologiích a specifických požadavcích daného radarového systému. Ukázka příkladu signálového zpracování je na Obr. 9, [32].



Obr. 9: Blokové schéma signálového zpracování

3.1.1 Primární zpracování

Primární zpracování provádí operace na signálu, přijatém v průběhu jedné otáčky radarové antény. Přitom se nepracuje s vlastním signálem, ale s jeho komplexní obálkou. Např. vysílaný signál lze pomocí komplexní obálky vyjádřit takto:

$$s(t) = \text{Re}\{x(t) \cdot e^{(j2\pi f_0 t)}\} \quad (5)$$

kde,

$x(t)$ – je komplexní obálka vysílaného signálu,

$s(t)$ – je reálný vysílaný signál.

V přijímači se přijímaný signál transformuje na komplexní obálku přijímaného signálu $y(t)$, s níž se v signálovém procesoru provádějí operace, uvedené na Obr. 9. Prvním krokem je přizpůsobená filtrace, který lze popsat vztahem (6). Protože je signál v našem případě diskretizovaný, budu uvádět vztahy pro diskrétní čas:

$$u_{yx}[n] = \sum_{k=1}^K y[n-k+1] \cdot x^*[K-k+1] \quad (6)$$

kde,

$u_{yx}[n]$ – je n -tý vzorek výstupního signálu přizpůsobeného filtru,

$y[n]$ – je n -tý vzorek komplexní obálky přijímaného signálu,

$x^*[k]$ – je k -tý vzorek komplexní obálky vysílaného signálu,

n – je pořadí vzorku, vstupujícího do kompresního filtru,

k – je pořadí vzorku v komplexní obálce vysílaného signálu,

K – je počet vzorků v komplexní obálce vysílaného signálu.

Při tomto procesu jsou přijaté vzorky signálu korelovány s replikou vyslaného signálu. Pokud je přijatý signál zpožděnou a zeslabenou replikou vyslaného signálu, bude výsledkem signál s průběhem zpožděné autokorelační funkce. Přitom se zvyšuje SNR (Signal to Noise Ratio – poměr výkonu signálu k výkonu šumu).

Druhým krokem primárního zpracování je dopplerovská filtrace. Dopplerovská filtrace využívá změny fáze odraženého signálu mezi jednotlivými přijatými impulzy k selekci (filtraci) cílů podle jejich radiální rychlosti. Používají se hlavně filtry: MTI (Moving Target Identification), které potlačují odrazy od nepohybujících se objektů, AMTI (Adaptive MTI), potlačující odrazy od nepohyblivých a pomalu se pohybujících cílů, jako jsou meteóutvary a MTD (Movig Target Detection) filtry, které separují cíle, pohybující se různými rychlostmi. [31], [32].

Za dobu ozáření cíle svazkem (dwell time) přijme přijímač několik odrazů vysílaných impulzů od stejného, takže i na výstupech Dopplerových filtrů bude jednomu cíli vždy odpovídat určitý počet impulzů. Tyto impulzy se pak zpravidla ještě integrují pro zvýšení odstupů signálu od šumu (SNR). Z praxe známe několik druhů integrací a za ty nejpoužívanější se považují: koherentní integrace, video integrace a binární integrace. Principem integrace je sčítání impulzů v určitém intervalu. U koherentní integrace je to jen v intervalu koherence (CPI), u ostatních typů to může být i v celé době ozáření cíle (dwell time).

Následujícím krokem je detekce signálu. Smyslem detekce je rozhodnutí o přítomnosti signálu (cíle) nebo pouze šumu v každé rozlišovací buňce. Jeden z nejnámějších algoritmů detekce je takzvaný CFAR (Constant False Alarm Rate), případně jeho další variace (Cell Averaging – CA-CFAR, Ordered Statistics OSCFAR, Greatest Of GO-CFAR, atd.). [31], [33]

Posledním krokem primárního zpracování je extrakce souřadnic signálu. Detekovaný signál se může nacházet ve více rozlišovacích buňkách současně. U bodových cílů se obvykle vypočte poloha těžiště oblasti detekcí. Toto se provádí v extraktoru. [31], [34]

3.1.2 Sekundární zpracování


Účelem sekundárního zpracování (sledování cíle) je především zpřesňování trajektorie cíle v okamžicích jeho detekce při každé otáčce antény. Součástí tohoto zpracování, je predikce polohy cíle před následující detekcí, což umožňuje odhadnout polohu cíle i v případě ojedinělých výpadků jeho detekce. K určení predikovaných poloh se obvykle využívají různé formy Kálmánova filtru.

3.1.3 Terciální zpracování

Dalším krokem je terciální zpracování, známé také pod anglickým názvem multiradar tracker. Cílem tohoto zpracování je sloučení informací z více radarových stanic do jednoho zobrazovacího systému. Tyto informace využívá například řízení letového provozu ke spolehlivému monitorování vzdušného prostoru. [35]

3.2 Popis parametrů primárního radaru

Primární RS mají za úkol detekovat a sledovat pohyb všech spolupracujících/nespolupracujících cílů ve svém operačním rozsahu Obr. 10.



Obr. 10: Typy cílů v radarovém prostředí

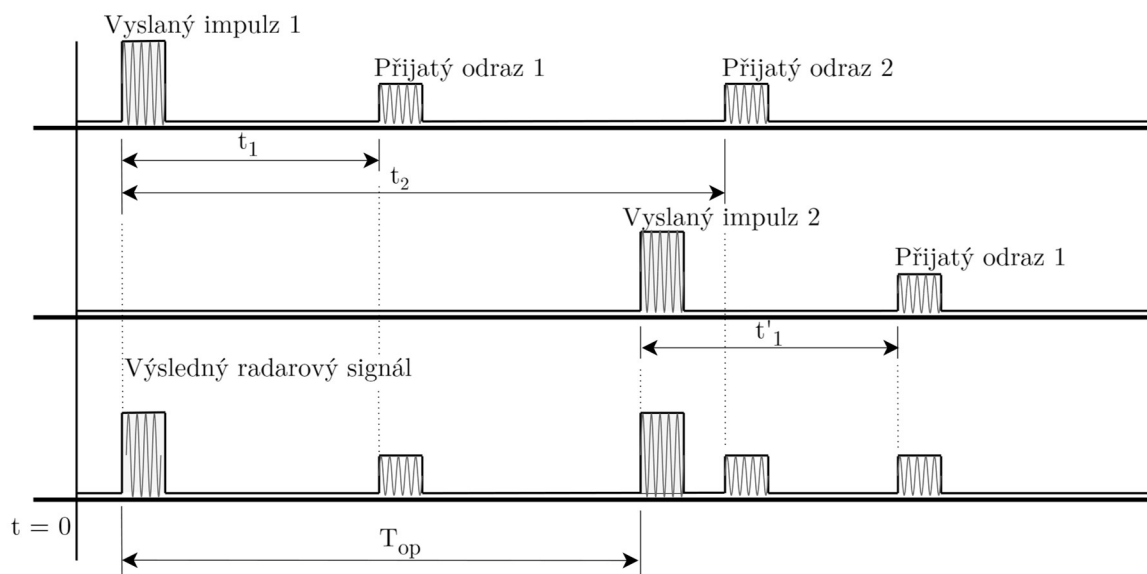
Účelem radaru je schopnost určení vzdálenosti a rychlosti zájmových objektů. Toto probíhá pomocí měření zpoždění mezi vyslaným signálem a přijatým odrazem. Většina dnešních radarů dlouhého dosahu pracuje v impulzním režimu, jinými slovy řečeno, radar v jednom okamžiku vyšle elektromagnetickou vlnu, a pak přijímá odrazy této vlny od jednotlivých objektů.

Vzdálenost objektu R_k se pak pomocí rychlosti světla c vypočte:

$$R_k = \frac{c}{2} t_k; k = 1, 2, 3, \dots \quad (7)$$

kde,

t_k – je doba šíření vlny ke k -tému cíli.



Obr. 11: Ukázka měření šikmé dálky

Z naměřených hodnot vzdáleností $R(t_k), R(t'_k)$ stejného objektu v časových okamžicích t_k a t'_k je možné vypočítat i radiální rychlost objektu vůči radaru podle vztahu (8), Obr. 11.

$$v_r = \frac{R(t_1) - R(t'_1)}{t_1 - t'_1} \quad (8)$$

Při tomto postupu je však nutnost použít velmi dlouhý interval $|t_1 - t'_1|$ mezi měřeními, aby se dosáhlo dostatečné přesnosti. Jestliže totiž uděláme při měření vzdálenosti chybu δR a při měření časů chybu δt , bude chyba určení radiální rychlosti δv_r rovna přibližně:

$$\delta v_r = \frac{R(t_1) - R(t'_1) + \delta R}{t_1 - t'_1 + \delta t} - v_r \cong \frac{\delta R}{t_1 - t'_1} - v_r \frac{\delta t}{t_1 - t'_1} = \frac{\delta R - v_r \delta t}{t_1 - t'_1} \quad (9)$$

Jestliže použijeme následující běžné hodnoty veličin u přehledových radarů:

$$|\delta R| = 50 \text{ [m]}; |v_r| = 200 \text{ [ms}^{-1}\text{]}; |\delta t| = 10^{-7} \text{ [s]}, \text{ pak } |\delta v_r| \geq \frac{50 - 2 \cdot 10^{-5}}{|t_1 - t'_1|} \quad (10)$$


Pokud chceme touto metodou měřit rychlost s chybou menší než např. 50 km/h (13,5 m/s), je zapotřebí volit časový interval $|t_1 - t'_1| \geq 3,7$ s, což vylučuje měření během jedné otáčky antény [36].

Další možností měření rychlosti je využít Dopplerova jevu. Dopplerův jev se projevuje změnou frekvence vlnění vysílaného nebo odraženého nějakým objektem, který se pohybuje vůči pozorovateli. Zde se budeme zabývat pouze signály, které jsou přenášeny elektromagnetickými vlnami, jejichž rychlost šíření ve vakuu je konstantní:

$$c = \frac{1}{\sqrt{\epsilon_0 \mu_0}} \quad (11)$$

kde:

- ϵ_0 – je permitivita vakua,
- μ_0 – je permeabilita vakua,
- c – je rychlost světla ve vakuu.



Obr. 12: Vysílač A, přijímač C a odrážející objekt B (vpravo).

U radarů většinou přijímáme odražený signál v místě vysílání, situace je zobrazena na Obr. 12. Dráha, kterou musí urazit vyslaný signál přes odraz na objektu B k přijímači C je nyní rovna $R_1 + R_2$, a proto bude platit:

$$\Psi = \Psi_0 + \omega_0 \left(t - \frac{R_1 + R_2}{c} \right); \quad f_d = -f_0 \frac{d(R_1 + R_2)}{c \cdot dt} \quad (12)$$

Pro monostatické radary, jejichž vysílač i přijímač jsou ve stejném místě, platí: $R_1 = R_2 \equiv R$ a potom pro Dopplerův posun dostaneme vztah:

$$f_d = -2f_0 \frac{dR}{c \cdot dt} = -2f_0 \frac{v_r}{c}; \quad v_r = \frac{dR}{dt} \quad (13)$$

kde:

v_r – je radiální rychlost, která reprezentuje rychlost změny vzdálenosti R mezi radarem a odrážejícím předmětem.

Znaménko mínus ve vztahu (13) pro Dopplerův posun znamená, že pokud se odrážející objekt vzdaluje od radaru tedy $\frac{dR}{dt} > 0$, je Dopplerův posuv f_d záporný a naopak.

Velikost Dopplerova posuvu f_d závisí na kmitočtu nosné vlny f_0 a na poměru rychlostí $\frac{v_r}{c}$. Například při rychlosti $100 \text{ km/h} = 27,8 \text{ m/s}$ je tento poměr roven $9,25 \cdot 10^{-8}$. Na kmitočtu 1 GHz tedy taková radiální rychlost způsobí posuv kmitočtu odraženého signálu o $f_d = 92,5 \text{ Hz}$. Velmi nízká hodnota poměru rychlostí $\frac{v_r}{c}$ způsobuje, že Dopplerův posuv je podstatně menší než kmitočet vysílaného signálu, což značně komplikuje separaci Dopplerovského spektra z celkového spektra signálu.

Pokud se odrážející objekt skládá z N částí, které se samostatně pohybují a tyto části lze chápat jako samostatné bodové odražeče, bude se celkový odražený signál $s(t, R)$ rovnat součtu dílčích odrazů:

$$s(t, R) = \sum_{n=1}^N s_n(t, R_n) = e^{j\omega_0 t} \sum_{n=1}^N u_n(R_n) \cdot e^{j(\Psi_{0n} - \omega_0 \frac{R_n}{c})} \quad (14)$$

$$s(t, R) = A(t) e^{j\omega_0 t} e^{j\Psi_1(t)}; \quad f_d(t) = \frac{1}{2\pi} \frac{d\Psi_1(t)}{dt}$$

kde:

- R_n – je vzdálenost n -té části odrážejícího objektu,
- $s_n(t, R_n)$ – je signál odražený od n -té části objektu,
- $u_n(R_n)$ – je absolutní hodnota komplexní obálky signálu $s_n(t, R_n)$,
- $A(t)$ – je absolutní hodnota komplexní obálky celkového odraženého signálu,
- $\Psi_1(t)$ – je okamžitá fáze komplexní obálky celkového odraženého signálu.

Při tomto přístupu sice zanedbáváme vzájemné odrazy mezi jednotlivými částmi objektu, ale protože amplituda signálu s každým dalším odrazem klesá, vede obvykle tento model k dobře použitelným výsledkům.

Ve většině případů se objekt skládá z nějakého většího počtu částí (trup letadla, karoserie auta, stožár větrné elektrárny atd.). Tyto části se pohybují vůči radaru v daném okamžiku rychlostí v_r . Dále se tyto objekty mohou skládat z částí, které se vůči tomuto tělesu pohybují odlišnými pohyby (listy vrtule, kola vozidel atd.). Obvykle je vhodné rozdělit vliv celkového pohybu na spektrum Dopplerova posuvu ω_{r0} v důsledku radiální rychlosti v_r a na ostatní vlivy, které zahrnujeme pod název mikro- Dopplerův (μ - Dopplerův) jev:

$$s(t, R) = A(t) e^{j\omega_0 t} e^{j\omega_{r0} t} e^{j\Psi_2(t)}; \quad \omega_{r0} = -2\omega_0 \frac{v_r}{c}; \quad \Psi_2(t) = \Psi_1(t) - \omega_{r0} t \quad (15)$$

kde:

- $\Psi_2(t)$ – je fáze komplexní obálky signálu, odpovídající μ - Dopplerovu efektu.

3.3 Radarová rovnice

Radarová rovnice primárního radaru popisuje výkon přijatého signálu na vstupu přijímače odraženého od zájmového objektu.

$$P_p = P_v G_v G_p \frac{f_v^2(\theta, \varphi) f_p^2(\theta, \varphi) \sigma(-\theta, -\varphi) \lambda^2}{(4\pi)^3 R^4 L^2(R)} \quad (16)$$

kde,

P_p – je přijatý výkon,

G_v, G_p – jsou zisky vysílací a přijímací antény,

$f_v^2(\theta, \varphi)$ – je anténní charakteristika vysílací antény,

$f_p^2(\theta, \varphi)$ – je anténní charakteristika přijímací antény,

$\sigma(-\theta, -\varphi)$ – je efektivní odrazná plocha odrážejícího objektu ve směru k radaru,

λ – je vlnová délka,

R – je šikmá délka k sledovanému cíli,

L – jsou ztráty (atmosférické, kabely, vlnovody, zpracování).

potlačení postranních laloků SLS (Side Lobe Suppression), šířku hlavního laloku T_c a dopplerovskou odolnost nejlépe. [37].

V průběhu mého doktorského studia se mi podařilo vytvořit nový druh modulace. Tuto modulaci jsem pojmenoval FLAMENCO (**FLA**t lobes **M**atch**E**d filter **N**onlinear frequen**C**y m**O**dulation). Jedná se o modulaci s velmi vysokým odstupem postranních laloků a plochým průběhem těchto laloků. Tato modulace bude následně porovnávána s dalším velmi rozšířeným typem nelineární modulace, a to NLFM váhovanou Taylorovým okem.

FLAMENCO metoda je postavená na odlišném přístupu k tvorbě fáze komplexní exponenciály. Následující vztah vyjadřuje průběh fáze

$$\Phi(t) = 4\kappa B \cdot t \cdot \arcsin\left(\frac{2t}{\tau_0}\right) \quad \text{pro: } t \in \left\langle -\frac{\tau_0}{2}, \frac{\tau_0}{2} \right\rangle; \quad (17)$$

kde,

- B – je efektivní šířka pásma,
- κ – je bezrozměrný koeficient, pro nastavení šířky hlavního laloku autokorelační funkce,
- τ_0 – je délka vysílaného impulsu,
- $\Phi(t)$ – je okamžitá fáze modulovaného signálu.

Okamžitý kmitočet $f(t)$ je roven:


$$f(t) = \frac{d\Phi(t)}{2\pi dt} = \frac{2\kappa B}{\pi} \arcsin\left(\frac{2t}{\tau_0}\right) + \frac{2\kappa B}{\pi} \frac{t}{\sqrt{\left(\frac{\tau_0}{2}\right)^2 - t^2}} \quad \text{pro: } t \in \left\langle -\frac{\tau_0}{2}, \frac{\tau_0}{2} \right\rangle \quad (18)$$

Z uvedeného vztahu vyplývá, že na hranicích impulsu $t = \pm \frac{\tau_0}{2}$ není okamžitý kmitočet $f(t)$ omezený $f(t) \rightarrow \pm\infty$, což nelze v praxi uskutečnit, jedná se tedy o idealizovaný případ této modulace. Ve skutečnosti vždy pracujeme se signálem vzorkovaným kmitočtem f_s a s periodou vzorkování $T_s = \frac{1}{f_s}$. Potom vztahy (17) a (18) přejdou na vztahy následující:

$$\begin{aligned} s(t_r) &= A(t_r) \cdot e^{j\Phi(t_r)} \\ t_r &= \tau_0 \cdot r; \quad \text{pro: } r \in \langle -K, K \rangle; \quad K = \left\lceil \frac{\tau_0}{2T_s} \right\rceil \\ f(t_r) &\cong \frac{\Phi(t_r) - \Phi(t_{r-1})}{T_s}; \quad \text{pro: } r \in \langle -K, K \rangle \end{aligned} \quad (19)$$

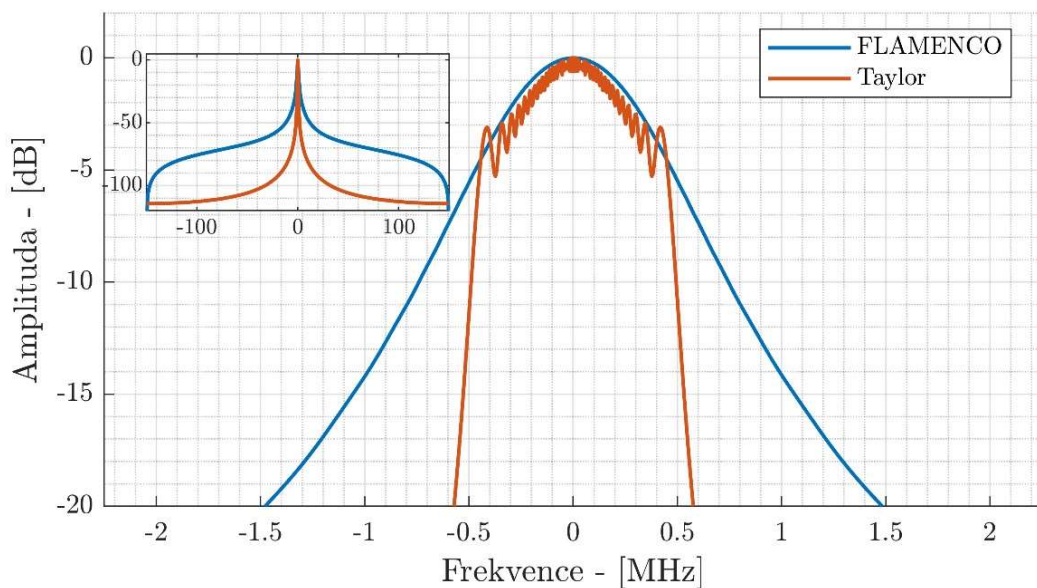
Protože je fáze $\Phi(t_r)$ vždy omezená, bude i okamžitá frekvence $f(t_r)$ vzorkovaného signálu omezená, ale její zdvih $\Delta f = f(t_K) - f(t_{-K})$ bude záviset na vzorkovacím kmitočtu f_s .

Ukázky průběhů fáze $\Phi(t_r)$ a okamžité frekvence $f(t_r)$ jsou na Obr. 14, ve srovnání s klasickou modulací NLFM – Taylor s průběhem okamžité frekvence. Parametry signálu jsou následující: $f_s = 300$ MHz, $\tau_0 = 200$ μ s a $B = 1$ MHz.



Obr. 14: Okamžitá fáze a frekvence


Průběh okamžité frekvence indikuje velmi strmý frekvenční zdvih na okrajích intervalu τ_0 , zatím co průběh okamžité fáze má pozvolný trend podobný Taylorovu. Dalším krokem je srovnání spekter obou signálů.



Obr. 15: Spektra signálů


Průběhy obou spekter jsou v užitečném pásmu $\langle -0.5|0.5 \rangle$ MHz velmi podobné, Obr. 15. Jediný rozdíl je ve zvlnění Taylorova spektra. Mimo užitečné pásmo má

Taylorův průběh spektra výrazně větší strmost, než je tomu v případě FLAMENCO. Tato skutečnost může mít vliv na druh použité aplikace. V případě nutnosti striktního dodržení šířky spektra lze na tento signál použít vhodný druh filtrace. Pro lepší představu o tom, co se děje uvnitř takovýchto signálů, jsou na Obr. 16 ukázány spektrogramy.




Obr. 16: Spektrogram FLAMENCO (vlevo), Taylor (vpravo).

Vlevo je vidět nepatrně vyšší spektrální náročnost metody FLAMENCO na rozdíl od Taylorova průběhu. Pomocí oranžových a zelených kót je ohraničeno $B = 1$ MHz pásmo. Taylorova funkce nese veškerou energii uvnitř tohoto intervalu, na rozdíl od funkce FLAMENCO, které částečně překračuje toto pásmo. Ještě před porovnáním samotných autokorelačních funkcí se podíváme na funkce neurčitosti Obr. 17 a její řezy Obr. 18, Obr. 19, Obr. 20.




Obr. 17: Funkce neurčitosti FLAMENCO (vlevo), Taylor (vpravo)


Oba průběhy jsou velice podobné, avšak metoda FLAMENCO má nepatrně lepší odolnost vůči Dopplerovu posuvu. Její hlavní lalok lépe drží tvar při zvyšujícím se Dopplerovu posuvu. Toto je lépe vidět na obrázcích ukazující jednotlivé řezy na kmitočtech $F_d = 0, 0.5$ a 1 MHz.



Obr. 18: Vliv Dopplerova posuvu na tvar korelační funkce, $F_d = 0$ Hz. FLAMENCO (vlevo), Taylor (vpravo)




Obr. 19: Vliv Dopplerova posuvu na tvar korelační funkce, $F_d = 0.5$ MHz. FLAMENCO (vlevo), Taylor (vpravo)



Obr. 20: Vliv Dopplerova posuvu na tvar korelační funkce, $F_d = 1$ MHz. FLAMENCO (vlevo), Taylor (vpravo)

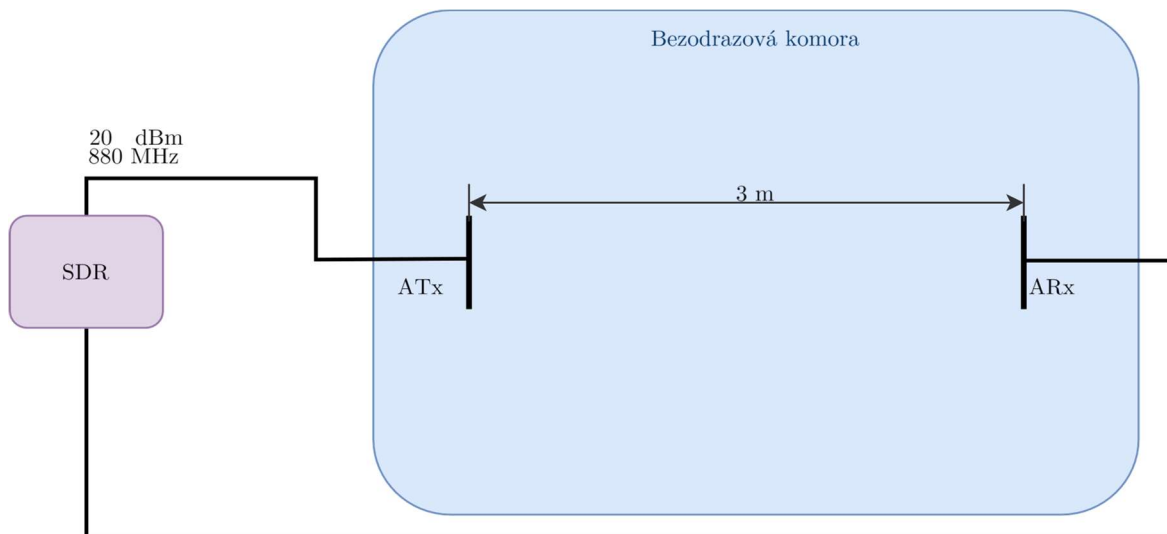
Obr. 20 je doplněn o kóty pomáhající kvantifikovat rozdíl v metodách. Nejdříve se podívejme na rozdíl v amplitudě hlavního laloku (označeno zeleně). Rozdíl mezi metodami je v tomto případě je roven 10.5 dB. Větší rozdíl nalezneme při porovnání funkcí v čase (označeno červeně). Zde se maximum nachází v následujících časech: FLAMENCO = 170 μ s, Taylor = -192 μ s. Absolutní hodnota rozdílu je po té rovna 28 μ s.

Nyní už zbývá porovnání autokorelačních funkcí obou metod.




Obr. 21: Srovnání ACF obou funkcí.

Na Obr. 21 je patrný značný rozdíl v odstupech postranních laloků mezi oběma metodami. Taylorova metoda dosahuje odstupech postranních laloků přibližně 23 dB (označené kótou a). V porovnání s metodou FLAMENCO tato metoda dosahuje odstupech postranních laloků až 70 dB (označené kótou b). Další výhodou je tzv. „plochost“ těchto laloků. Všechny laloky se drží na stejné úrovni v celém intervalu korelace. Výše uvedené pokusy se signály byly provedeny za použití nástroje MATLAB. Přesuňme se z tohoto „ideálního“ prostředí k reálnému systému. V následující části bude ukázáno, jak se vygenerovaný signál chová v reálném prostředí. Experiment byl proveden za použití SDR – USRPX310, dvou antén a bezodrazové komory Obr. 22. Vzorkovací frekvence byla zvolena s přihlédnutím k reálnému HW: $f_s = 10 \text{ MHz}$, $\tau_0 = 200 \text{ } \mu\text{s}$ a $B = 1 \text{ MHz}$.



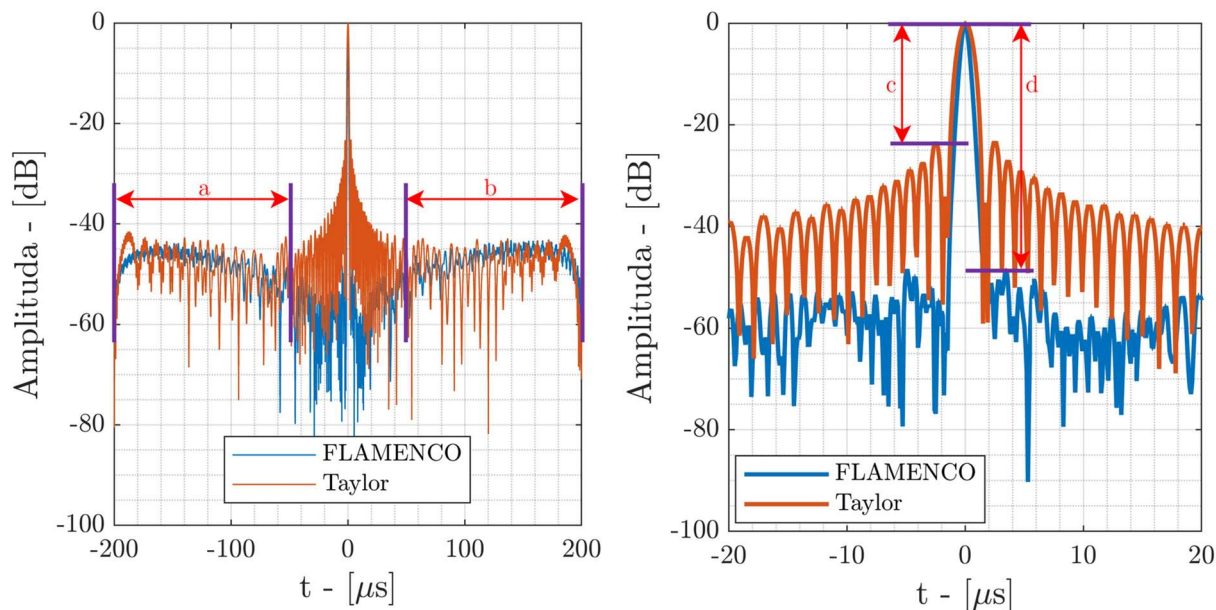
Obr. 22: Měřící řetězec pro určení vlivu reálného systému na ACF

Pro ilustraci se podíváme na ukázkou jednoho přijatého impulzu v čase, Obr. 23. Zobrazené průběhy jsou na výstupu IQ demodulátoru.



Obr. 23: Ukázka komplexní obálky přijatého signálu Taylor (vlevo), FLAMENCO (vpravo)

Nyní už zbývá porovnání obou autokorelačních funkcí Obr. 24. V levé části tohoto obrázku je ukázán celý interval korelační funkce. Kóty a , b vyznačují interval, ve kterém jsou postranní laloky obou funkcí pod hranicí dynamiky tohoto systému. V pravé části stejného obrázku je ukázán detail stejných autokorelačních funkcí. Kóty c , d vyjadřují hodnotu odstupu postranních laloků v okolí maxima korelační funkce. Taylorova funkce nabývá odstupu postranních laloků $c = 24$ dB. Funkce FLAMENCO má odstup $d = 49$ dB.



Obr. 24: Autokorelační funkce(vlevo), detaily stejných autokorelačních funkcí (vpravo)

4.2 Metody zpracování ve spektrální oblasti


Jedním z nejdůležitějších kroků při tvorbě spektrálních charakteristik signálu je výběr vhodné metody zpracování ve spektrální oblasti. V následující části jsou zkoumány tyto metody: Zprvke metody STFT (Short Time Fourier Transform), založené na DFT (Diskrétní Fourierově Transformaci): Blackman–Tukey, Bartlett a Welch. Zadruhé metody adaptivního filtru CAPON, APES. Dále metody, založené na autoregresivním (AR) modelu signálu: Yule–Walker, Modifikovaná kovarianční metoda a Burgova metoda. Z metod, založených na rozkladu kovarianční matice signálu, byla testována adaptivní metoda MUSIC (**MU**lti **SI**gnal **C**lassification).

Prvním krokem je popis metodiky získání dat, použitých při výběru vhodné metody zpracování ve spektrální oblasti.

- A) Mějme jednoduchý tří lopatkový odražeč. Parametry tohoto odražeče jsou uvedeny v Tab. 5, ukázka je na Obr. 25.

Tab. 5: Parametry simulace

Parametr	Hodnota	Jednotka
Rychlost cíle	0	$\text{m}\cdot\text{s}^{-1}$
Délka lopatky – l_b	1	m
Počet lopatek	3	-
Počet vrtulí	1	-
Frekvence otáčení – f_{ot}	4	Hz




Obr. 25: Bodový odražeč

B) Tento odražeč je sledován simulovaným radarovým senzorem. Parametry tohoto systému jsou uvedeny v Tab. 6.

Tab. 6: Ostatní parametry simulace

Parametr	Hodnota	Jednotka
Druh modulace	FLAMENCO	–
Délka impulzu	20	μs
Opakovací frekvence – PRF	6000	Hz
Frekvenční zdvih – BW	1	MHz
Nosná frekvence – f_0	9.28	GHz
Vzorkovací frekvence	10	MHz
Doba simulace	0.5	s

C) Přijatý signál je následně zpracován, spektrogram odraženého signálu je možné vidět na Obr. 26. Z tohoto spektrogramu budou vybrány zajímavé úseky, na kterých budou prováděny další analýzy. Tyto úseky jsou využity pouze k identifikaci časových okamžiků v přijatém signálu. Metody budou využívat data z přijatého signálu označeného časovými značkami.



Obr. 26: Spektrogram testovacího signálu

První úsek obsahuje tzv. „záblesk“ – flash (v okamžiku kolem $t = 0.15$ s). Jako „záblesk“ v souvislosti s μ -Dopplerovou signaturou rotující lopatky označujeme krátkodobý prudký nárůst odraženého signálu. Tento jev nastane ve chvíli, kdy se lopatka nebo list vrtule natočí kolmo k radarovému svazku. Druhý úsek je vybrán v době mezi záblesky v okamžiku kolem ($t = 0.3$ s).

Na základě parametrů z Tab. 5 a Tab. 6 je možné teoreticky ověřit věrohodnost simulace ve vztahu k velikosti Dopplerova posuvu. Nejprve je nutné vhodně upravit rovnici (13) tak, aby rychlost v_r odpovídala obvodové rychlosti na konci lopatky. To se provede následujícím způsobem:

$$v_t = 2\pi f_{ot} l_b \quad (20)$$

kde,

v_t – je obvodová rychlost na konci lopatky.

Po dosazení (20) do (13), bude tato rovnice vypadat následovně:

$$f_d = \pm 2f_0 \frac{2\pi f_{ot} l_b}{c} = \pm 2 \cdot 9.28 \cdot 10^9 \frac{2\pi \cdot 4 \cdot 1}{c} \cong \pm 1556 \text{ Hz} \quad (21)$$

Znaménko \pm v tomto případě indikuje, že pro nepohybující se cíl bude dopplerovské spektrum symetrické kolem nulového kmitočtu ve spektrogramu. Vypočtenou hodnotu 1556 Hz je možné odečíst z Obr. 26. Zde je tato hodnota označena červenými kótami.

4.2.1 Diskrétní Fourierova transformace (DFT):

Diskrétní Fourierova transformace, obecně označovaná zkratkou DFT, se používá k transformaci signálu z časové oblasti do jeho reprezentace ve frekvenční oblasti, což usnadňuje analýzu periodických složek v signálu.

$$D(n) = \sum_{k=0}^{N-1} d(k)e^{-j\frac{2\pi nk}{N}}, n = 0, \dots, N-1 \quad (22)$$

kde:

- $d(k)$ – je k -bodová posloupnost vzorků transformovaného signálu,
- $D(n)$ – je n -bodová posloupnost vzorků spektra signálu $d(k)$.

K její efektivní aplikaci se používá výkonný algoritmus FFT (Fast Fourier Transform). U náhodných signálů je důležitou charakteristikou výkonová spektrální hustota signálu (Power Spectral Density – PSD). Ta je definována jako statistická střední hodnota kvadrátu absolutní hodnoty DFT jednotlivých realizací signálu:

$$S_P(n) = E[|D(n)|^2], \quad n = 0, \dots, N-1 \quad (23)$$

DFT je v zásadě vhodná pouze pro stacionární signály. V praxi se však setkáváme i s nestacionárními signály, jejichž vlastnosti se s časem mění. Pak přicházejí na řadu další metody, spadající do skupiny tzv. krátkodobých Fourierových transformací (Short Time Fourier Transform – STFT) [38].

Nyní bude ukázán způsob vyjádření metriky, pomocí které budou hodnoceny výsledky jednotlivých metod. Na Obr. 27 jsou ukázány řezy vycházející z Obr. 26. Dále jsou tyto obrázky doplněny o kóty a_1 až a_5 a b . Hodnoty dané těmito kótami jsou použity pro určení nejhodnější metody zpracování následujícím způsobem,

$$\bar{a} = \frac{1}{N} \left(\sum_{n=1}^N |a_n| \right) \quad (24)$$

kde,

\bar{a} – je aritmetický průměr absolutních hodnot $|a_n|$

N – je počet hodnot. $N = 5$.

Hodnota daná rovnicí (24) vyjadřuje metriku, velikosti maxim daných odrazem od jednotlivých listů a propady v místech mimo tato maxima. Obecně platí, že čím větší hodnota \bar{a} , tím lepší výsledek.

Druhý parametr $|b|$ vyjadřuje tzv. „plochost/čistotu“ sledovaného průběhu. Tato hodnota je sledována pouze pro první úsek signálu, a to v intervalu $F_d \in \langle 0 ; 1500 \rangle$ Hz. Zde platí, že čím menší, tím lepší.

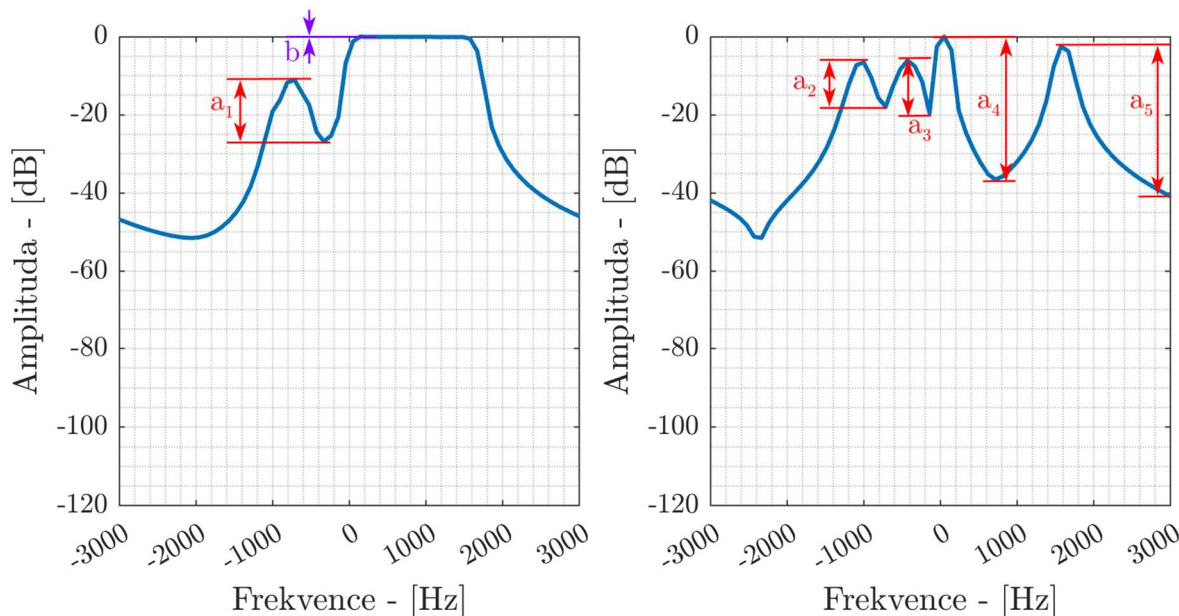
Výsledné skóre, které bude přiděleno každé metodě, je následující:

$$\kappa = \frac{|b|}{a} \quad (25)$$

kde,

κ – je skóre charakterizující metodu. Zde platí, čím menší, tím lepší.

Příklad jedné vypočtené hodnoty kappa, pro metodu DFT je: $\kappa = 0.1082$



Obr. 27: Metoda DFT, První úsek (vlevo), druhý úsek (vpravo), Délka FT = 64

4.2.2 Metody vycházející z DFT

Tyto metody se používají k odhadu výkonové spektrální hustoty (PSD). Hlavní myšlenkou spočívající v těchto metodách, je rozdělení signálu do několika segmentů. Na těchto segmentech se následně provádí FFT analýza. Jednotlivé metody se liší ve způsobu, jakým je přistupováno k jednotlivým segmentům signálu.

A) Bartlettova metoda

Tato metoda se snaží redukovat varianci periodogramu pomocí následujících tří kroků. Nejdříve je N -bodová posloupnost rozdělena do K nepřekrývajících se segmentů délky M . [38]

$$x_i(n) = x(n + iM) \quad (26)$$

kde:

$$i = 0, 1, \dots, K - 1$$

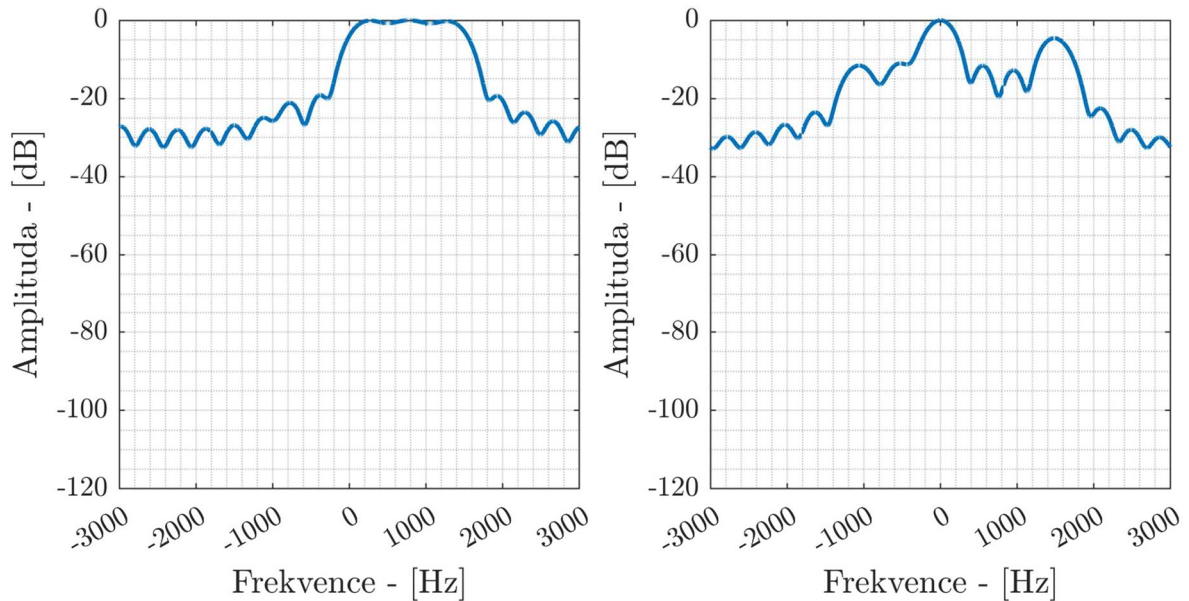
$$n = 0, 1, \dots, M - 1$$

Pro každý takto vytvořený segment, je následovně vypočten periodogram.

$$P^{(i)}(f) = \frac{1}{M} \left| \sum_{n=0}^{M-1} x_i(n) e^{-2\pi jfn} \right|^2 \quad (27)$$

Posledním krokem je získání průměru ze všech periodogramů Obr. 28.

$$P(f) = \frac{1}{K} \sum_{i=0}^{K-1} P^{(i)}(f) \quad (28)$$



Obr. 28: Bartlettova metoda, První úsek (vlevo), druhý úsek (vpravo), $K = 4$

B) Welchova metoda

Dva hlavní rozdíly odlišují tuto metodu od Bartlettovy metody. Prvním rozdílem je to, že segmenty posloupnosti jsou navzájem překryty. Druhým rozdílem je použití vhodného okna váhující tyto segmenty, před výpočtem samotného periodogramu. Rozdělení vstupní posloupnosti do segmentů probíhá následovně

$$x_i(n) = x(n + iD) \quad (29)$$

kde:

$$i = 0, 1, \dots, K - 1,$$

$$n = 0, 1, \dots, M - 1,$$

D – je počáteční bod i -té sekvence.

Pokud se $D = M$, elementy se nepřekrývají. Tím pádem se jedná o Bartlettovu metodu. Pokud $D = M/2$, jedná se o 50 % překryv elementů. Překryvy se mohou libovolně měnit. [38]

$$\bar{P}^{(i)}(f) = \frac{1}{MU} \left| \sum_{n=0}^{M-1} x_i(n) \omega(n) e^{-2\pi jfn} \right|^2 \quad (30)$$

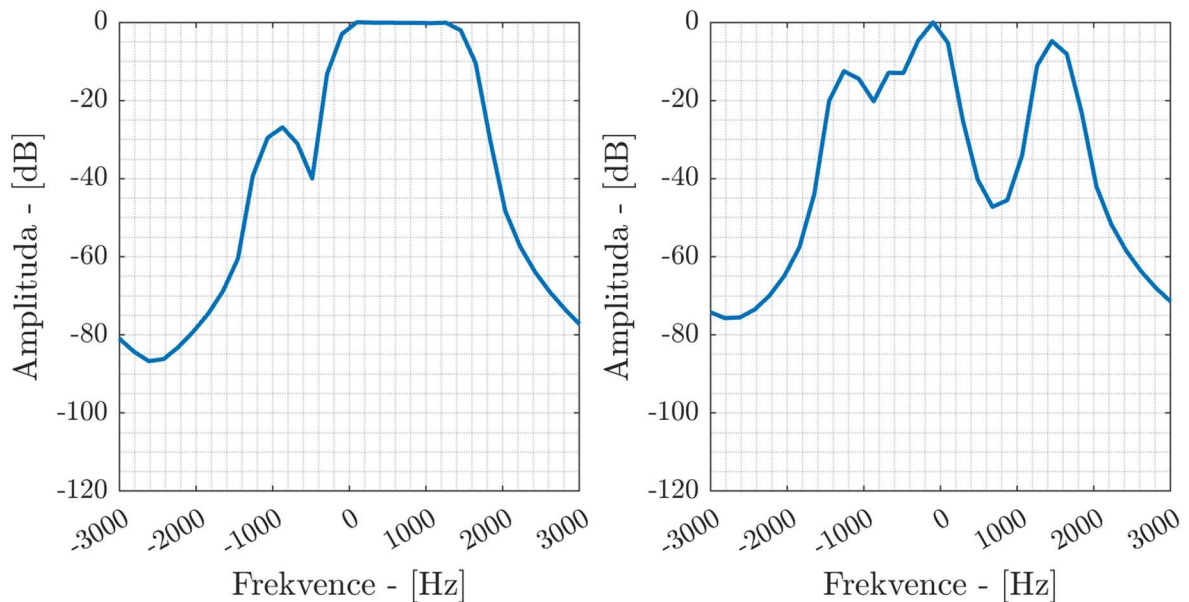
kde:

$$i = 0, 1, \dots, L-1,$$

$\{\omega(n)\}_{n=0}^{M-1}$ – je váhovací okno.

Výsledný periodogram je produktem průměru $\bar{P}^{(i)}(f)$, Obr. 29.

$$P_W(f) = \frac{1}{L} \sum_{i=0}^{L-1} \bar{P}^{(i)}(f) \quad (31)$$



Obr. 29: Welchova metoda, První úsek (vlevo), druhý úsek (vpravo), $L = 4$, $D = 0.7$

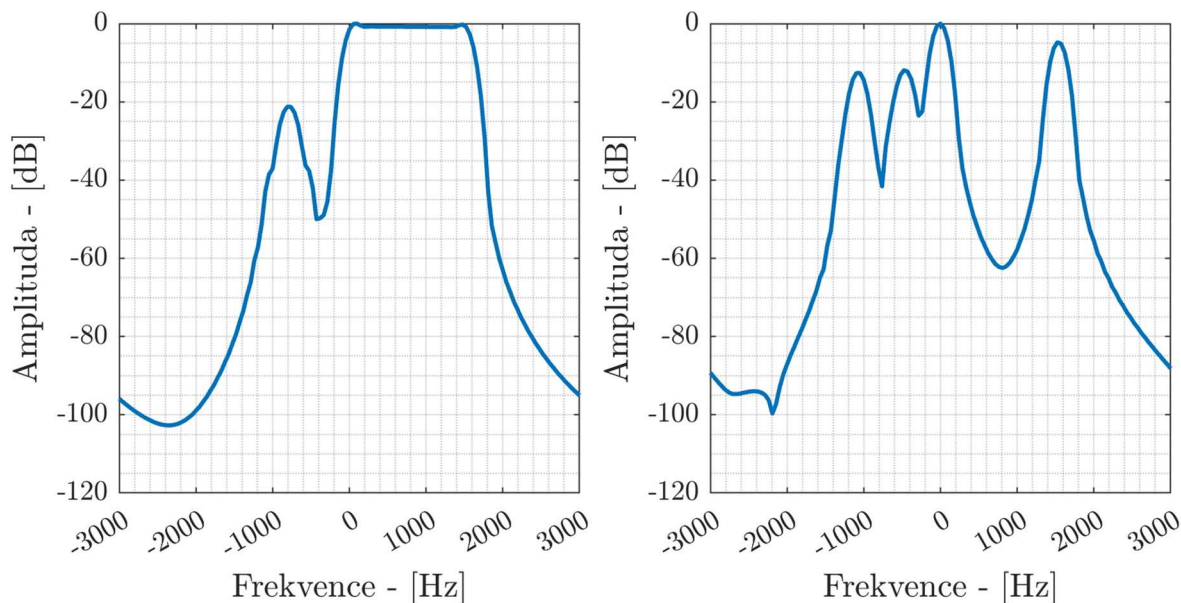
C) Blackman–Tukeyova metoda

Blackman–Tukeyho metoda kombinuje koncept autokorelace a Fourierovy transformace pro odhad výkonového spektra signálu. Toto zahrnuje výpočet autokorelační funkce a následné provedení Fourierovy transformace k získání výkonového spektra Obr. 30.

$$P_{BT}(f) = \int_{-\frac{1}{2}}^{\frac{1}{2}} P_W(f) W(f-v) df \quad (32)$$

kde:

$W(f-v)$ – je funkce okna váhajícího periodogram.



Obr. 30: BI-Tu metoda, První úsek (vlevo), druhý úsek (vpravo), Délka FT = 64

4.2.3 Metody odhadu spektra, složeného z harmonických funkcí a šumu

Zatím co DFT a z DFT odvozené metody, uvedené v 4.2.2, odhadují zcela obecné spektrum signálu, následující metody jsou zaměřeny pouze na signály, které se skládají z konečného počtu harmonických funkcí a šumu. Těchto metod je velké množství a liší se svou rozlišovací schopností (tj. jak blízko mohou být kmitočty harmonických funkcí, aby se daly rozeznat), přesností odhadu kmitočtu, amplitudy a fáze harmonických funkcí, komplikovaností výpočtu. Jedním z charakteristických rysů jednotlivých metod je požadavek na znalost dodatečných parametrů signálu v případě metod parametrických, oproti metodám neparametrickým, které takovou znalost nevyžadují. Parametrické metody dosahují zpravidla lepší rozlišovací schopnosti, ale obvykle je nutno znát buď počet harmonických funkcí nebo řád systému (což také souvisí s počtem harmonických funkcí).

Pokud neodhadneme správně tento parametr, parametrické metody zpravidla zcela selhávají. Mezi neparametrické metody patří například metoda CAPON (ASCE) nebo APES [39], [40]. K parametrickým metodám řadíme skupinu metod, využívajících rozklad kovarianční matice signálu (např. MUSIC, ESPRIT, Relax a jiné [41]–[43]) a metody, vycházející z autoregresního (AR) modelu signálu např. metoda Yule-Walker, kovarianční a modifikovaná kovarianční metoda, Burgrova metoda [44]–[48]).

A) Neparametrické metody – ASCE

Jako příklad ukáži metodu označovanou jako ASCE – Amplitude Spectrum Capon Estimator. U tohoto estimátoru se kolem vybraného kmitočtu vytvoří filtr, jehož maximální výstupní signál závisí na amplitudě harmonického signálu na vybraném

kmitočtu, přičemž harmonické signály na okolních kmitočtech se uplatňují minimálně.

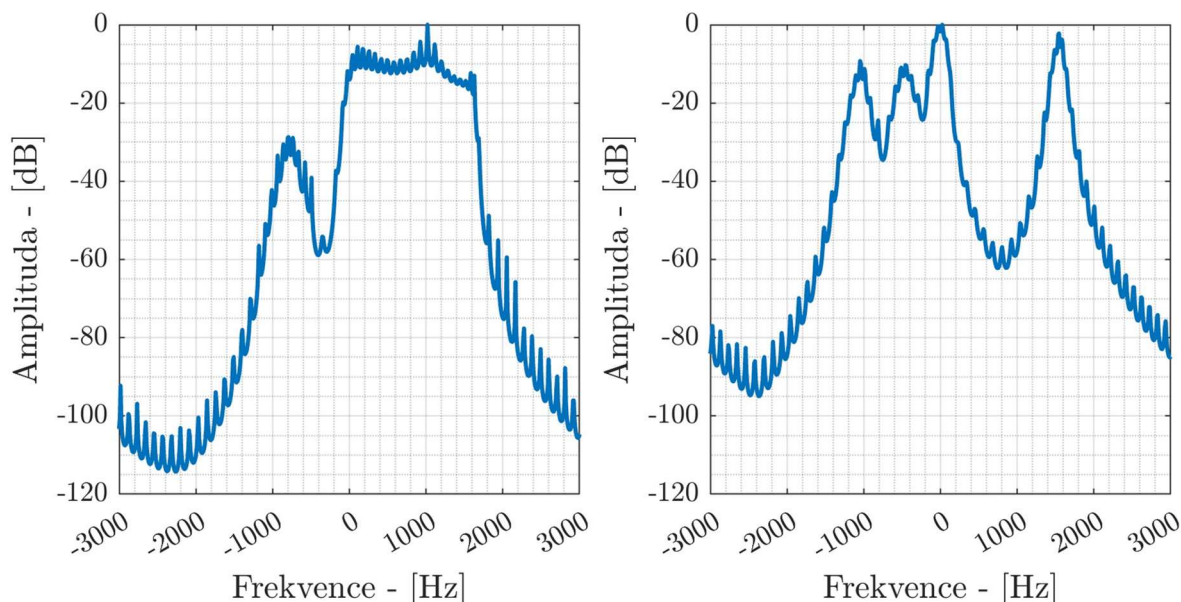
Pro výkonovou spektrální hustotu na kmitočtu, který odpovídá skoku fáze θ mezi sousedními harmonickými složkami, dostaneme vztah:

$$\begin{aligned} \hat{S}_P(\theta) &= \frac{1 + K}{\mathbf{e}_\theta^H \mathbf{R}^{-1} \mathbf{e}_\theta}; \\ \mathbf{e}_\theta &= [1 \quad e^{j\theta} \quad e^{2j\theta} \quad \dots \quad e^{(Kj\theta)}]; \\ \mathbf{R} &= \begin{bmatrix} r(0) & r(1) & \dots & r(K) \\ r(-1) & r(0) & \dots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ r(-K) & r(-K+1) & \dots & r(0) \end{bmatrix}; \quad r(m) = \mathbf{E}[u_k^* u_{k+m}]; \\ \theta &= 2\pi f \frac{T}{K} \end{aligned} \quad (33)$$

kde:

- f – je kmitočet harmonické složky,
- $K + 1$ – je celkový počet vzorků signálu v intervalu T ,
- \mathbf{e}_θ – je řádkový vektor fázových posuvů,
- \mathbf{R} – je autokovarianční matice signálu.

Otázkou vždy je, jak se autokovarianční matice \mathbf{R} počítá. Tím se řada metod od sebe liší, jak výpočetní náročností, tak přesností výsledků. Kmitočty harmonických funkcí v signálu se určují jako maxima křivky $|\hat{S}_P(\theta)|$, Obr. 31.



Obr. 31: CAPON estimátor, První úsek (vlevo), Druhý úsek (vpravo), $K = 64$

B) Autoregresní (AR) modely

Autoregresní (AR) modely jsou základními nástroji v analýze časových řad a zpracování signálů. Tyto modely předpokládají, že aktuální hodnotu časové řady lze dobře předpovědět na základě jejích předchozích hodnot pomocí lineární kombinace těchto minulých hodnot a šumu. [46]

$$x(n) + \sum_{k=1}^p a_p(k)x(n-k) = \nu(n) \quad (34)$$

kde:

- p – je řád modelu,
- $a_p(k)$ – jsou parametry modelu,
- $\nu(n)$ – jsou vzorky Gaussovského, bílého šumu.


$$\hat{P}_{AR}(f) = \frac{1}{f_s} \frac{\varepsilon_p}{\left| 1 + \sum_{k=1}^p \hat{a}_p(k) e^{-2\pi j k f / f_s} \right|^2} \quad (35)$$

kde:

- f_s – je vzorkovací frekvence,
- \hat{a}_p – jsou parametry (koeficienty) AR modelu,
- ε_p – je rozptyl šumu.

C) Yule–Walkerova metoda


Yule–Walkerova metoda je klasický přístup, který se používá k odhadu koeficientů AR modelu přizpůsobením autoregresního procesu autokovarianční posloupnosti dat [46]. Poskytuje přímočaré řešení založené na metodě momentů. Mezi hlavní charakteristiky této metody patří to, že je jedná o tzv. autokorelační metodu. Její výhodou je to, že je vždy stabilní. Nevýhodou jsou relativně špatné výsledky pro malé množství dat, proto se využívá zejména při dlouhých úsecích dat, Obr. 32.



Obr. 32: Yule–Walkerova metoda, První úsek (vlevo), Druhý úsek (vpravo), $p = 64$

D) Burgova metoda

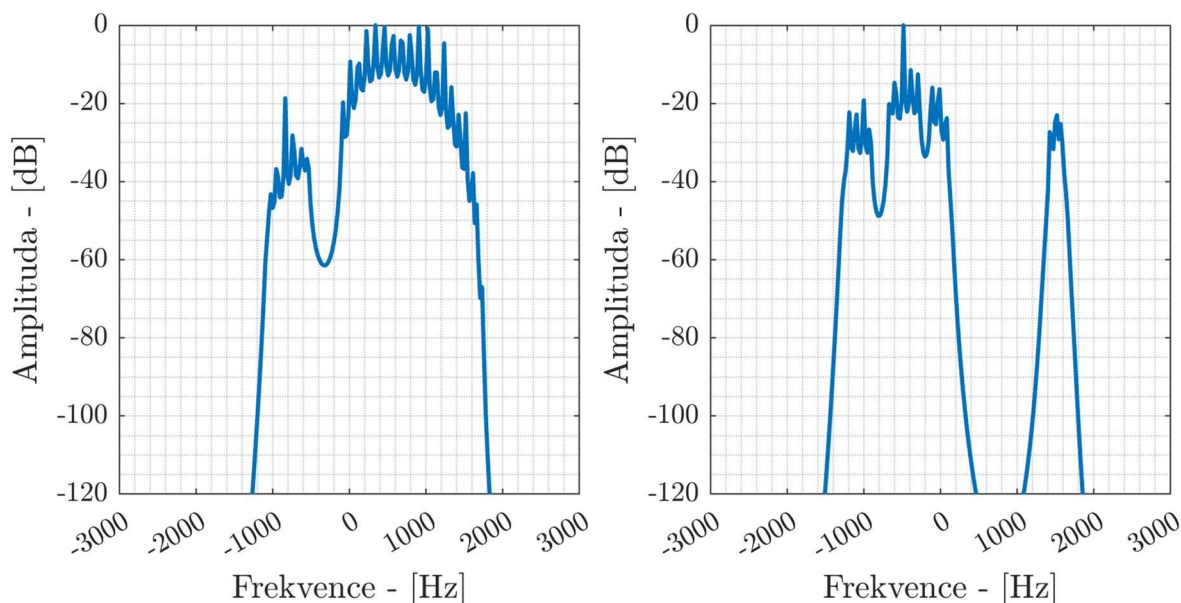
Jedná se o iterační algoritmus používaný k odhadu parametrů AR modelu [43]–[44]. Minimalizuje chyby dopředné a zpětné predikce, aby se získala přesná reprezentace časové řady. Hlavní výhodou je dobré rozlišení ve frekvenci i pro malé množství dat. Další výhodou je stabilita této metody. Tato metoda trpí i jistými nevýhodami. První je vysoká závislost spektrálních špiček na počáteční fázi signálu. Další možnou nevýhodou je štěpení těchto špiček za přítomnosti velkého množství šumu, Obr. 33.



Obr. 33: Burgova metoda, První úsek (vlevo), Druhý úsek (vpravo), $p = 64$

E) Kovarianční a modifikovaná kovarianční metoda

Kovarianční metoda pro odhad spektra AR je založena na minimalizaci chyby dopředné predikce. Modifikovaná kovarianční metoda je vylepšením kovarianční metody a provádí minimalizaci chyb dopředné a zpětné predikce [47]. Poradí si i s případy, kdy kovarianční metoda nedává uspokojivé výsledky. PSD vypočtené touto metodou jsou zobrazeny na Obr. 34



Obr. 34: Modifikovaná kovarianční metoda, První úsek (vlevo), Druhý úsek (vpravo), $p = 32$

F) Metoda MUSIC

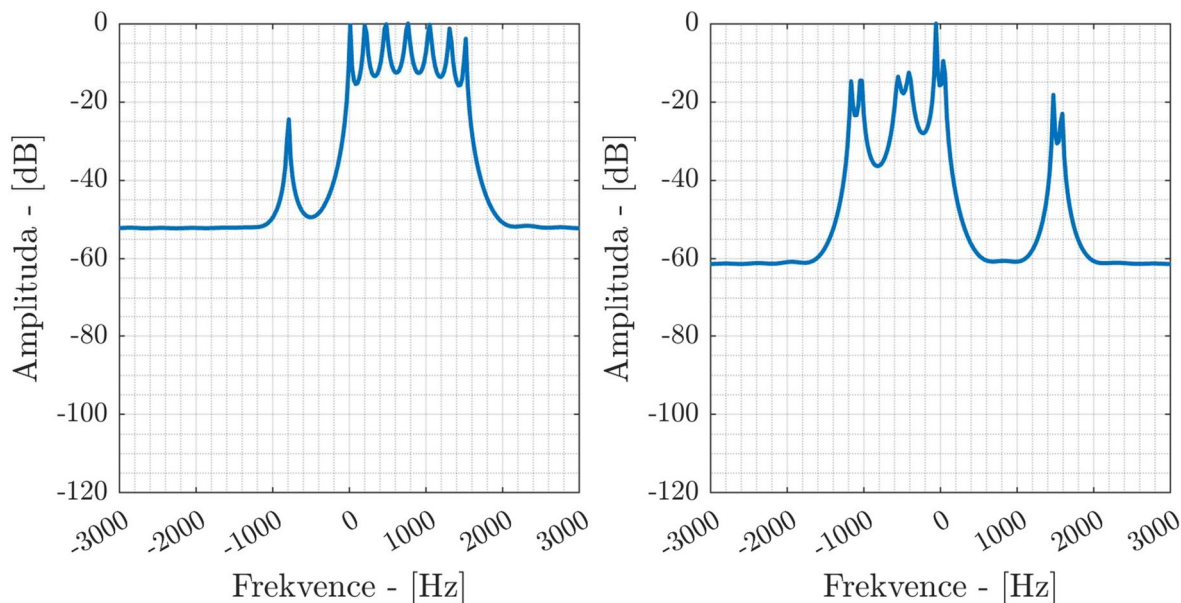
Metoda MUSIC (MUltiple SIgnal Classification) je populární technikou používanou pro výkonovou spektrální analýzu, zejména v oblasti zpracování signálů a zpracování anténních polí [41]. Běžně se používá k odhadu počtu zdrojů signálu a jejich frekvencí v zašuměném prostředí. Hlavní myšlenkou metody MUSIC je promítnutí přijímaného signálu do signálového a šumového podprostoru. Seřazení vlastních vektorů kovarianční matice signálu podle velikosti vlastních čísel umožňuje rozlišit složky signálu od šumu následovně:

$$\mathbf{S}_{\text{MUSIC}}(\boldsymbol{\theta}) = \left[\sum_{i=P+1}^N |\mathbf{s}^H(\boldsymbol{\theta}) \hat{v}_i|^2 \right]^{-1} \quad \text{kde: } \mathbf{s}(\boldsymbol{\theta}) \equiv [1, e^{j\theta}, e^{2j\theta} \dots] \quad (36)$$

kde:

- \hat{v}_i – je vektor vlastních čísel,
- \mathbf{s}^H – je Hermitovská transpozice vektoru \mathbf{s} .

Ukázka výsledného spektra je na Obr. 35.



Obr. 35: MUSIC metoda, první úsek (vlevo), druhý úsek (vpravo), řád modelu $N = 8$

G) Vyhodnocení výsledků

V Tab. 7 jsou ukázána výsledná skóre jednotlivých metod. Skóre jsou daná ukazatelem κ (23) určující nejvhodnější metodu. Tabulka je seřazena vzestupně podle parametru κ , kde platí, že menší hodnota je lepší výsledek. První tři příčky obsadily metody Blackman–Tukey, Yule–Walker a Welch. Důvodem je „plynulost/plochost“ jejich spektra dané nízkou hodnotou $|b|$. Naopak nejhorší metody v tomto testu jsou CAPON, MUSIC a Burg. Tyto metody trpí tzv. „roztřepeným“ spektrem. To se odráží vysokou hodnotou $|b|$. Proto jsem pro výpočty spekter v této práci zvolil metodu Blackman–Tukey.

Tab. 7: Skóre jednotlivých metod

Metoda	\bar{a}	$ b $	κ
Blackman–Tukey	43.02	1.50	0.0350
Yule–Walker	41.69	1.50	0.0360
Welch	27.93	2.00	0.0716
DFT	23.11	2.50	0.1082
APES	15.57	2.50	0.1606
Bartlett	11.65	2.50	0.2144
CAPON	42.73	15.0	0.3510
MUSIC	33.10	15.5	0.4682
Burg	79.03	44.0	0.5568

4.3 Modely pozorovaných cílů

Tato kapitola uvádí jednotlivé typy sledovaných cílů včetně jejich charakteristických parametrů. Všechny modely vycházejí ze skutečných objektů, které byly použity při akvizici reálných měření. Pro experimentální část práce byly vybrány tři reprezentativní typy cílů: **ventilátor**, **dron** a **jízdní kolo**. Volba těchto konkrétních objektů byla vedena praktickými a technickými důvody, které spočívají v relativní jednoduchosti měření všech tří typů cílů v bezodrazové komoře.


Dron představuje typický vzdušný cíl, který je v současnosti hojně využíván v civilních i vojenských aplikacích. Z tohoto důvodu byl zařazen jako primární objekt zájmu této práce.

Ventilátor slouží jako zástupný model pro rotující cíle typu větrná elektrárna. Větrné elektrárny jsou významnými zdroji radarového clutteru a mohou ovlivňovat funkci radarových systémů v oblastech s velkou hustotou pokrytí těmito elektrárnami. Nicméně jejich reálné měření je velmi náročné kvůli jejich rozměrům a lokalizaci. Z tohoto důvodu byl zvolen běžně dostupný a snadno manipulovatelný ventilátor, který simuluje základní rotační charakteristiky větrné turbíny v kontrolovaných laboratorních podmínkách. Jízdní kolo zastupuje třídu pozemních kolových cílů, jako jsou například motocykly nebo osobní automobily. Přímé měření těchto větších dopravních prostředků je komplikováno jak jejich velikostí, tak i potřebou testování v otevřeném prostoru. Toto je spojeno s mnoha omezeními (např. rušení a odrazy). Jízdní kolo nabízí obdobný způsob pohybu a strukturu pohybujících se částí (rotace kol), přičemž je dostatečně kompaktní pro testování v laboratorních podmínkách.

Výběr těchto modelů umožňuje zachytit různé typy pohybových zdrojů μ -Dopplerových jevů, které jsou typické pro široké spektrum reálných cílů. Zároveň zajišťuje, že měření lze provádět v bezodrazové komoře, což významně zvyšuje opakovatelnost experimentů. Tímto způsobem vzniká datová sada, která umožňuje efektivní trénink a validaci klasifikačního systému pro detekci a rozpoznání UAV objektů a jiných typů cílů.

4.3.1 Ventilátor

Mějme ventilátor, který reprezentuje tří lopatkový odražeč (např. větrná elektrárna), s úhlem ϑ mezi jednotlivými lopatkami, kde N je počet lopatek, Obr. 36.



Obr. 36: Tří lopatkový odražeč

Úhel mezi lopatkami je vyjádřen následovně:


$$\vartheta = 2\pi/N \quad (37)$$

Jednotlivé lopatky jsou aproximovány jako rotační elipsoidy, což představuje jisté zjednodušení oproti jejich skutečné geometrii. V reálných aplikacích, například u lopatek větrných elektráren nebo rotorů vrtulníků, mají tyto struktury velmi složitý tvar. Ten zahrnuje proměnlivý profil, zakřivení a aerodynamickou torzi podél jejich délky. Přesné modelování takových lopatek by vyžadovalo komplexní geometrii. Ostatní parametry jsou v Tab. 8.

Tab. 8: Parametry ventilátoru

Parametr	Hodnota	Jednotka
Počet vrtulí	1	–
Počet lopatek – N	3	–
Délka lopatky – l	0.18	m
Rychlost otáčení – f_y	17.23	Hz
r_a	9	cm
r_b	2	cm

Ukázka takto sestaveného objektu je na Obr. 37



Obr. 37: Bodová reprezentace ventilátoru

4.3.2 Dron

V rámci experimentální části byly testovány dva odlišné typy bezpilotních prostředků, které se liší konstrukcí, hmotností i aerodynamickými vlastnostmi. Prvním z nich byl dron kategorie DIY (*Do-It-Yourself*), který byl sestaven z jednotlivých komponent, převážně z uhlíkových kompozitů. Tento typ konstrukce je charakteristický nízkou hmotností a vysokou tuhostí. Druhým zkoumaným prostředkem byl komerčně dostupný dron MATRICE 600 PRO, patřící do kategorie profesionálních UAV s robustní konstrukcí a vysokou nosností, určený především pro náročné průmyslové a filmové aplikace. Tento model disponuje pokročilou stabilizací letu a redundantními systémy řízení, což jej činí vhodným pro dlouhodobé a spolehlivé provozní nasazení. Ukázky obou dronů jsou uvedeny na Obr. 38. Jejich parametry jsou uvedeny v Tab. 9 a Tab. 10.



Obr. 38: MATRICE-600 PRO (vlevo), DIY Dron (vpravo)

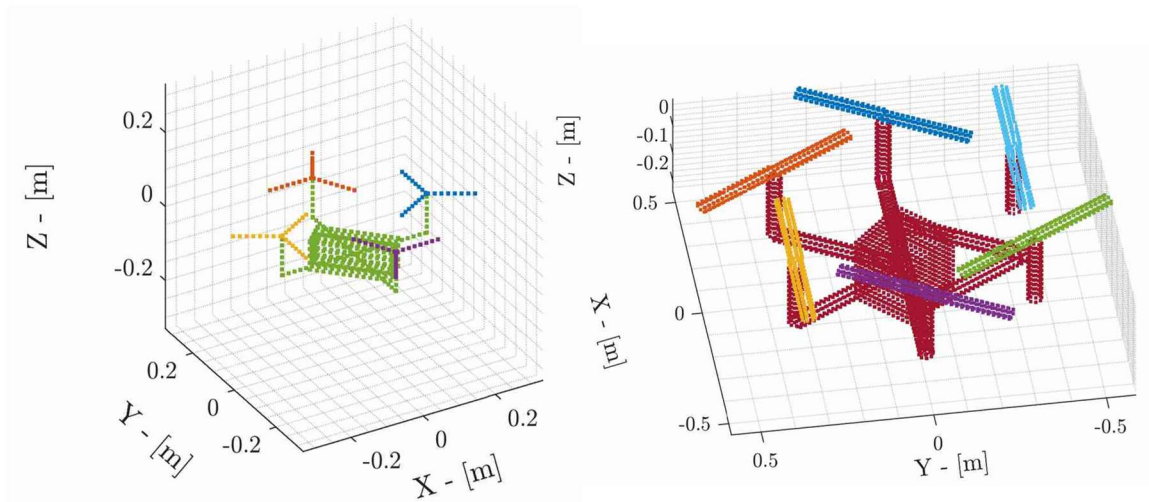
Tab. 9: Parametry DIY dronu

Parametr	Hodnota	Jednotka
Počet vrtulí	4	–
Počet lopatek – N	3	–
Délka lopatky – l	9	cm
Frekvence otáčení – f_y	14.8, 28.1, 53.2, 85.8	Hz
r_a	1	cm
r_b	1	cm

Tab. 10: Parametry MATRICE-600 PRO

Parametr	Hodnota	Jednotka
Počet vrtulí	6	–
Počet lopatek – N	2	–
Délka lopatky – l	27	cm
Frekvence otáčení – f_y	23.8	Hz
r_a	2	cm
r_b	1	cm


Pro účely modelování a simulace byly dále vytvořeny bodové reprezentace obou UAV, které slouží k analýze μ - Dopplerových jevů. Tyto modely zachycují rozmístění konstrukčních prvků, zejména rotorů, jež jsou dominantním zdrojem μ - Dopplerových složek. Vizualizace obou bodových modelů je znázorněna na Obr. 39.



Obr. 39: Bodová reprezentace DIY dron (vlevo), MATRICE (vpravo)

4.3.3 Jízdní kolo

Uvažujme jízdní kolo s M koly a N dráty ve výpletu (Obr. 40).



Obr. 40: Jízdní kolo

V běžné praxi se setkáme s jízdními koly, kde poloměr každého kola $r_M = \text{const}$, poté můžeme říct, že úhlové rychlosti jednotlivých kol jsou také shodné $f_{y1} = f_{y2}$. Mějme standardní silniční kolo s ocelovými dráty výpletu kola. Počet drátů a jejich materiál se může obecně lišit v závislosti na ceně. V našem případě je použito jízdní kolo s následujícími parametry.


Tab. 11: Parametry jízdního kola

Parametr	Hodnota	Jednotka
Počet kol*	1	–
Počet drátů – N	36	–
Poloměr kola – r_M	35	cm
Rychlost otáčení – f_y **	≈ 4	Hz

*V reálném měření je jízdní kolo postaveno na řídlíčka, takže se otáčí pouze jedno kolo. Důvodem je nemožnost zajistit rovnost otáček obou kol ($f_{y1} \neq f_{y2}$). Při rozdílných frekvencích by došlo ke kontaminaci μ - Dopplerova spektra dalšími frekvenčními složkami, což by znemožnilo jednoznačnou interpretaci výsledků. Rotací pouze jednoho kola se tomuto efektu záměrně předchází.

**Rychlost otáčení f_y , je v tomto případě částečně problematické definovat jako konstantní parametr. Praktické měření, které bude následovat v dalších částech této práce, naráží na problém s udržením konstantní f_y . Jízdní kolo, které je postaveno na svá řídlíčka, má roztočené zadní kolo pomocí pedálu. Nicméně samotné měření


probíhá až po opuštění bezodrazové komory s volně se otáčejícím kolem. Tímto vznikají dva problémy. Prvním je nemožnost přesně nastavit f_y vícekrát po sobě a druhým je pozvolna klesající f_y v závislosti na setrvačnosti. Ukázka sestaveného bodového objektu je na Obr. 41.



Obr. 41: Bodová reprezentace jízdního kola

4.4 Model odrazu signálu od překážky

Jak jsem konstatoval v odstavci 2.5, lze počítat s tím, že rozměry odrážejícího předmětu jsou větší než vlnová délka dopadajícího signálu. Můžeme proto předpokládat, že pro signál a jeho odraz lze použít paprskový model. Budeme uvažovat, že na každý bod předmětu dopadá paprsek rovinné vyslané vlny, který se odráží s určitým (komplexním) koeficientem odrazu. Fáze odraženého přijatého signálu je ovlivněna přenosem v prostoru, zejména okamžitou vzdáleností odrážejícího bodu od radaru. Obr. 42 znázorňuje ukázkou jednoduchého objektu, v tomto případě složeného z osmi bodů ve vrcholech krychle. Tento útvar je umístěn do středu souřadnicového systému a je „pozorován“ z modrého bodu. Jedná se o virtuální místo pozorování ve směru, charakterizovaném azimutem φ a elevací θ . Rovnice 35 vyjadřuje intenzitu odraženého pole v závislosti na úhlech pozorování φ a θ . [45]. Je důležité podotknout, že obecně se úhly θ_m a φ_m liší pro m -tý bod objektu vzhledem k místu pozorování. Pokud je však vzdálenost mezi objektem a místem pozorování výrazně větší než rozměry samotného objektu, lze celý objekt považovat za bodový cíl. V takovém případě můžeme úhly θ_m a φ_m považovat za společné pro všechny body objektu a vyjádřit je následovně θ a φ . Tento předpoklad výrazně zjednodušuje výpočty a snižuje výpočetní náročnost, a proto jej v modelech budu dále uplatňovat.



Obr. 42: Ukázka geometrie sledovaného objektu

$$E_s(\theta, \varphi) \approx \sum_{m=1}^M A_m \cdot e^{\left(\frac{-4i\pi f}{c}(x_m \cos \theta \cos \varphi + y_m \cos \theta \sin \varphi + z_m \sin \theta)\right)} \quad (38)$$

kde:

- x_m, y_m, z_m – je souřadnice m -tého odrazného bodu,
- E_s – je odražené elektrické pole,
- θ – je azimut směru pozorování,
- φ – je elevace směru pozorování,
- A_m – je komplexní skalár charakterizující velikost odrazu od m -tého bodu a jeho fázi.

Odražené pole $E_s(\theta, \varphi)$ je poté převedeno na efektivní odraznou plochu následujícím způsobem. Prvním krokem, je normalizace:


$$E_{s_norm}(\theta, \varphi) = \frac{|E_s(\theta, \varphi)|}{\max_{\theta, \varphi} |E_s(\theta, \varphi)|} \quad (39)$$

Lze oprávněně očekávat, že odrazná plocha $\sigma(\theta, \varphi)$ jako funkce úhlů θ, φ , bude úměrná veličině $E_{s_no}^2(\theta, \varphi)$:

$$\sigma(\theta, \varphi) \cong \sigma_{max} \cdot E_{s_norm}^2(\theta, \varphi) \quad (40)$$

Jak už bylo řečeno, na kmitočtech, kde je vlnová délka mnohem kratší, než rozměry předmětu je efektivní odrazná plocha srovnatelná s geometrickou (viditelnou) plochou průřezu předmětu.

Dalším krokem je tedy výpočet viditelné plochy cíle ve směru největšího odrazu. Toto se provede promítnutím předmětu do 2D. Ukázka takového tvaru pro kvadrokoptéru je na Obr. 43.



Obr. 43: Ukázka 2D projekce dronu

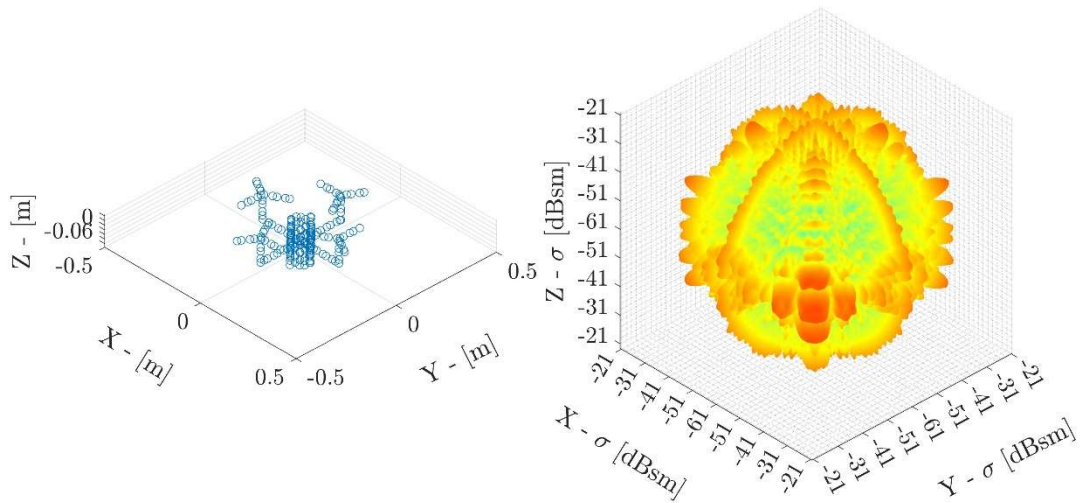
Takto získaná plocha A v m^2 , se považuje za σ_{max} a pro efektivní odraznou plochu v závislosti na směrových úhlech θ, φ dostáváme vztah:

$$\sigma(\theta, \varphi) = A \cdot E_{s_norm}^2(\theta, \varphi) \quad (41)$$

Protože v simulacích a dalších grafech pracuji v kartézské soustavě souřadnic, je efektivní odrazná plocha $\sigma(\theta, \varphi)$ převedena následujícím způsobem:


$$\begin{aligned} x &= r \sin(\theta) \cos(\varphi) \\ y &= r \sin(\theta) \sin(\varphi) \\ z &= r \cos(\theta) \end{aligned} \quad (42)$$

Nyní se už zbývá jenom podívat na výsledné tvary odrazných ploch pro jednotlivé typy cílů.

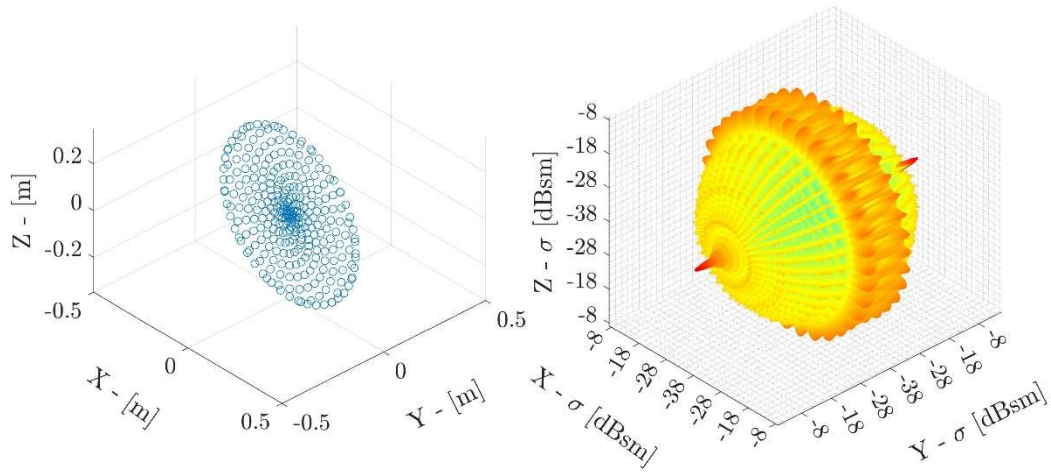


Obr. 44: Pohled na dron z boku (vlevo), průběh velikosti efektivní odrazné plochy σ [dBsm] v závislosti na úhlu pozorování (vpravo)

Na Obr. 44, Obr. 45 a Obr. 46 jsou znázorněny výsledky analýzy efektivní odrazné plochy cíle na úhlu pozorování. Tyto grafy demonstrují, že velikost radarového odrazu není konstantní, ale podléhá výrazným fluktuacím v závislosti na změně azimutu či elevace, přičemž charakter průběhu se liší podle typu cíle.



Obr. 45: Pohled na lopatky ventilátoru z boku (vlevo), průběh velikosti efektivní odrazné plochy σ dBsm v závislosti na úhlu pozorování (vpravo)



Obr. 46: Pohled na jízdní kolo z boku (vlevo), průběh velikosti efektivní odrazné plochy σ [dBsm] v závislosti na úhlu pozorování (vpravo)

4.5 Částečný odraz vlny na rozhraní prostředí

Na rozhraní dvou různých prostředí se vlna částečně odráží a částečně postupuje do druhého prostředí. Velikost a fáze odrazu se dá vyjádřit pomocí tzv. Fresnelova koeficientu odrazu Γ . Je to poměr mezi komplexními amplitudami odražené vlny E_s a dopadající vlny E_{dop} na rovinném rozhraní dvou dielektrik.

$$\Gamma = \frac{E_s}{E_{dop}} \quad (43)$$

Koeficient odrazu Γ souvisí s vlnovými impedancemi obou prostředí podle vztahu (44), [38].

$$\Gamma = \frac{Z_1 - Z_0}{Z_1 + Z_0} \quad (44)$$

kde,

Γ – koeficient odrazu,

Z_1 – vlnová impedance materiálu cíle,

Z_0 – vlnová impedance okolního prostředí.

Vlnovou impedanci homogenního prostředí lze vypočítat pomocí jeho permitivity ε a permeability μ [38]:

$$Z = \sqrt{\frac{\mu}{\varepsilon}} = \sqrt{\frac{\mu_0}{\varepsilon_0}} \cdot \sqrt{\frac{\mu_r}{\varepsilon_r}} \cong 377 \sqrt{\frac{\mu_r}{\varepsilon_r}} \quad [\Omega] \quad (45)$$

kde,

μ_0 – permeabilita vakua,

ε_0 – permitivita vakua,

μ_r – komplexní relativní permeabilita materiálu cíle,

ε_r – komplexní relativní permitivita materiálu cíle.

Velikost odrazu od cíle závisí tedy také na typu použitého materiálu. Materiály se liší především svou permitivitou a permeabilitou, případně vodivostí. Parametry vybraných materiálů jsou v Tab. 12. Jsou zde také uvedeny absolutní hodnoty koeficientu odrazu. Tato veličina bude dále označována jako R_C .


Tab. 12: Materiálové parametry

Materiál	Reálná složka relativní permitivity ε_r	Relativní permeabilita: μ_r	Absolutní hodnota koeficientu odrazu: $R_C = \Gamma $
PP – Polypropylene[49]	2.3	1	0.2053
PS – Polystyrene[49]	2.55	1	0.2298
PET – Polyethylene Terephthalate[49]	3.5	1	0.3033
Polykarbonát, Uhlíkové nanokompozity, epoxidové kompozity[50]	10	1	0.5195
Kovy			$\cong 1$

Permeabilita dielektrických materiálů je obvykle rovna permeabilitě vakua. Kovy na rozdíl od předchozí skupiny jsou dobře vodivé. Na povrchu dokonale vodivého materiálu je elektrické pole nulové, takže koeficient odrazu Γ je pak roven -1.

4.6 Model šíření signálu volným prostorem

V této části práce se budu zabývat modelem šíření signálu volným prostorem. Signál vyslaný anténou s anténní charakteristikou $f^2(\theta, \varphi)$ radaru se šíří volným prostředím směrem k cíli. Sledovaný objekt s efektivní odraznou plochou σ odrazí tento signál s posunutou fází. Odražený signál po druhém průchodu volným prostorem signál dopadá zpátky na anténu, kde je přijat a zpracován.



Obr. 47: Šíření signálu volným prostorem

Vyslaný signál je reprezentovaný tzv. paprskem, Obr. 47. Každý z těchto paprsků se šíří ke každému bodu „odražeči“ svou cestou. Tím jsme schopni získat informaci o fázi, každého z těchto paprsků. Přijatý signál $E(t)$ odražený od objektu je dán následujícím vztahem:

$$E(t) = f^2(\theta, \varphi) \cdot \Gamma \cdot \sum_{n=1}^N e^{\frac{-4\pi i R_n + i \Psi_n}{\lambda}} \cdot \frac{\lambda \sqrt{\sigma_n}}{4\pi^{3/2} \cdot R_n^2} \cdot x\left(t - \frac{2R_n}{c}\right) \quad (46)$$

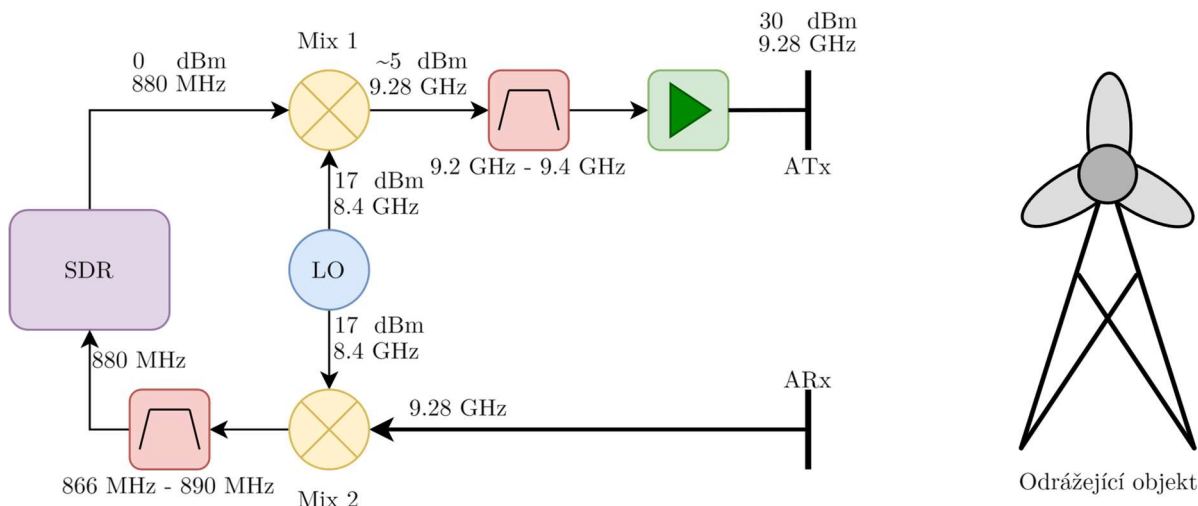
$$R_n = R_{n0} + v_n \cdot t \quad (47)$$

kde:

- R_n – jsou vzdušné vzdálenosti k jednotlivým odražečům,
- R_{n0} – je vzdušná vzdálenost k odražečům v okamžiku t_0 ,
- λ – je vlnová délka,
- $x(t)$ – je vyslaný signál,
- v_n – je radiální rychlost n -tého odražeče,
- f_0 – je nosná frekvence,
- N – je počet odražečů,
- σ_n – je efektivní odrazná plocha n -tého bodu,
- Ψ_n – je fáze odrazu od n -tého bodu.


5 Popis měřicího řetězce

Důležitou součástí této práce je navržení měřicího řetězce. Tento blok je navržen tak, aby umožňoval analýzu změn spektra odraženého signálu způsobených relativními pohyby částí měřeného objektu vůči vysílači. Nejprve popíšu strukturu tohoto zařízení podle Obr. 48. Zařízení má samostatné antény pro vysílač (ATx) a pro přijímač (ARx). Vysílací a přijímací cesta mají společný mikrovlnný místní oscilátor (LO) kvůli dokonalé koherenci vysílaného a přijímaného signálu. Směšovače Mix1 a Mix2 transformují kmitočet vysílaného signálu z mezifrekvence 880 MHz na vysílaný signál v pásmu 9.28 GHz a přijímaný mikrovlnný signál zpět na mezifrekvenci. Jádrem zařízení je softwarový rádiový přijímač/vysílač (SDR – Software Defined Radio), který generuje modulační signál pro vysílač a přijímá odražený signál, kmitočtově transformovaný do pásma 880 MHz. Dále provádí digitální zpracování přijatého signálu.



Obr. 48: Blokové schéma měřicího pracoviště

Ukázka takto zapojeného měřicího pracoviště je na Obr. 49.



Obr. 49: Měřící pracoviště

5.1 Softwarově řízené rádio (SDR)

Jádrem měřicího řetězce je softwarově řízené rádio (SDR) typ USRPX310, které slouží k digitálnímu zpracování přijímaného signálu i ke generování vysílaného signálu. Umožňuje flexibilní a přesné nastavení parametrů vysílaného signálu, jako je frekvence, šířka pásma a druh modulace, což je klíčové pro následné zpracování a analýzu. V Tab. 13 jsou uvedeny parametry vysílaného signálu.

Tab. 13: Parametry vysílaného signálu

Parametr	Hodnota	Jednotka
Druh modulace	FLAMENCO	-
Délka impulzu	20	μs
Opakovací frekvence – PRF	6000	Hz
Frekvenční zdvih – BW	1	MHz
Vzorkovací frekvence – f_S	10	MHz
Mezifrekvenční kmitočet – f_{mf}	880	MHz
Výstupní výkon	0	dBm

5.2 Směšování vysílaného signálu

Výstupní signál ze SDR se směšuje s místním oscilátorem LO. Tento krok je nezbytný pro posunutí frekvence signálu do vhodného pásma. Frekvence místního oscilátoru je nastavena tak, aby signál po směšování ležel frekvenčně ve středu výstupního filtru, a to v rozmezí 9200 MHz – 9400 MHz. Přesný kmitočet je dán následovně $Rf = f_c + f_{mf} = 8400 + 880 = 9280$ MHz.

5.3 Výstupní filtrace

Filtrace vysílaného signálu na výstupu směšovače je nezbytným krokem v signálovém zpracování. Hlavním důvodem je přítomnost parazitních kmitočtů po směšování. Směšovač je nelineární prvek, který vytváří parazitní kmitočty f_n : $f_n = f_c \pm n \cdot f_{mf}$; pro: $n \in \langle 1, 2, 3 \dots \infty \rangle$.

5.4 Výstupní zesílení

Posledním krokem vysílacího řetězce je zesílení signálu. O to se stará výkonový zesilovač– QPA0812, jehož zisk činí 25 dB. Úroveň výstupního signálu je nastavena na hodnotu 30 dBm.

5.5 Vstupní filtrace

Vstupní filtrace slouží ke zvýšení selektivity přijímače. Díky omezení šířky pásma se na vstup SDR dostane menší množství šumu, a tím se zvýší dynamika zpracování digitálního signálu. Bez použití tohoto filtru je pásmo omezeno pouze šířkou pásma vstupních obvodů SDR která činí 160 MHz.

5.6 Zpracování signálu

Zpracování přijatého digitalizovaného radarového signálu probíhá ve čtyřech hlavních krocích:

A) Uložení přijatého signálu do matice odběhů

Přijatý radarový signál je ukládán do matice $\mathbf{S} \in \mathbb{C}^{N \times M}$

kde:

N – je počet vzorků v jednom odběhu (odpovídá rozsahu měřené vzdálenosti),

M – je počet zaznamenaných odběhů (odpovídá časovému vývoji, tj. jednotlivým impulzům). Každý sloupec $\mathbf{s}_m = \mathbf{S}_{:,m}$ představuje jeden radarový odběh, každý řádek $\mathbf{S}_{n,:}$ pak odpovídá časové řadě amplitud na pevné vzdálenosti.

B) Přizpůsobená filtrace přes jednotlivé odběhy

Na každý sloupec matice \mathbf{S} , tedy jednotlivé odběhy \mathbf{s}_m , je aplikována přizpůsobená filtrace. Výsledkem je matice $\mathbf{S}_{\text{filt}} \in \mathbb{C}^{N \times M}$, kde $\mathbf{S}_{\text{filt}}(:, m) = \mathbf{s}_m * h$, přičemž h je impulsní odezva přizpůsobeného filtru.

C) Výběr vzdálenosti s maximální odezvou

Z matice \mathbf{S}_{flt} se pro každé měření identifikuje vzdálenost, na které je signál nejsilnější. Nejprve se pro každý řádek n vypočítá absolutní hodnota signálu v čase následujícím způsobem:

$$E_n = \sum_{m=1}^M |\mathbf{S}_{\text{flt}}(n, m)|^2 \quad (48)$$

Poté se určí index vzdálenosti s maximální hodnotou:

$$n_{\text{max}} = \arg \max_n (E_n) \quad (49)$$

Tento řádek $\mathbf{x} = \mathbf{S}_{\text{flt}}(n_{\text{max}}, :)$ představuje časovou řadu amplitud odpovídající vybrané vzdálenosti.

D) Výpočet spektrogramu

Ze získaného signálu $\mathbf{x} \in \mathbb{C}^{1 \times M}$, který reprezentuje vývoj amplitudy a fáze signálu v čase na pevné vzdálenosti, se vypočítá spektrogram pomocí metody, vybrané v kapitole 4.2.

5.7 Analýza blízké a vzdálené zóny

Při experimentálním ověřování μ -Dopplerových jevů v radarových systémech je nezbytné zajistit správné umístění cíle vzhledem k anténnímu systému, aby se měřené signály co nejvíce blížily podmínkám volného prostoru. Kritickým aspektem je určení, zda se cíl nachází ve vzdálené zóně (far-field, Fraunhoferova oblast), kde je elektromagnetická vlna již stabilizovaná a přibližně rovinná, což umožňuje validní analýzu spektra [51].

Elektromagnetické pole kolem antény se dělí na tři hlavní oblasti:

Reaktivní blízké pole (reactive near-field) : oblast těsně u antény, kde převažuje reaktivní energie a pole je silně nehomogenní. Je definována podmínkou:

$$R \leq 0.62 \sqrt{\frac{D^3}{\lambda}} \quad (50)$$

kde,

D – je největší rozměr antény,

λ – je vlnová délka.

Radiating near-field : oblast mezi reaktivní zónou a vzdáleným polem, kde je vlna částečně vyvinuta, ale stále není rovinná. Její horní mez je:

$$R \leq \frac{2D^2}{\lambda} \quad (51)$$

Pro daný experiment byly použity následující parametry:

Frekvence: $f_c = 9,28$ GHz

Rozměr antény: $D = 0.15$ m

Výpočet hranic jednotlivých zón

Reaktivní blízké pole:

$$R_{\text{reactive}} \leq 0.62 \sqrt{\frac{D^3}{\lambda}} = 0.62 \sqrt{\frac{(0.15)^3}{0.032}} \approx 0.20 \text{ [m]} \quad (52)$$

Přechod mezi blízkým a vzdáleným polem:

$$R_{\text{far-field}} \geq \frac{2D^2}{\lambda} = \frac{2 \times (0.15)^2}{0.032} \approx 1.39 \text{ [m]} \quad (53)$$

Experiment byl realizován v bezodrazové komoře, přičemž cíle byly umístěny ve vzdálenosti 2–3 [m] od antény. Tato vzdálenost překračuje minimální hranici 1.39 [m], a tedy splňuje podmínku pro Fraunhoferovu oblast. Díky tomu lze předpokládat, že elektromagnetická vlna dopadající na cíl byla prakticky rovinná, což minimalizuje chyby spojené s deformací vlnoplochy.

Z hlediska měření μ - Dopplerových jevů je toto kritické, protože rovinná vlna zajišťuje, že odražený signál odpovídá modelovým předpokladům pro extrakci frekvenčních složek. Pokud by byl cíl ve Fresnelově zóně, docházelo by k fázovým zkreslením a rozmazání spektrálních komponent.

6 Modely μ - Dopplerových spekter a porovnání s naměřenými daty


Tato kapitola je věnována μ - Dopplerovým spektrům cílů, zejména jejich rozdílům u jednotlivých typů cílů. Na základě odlišných rysů těchto spekter lze pak provádět klasifikaci cílů. Klíčem ke správné klasifikaci je tedy přesná analýza dopplerovských spekter obsahující i μ - dopplerovské kmitočty. Algoritmy a techniky strojového učení mohou pak i jemné rozdíly spekter využít ke správné klasifikaci cílů. Porozumění těmto spektrálním charakteristikám je klíčové pro úspěšnou identifikaci a klasifikaci cílů. Tato část práce se dá nejlépe realizovat na počítačových modelech, protože umožňují nastavení měřeného objektu do libovolné pozice a měnit jeho parametry ve velkém rozsahu. Naopak, měření skutečných zájmových objektů v reálných podmínkách (například vrtulníku) je nesmírně komplikované a drahé. Proto jsem zvolil následující postup: nejprve jsem vytvořil na základě reálných objektů modely, které lze snadno měřit v laboratoři (např. ventilátor). Na něm jsem ověřil shodnost modelu s experimentálními výsledky. Hlavním cílem modelu je získat podrobnou informaci o μ - Dopplerově jevu, který vzniká v důsledku rotace pohyblivých částí. V této práci se zaměřuji na provádění simulací stacionárních cílů. Tímto pojmem se rozumí, že se těžiště těchto cílů nepohybují. Prvotním úkolem je co nejdříve napodobit skutečná měření prováděná v bezodrazové komoře.

Vzhledem k tomuto kontextu je možné zanedbat některé parametry cílů, které by jinak mohly hrát významnější roli. Zvláště se jedná o parametry jako je aproximace tvaru trupu cíle a jeho efektivní odrazová plocha. Tyto faktory by mohly ovlivnit výsledky měření, avšak v tomto specifickém experimentálním prostředí mohou být považovány za zanedbatelné. V tuto chvíli je nutné co nejdříve reprodukovat μ - Dopplerovu informaci z rotujících částí, v rámci simulací stacionárních cílů v podmínkách omezeného prostoru bezodrazové komory.

Z důvodu praktické uskutečnitelnosti bude vždy volena velikost rozměrů cílů tak, aby co nejdříve reflektovala reálné cíle. Tímto přístupem bude zabezpečeno, že bude možné následně v dalších krocích snadno provádět srovnání výsledků získaných jejich měřeními, a to bez zbytečné potřeby upravovat nebo modifikovat získané výsledky.

6.1 Ventilátor

Analýza je zahájena ventilátorem, který představuje jeden z nejjednodušších modelových případů. Dříve, než se zaměříme na detailní charakteristiky μ -Dopplerových spekter, představím teoretický tvar spektra odvozený z analytického modelu. Následně bude tento teoretický předpoklad konfrontován s daty získanými měřeními a simulací. Očekávaný tvar spektrogramu odpovídá soustavě fázově posunutých harmonických funkcí. Jejich počet je roven N , přičemž jednotlivé složky mají vzájemný fázový posun ϑ (rovnice 35) a sdílejí stejnou úhlovou frekvenci f_y . Příklad takto odvozeného teoretického spektra je znázorněn na Obr. 50.




Obr. 50: Teoretický tvar spektrogramu ventilátoru

Zde si můžeme všimnout sinusových příspěvků od jednotlivých listů ventilátoru. Obecně platí, že počet harmonických příspěvků ve spektrogramu bude odpovídat počtu rotujících listů–lopatek ventilátoru. Reálný spektrogram bude nabývat mnohem složitějšího tvaru (např. Obr. 51) v důsledku tzv. flash (odst. 4.2) tvarů jednotlivých listů a vícenásobných odrazů.

6.1.1 Porovnání reálných měření a simulovaných dat

Pokud přejdeme k porovnání reálných dat a simulací, ukážeme si nejprve silné a slabé stránky navrženého simulátoru. Dále se zaměříme na výzvy spojené se zpracováním a porovnáváním spektrogramů a na závěry, které z těchto zjištění vyplývají pro budoucí práci. Jako první příklad představíme spektrogramy ventilátoru, kde jsou dobře viditelné lopatky. Díky relativní jednoduchosti jejich tvaru je možné pozorovat tři harmonické průběhy ve frekvenčním spektru. Z Obr. 51 je na první pohled patrné, že výsledné spektrogramy jen velmi vzdáleně

připomínají teoretický tvar ukázaný na Obr. 50. Důvod leží v dynamice signálu. Maximální signál představuje odraz od statických částí bezodrazové komory a cíle i přeslech antény. Toto se projeví ve frekvenčním spektru jako maximum na nulovém kmitočtu, viz Obr. 52. Měřitelné minimum je dáno šumem na vstupu přijímače. Mezi těmito úrovněmi se nachází zájmové μ - Dopplerovo spektrum. Na Obr. 51 jsou uměle zdůrazněné harmonické průběhy popsané na modelu (Obr. 50).



Obr. 51: Spektrogram měřeného objektu (Vlevo), spektrogram simulace (Vpravo)

Pro porovnání jednotlivých spektrogramů lze uvažovat následující postupy:

A) Porovnání časové periodicity lokálních extrémů

Jednou z možností je analyzovat periodicitu výskytu lokálních maxim a minim v čase, které jsou v μ - Dopplerově spektru důsledkem rotujících částí UAV (např. vrtulí). Tuto periodicitu lze kvantitativně porovnat mezi spektrogramem získaným z měřeného signálu, výstupem simulace a referenční hodnotou frekvence otáčení vrtule f_y , která je uvedena v Tab. 8. Tímto způsobem lze ověřit, zda dochází ke konzistenci mezi měřeními, simulovanými a teoreticky očekávanými charakteristikami periodických složek signálu.


Po odečtení hodnot $T_{y1} = 60$ ms a $T_{y2} = 60$ ms vidíme, že perioda otáčení pro simulaci a měření je naprosto shodná. Vypočtená hodnota frekvence otáčení je rovna $f_{y1,2} = 16.66$ Hz. V porovnání se zadanou hodnotou Tab. 8, je procentuální rozdíl roven 3.4 %.

B) Porovnání amplitudového rozsahu μ - Dopplerových spekter

Další možností porovnání je analýza amplitudového rozsahu μ - Dopplerových složek mezi jednotlivými spektrogramy. Z grafického odečtu vyplývá, že šířka spektra činí $\Delta f_1 = 1900$ Hz u měřeného signálu a $\Delta f_2 = 2200$ Hz u simulace.

Ještě před interpretací tohoto rozdílu je vhodné určit teoreticky očekávanou maximální Dopplerovu frekvenci pomocí rov. 21. Po dosažení vychází $f_d = \pm 1206 \Rightarrow \Delta f_d = 2412$ Hz. Tato vypočtená hodnota je zřetelně bližší šířce spektra Δf_2 , která odpovídá simulaci. Naopak Δf_1 , získaná z měření, je výrazně menší. Hlavním faktorem, který tento rozdíl pravděpodobně způsobuje, je geometrie lopatky vrtule.

Vliv tvaru lopatky je podrobněji rozebrán v kapitole 6.2.2. Ve stručnosti lze říci, že specifický profil lopatky způsobuje, že odrazná plocha na jejím konci (tedy v oblasti, kde se dosahuje nejvyšších Dopplerových frekvencí) je velmi malá. V důsledku toho se energetický příspěvek od těchto částí vrtule ve spektrogramu výrazně snižuje.



Obr. 52: Boční pohled na spektrogram měřeného objektu (Vlevo), simulace (Vpravo)

6.2 Dron

Druhým příkladem je dron. Zde se podrobněji zaměřím na další vlivy, komplikující tvar výsledných spekter a pokusím se vysvětlit důvody jejich vzniku.

6.2.1 Parametry modelu

Uvažujme dron s M vrtulemi, kde každá z vrtulí má N listů. Každá z M vrtulí generuje ve spektru N harmonických funkcí, které lze vyjádřit následujícím vztahem:

$$S_{m,n}(t) = \cos\left(\omega_m t + \frac{2\pi n}{N} + \theta_m\right) \text{ pro: } \theta_m \in \langle 0; 2\pi \rangle \quad (54)$$


kde:

θ_m – je náhodná počáteční fáze natočení m -té vrtule,

f_m – je úhlová frekvence m -té vrtule,

n – je pořadí listu ve vrtuli.

Předpokládáme, že se každá vrtule může otáčet jinou frekvencí f_m . Ukázka průběhů $S_{m,n}(t)$ při $N = 3$, $M = 4$ je na Obr. 53.



Obr. 53: Teoretický tvar spektrogramu: Průběhy funkce $S_{m,n}(t)$ podle (45), $N = 3$, $M = 4$.

Tečkované elipsy upozorňují na místa s vysokou nebo naopak s nízkou hustotou křivek

Teoretický spektrogram dronu je Obr. 53, i za zjednodušených podmínek, velmi komplikovaný. V závislosti na počtu vrtulí a listů mohou být v takovém spektru přítomny řádově jednotky až desítky harmonických funkcí. Množství harmonických funkcí s různou fází vytváří oblasti s vysokou hustotou harmonických funkcí (označeno červeně tečkovaně) a oblasti, které jsou relativně prázdné (označeno tečkovaně modře). Všechny tyto příspěvky v čase navzájem vytvářejí periodicky se opakující tzv. „hot spoty“. To, jestli ve finálním spektru uvidíme, jen „hot spoty“ nebo prokreslené harmonické funkce, závisí na parametrech signálového zpracování. Tímto je myšlena především opakovací frekvence PRF. Z tohoto důvodu budou mít spektra dronu formu periodicky se opakujících maxim a minim, Obr. 54 (vlevo).


6.2.2 Porovnání reálných měření a simulovaných dat

Na Obr. 54 jsou znázorněna měřená a simulovaná μ -Dopplerova spektra, ve kterých jsou zřetelně patrná periodicky se opakující lokální maxima a minima. Časové intervaly mezi jednotlivými maximy jsou označeny jako T_{x1} a T_{x2} . Ze spektrogramu byly tyto intervaly experimentálně určeny jako $T_{x1} = 10$ ms a $T_{x2} = 11$ ms.

Na základě těchto hodnot je velmi obtížné zpětně určit rychlost otáčení lopatek dronu. Důvodem je náhodnost spektrogramu vysvětlená na Obr. 53.


Přesto však lze konstatovat, že hodnoty intervalů T_{x1} a T_{x2} jsou si dostatečně blízké na to, aby podpořily závěr, že zvolený přístup k simulaci spektrogramu generuje výsledky, které jsou realistické a odpovídají charakteru reálného měření. Tato shoda představuje důležitý potvrzení validity použitého modelu.

S definitivním závěrem o vhodnosti a validitě tohoto přístupu však vyčkám až do kapitoly 8 – Klasifikace, kde bude ověřeno, zda simulovaná data vedou ke správnému rozpoznání a zařazení objektů pomocí navrženého klasifikačního modelu.




Obr. 54: Spektrogram měřeného objektu (Vlevo), spektrogram simulace (Vpravo) – PRF = 6000

U Obr. 55 vlevo je vidět další jev v měřeném spektru. Tím je nesymetrie spektra podle frekvenční osy: kladné frekvence ve spektru mají sestupný trend, zatímco záporné tolik neklesají. Takové chování spektra způsobuje specifický tvar lopatek a jejich natočení vůči radaru.



Obr. 55: Boční pohled na spektrogram měřeného objektu (Vlevo), simulace (Vpravo)

Na příkladu dvoulisté vrtule Obr. 56 tento jev je vysvětlen podle [52].




Obr. 56: Odraz vlny od vrtule dronu

Vyslaná vlna dopadá na takovýto objekt ze směru od radaru (označeno černým vektorem \mathbf{R}_0). Vrtule se otáčí ve směru šedé šipky. Vzduch zde proudí shora dolů. List vlevo od osy rotace se od radaru vzdaluje a odrazy od něj mají záporný Dopplerův posun (viz rov. (13)). U listu vpravo je to opačně. Čím dále je místo odrazu od osy rotace, tím vyšší je obvodová rychlost odrážejícího bodu a tím větší je absolutní hodnota Dopplerova posuvu, což ve spektru odpovídá větší vzdálenosti od osy ($f_d = 0$). Z náhledu je zřejmé, že v tomto směru pohledu (částečně shora, ze směru nasávání vzduchu) odrazný profil listu vůči radaru se ze vzdáleností od osy rotace příliš nemění, zatímco u přibližujícího se listu směrem ke konci listu rychle klesá. Proto bude spektrum Dopplerových kmitočtů vrtule v tomto případě v oblasti kladných kmitočtů klesat rychleji, než v oblasti záporných kmitočtů (Obr. 55). Při pohledu z opačné strany (zespoda, z výtlačné strany) tomu bude naopak (ukážu na modelování a měření ventilátoru). Je nutné podotknout, že složitý tvar lopatky

je v simulaci aproximován jako rotační elipsoid. Proto by byly vypočtené spektrogramy symetrické Aby se modely více přiblížily skutečnému stavu jsou vypočtené spektrogramy vrtulových cílů jednostranně váhovány (lineární pokles). Výsledek této metody je vidět např. na Obr. 55 vpravo.

6.3 Jízdní kolo

Dalším typem zkoumaného objektu je jízdní kolo. Opět se zaměřím na vysvětlení zvláštností ve spektru, jejich vzniku a vše porovnam se simulátorem. Ještě, než se dostaneme k porovnání spekter, podívejme se na teoretický tvar spektra vycházející z (45), Obr. 57.



Obr. 57: Teoretický tvar spektra jízdního kola

Na první pohled patrné, že je spektrum velmi hustě pokryto harmonickými funkcemi. Je nutno podotknout, že se díváme pouze na jedno otáčející se kolo. Výsledná spektra budou nabývat pouze periodicky se opakujících maxim, jak je tomu ukázáno na Obr. 58 a Obr. 59.


6.3.1 Porovnání reálných měření a simulovaných dat

V tomto případě se simulátoru daří velmi přesně aproximovat reálné μ - Dopplerovo spektrum. Na Obr. 58 jsou zřetelně identifikovatelná periodicky se opakující lokální maxima spektrální intenzity. Na Obr. 59 je pak dobře patrné symetrické rozložení spektra vzhledem k nulové Dopplerově frekvenci.


Tato spektrální symetrie je důsledkem přítomnosti konstrukčních prvků s axiálně symetrickým pohybem – konkrétně jde o dráty s kruhovým průřezem tvořící výplet

kola. Tyto dráty vytvářejí při rotaci μ - Dopplerovy složky, jejichž pozitivní a negativní části mají z fyzikálního hlediska shodnou amplitudu.

Nyní se podívejme na periodicitu lokálních maxim a minim. Z měření byly extrahovány následující časové intervaly: $T_{x1} = 12$ ms a $T_{x2} = 16$ ms. V tomto případě je procentuální rozdíl 25 %. Důvod toho, proč je rozdíl o něco vyšší než v ostatních případech, jsem vysvětlil ve způsobu a problematice s měřením reálného spektrogramu pod Tab. 11.



Obr. 58: Spektrogram měřeného objektu (Vlevo), spektrogram simulace (Vpravo)



Obr. 59: Boční pohled na spektrogram měřeného objektu (Vlevo), simulace (Vpravo)

7 Rozbor výsledků

Tato kapitola se zaměřuje na spektrální charakteristiky jednotlivých objektů, které mohou sloužit jako identifikační znaky pro klasifikaci. Dále je analyzován vliv změn orientace cíle vůči radaru, konkrétně naklonění θ a natočení φ , na tvar μ -Dopplerova spektra. Tyto změny ovlivňují projekci rychlostí do směru pozorování a tím i celkové spektrální rozložení. Prezentovány jsou vybrané výsledky měření, úplný přehled je uveden v Příloze A.

Nejdříve si řekněme, jaký vliv na velikost μ -Dopplerova spektra mají úhly naklonění θ a natočení φ . Vyděme z rovnice 21 a vhodně upravme její tvar do následujícího tvaru:

$$f_d = \pm 2f_0 \frac{2\pi f_{ot} l_b}{c} \sin(\theta, \varphi) \quad (55)$$

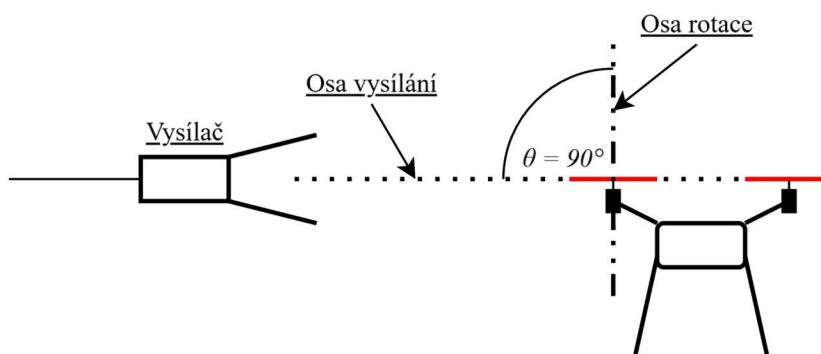
kde,

θ, φ – jsou úhly natočení a naklonění.

Pozn. význam těchto úhlů, pro samotný výpočet je identický. Jediný rozdíl je ve smyslu použití. Pro ventilátor a kolo má smysl uvažovat pouze φ , zatím co pro dron se uvažuje pouze θ .

7.1 Dron


Postupně byly testovány různé hodnoty frekvence otáčení vrtule f_y , konkrétně 14.8, 28.1, 53.2 a 85.8 Hz. Pro zvýšení odrazivosti je testovaný dron nakloněn pod úhlem $\theta = 75^\circ$ mezi osou vysílání a osou rotace (Obr. 60), čímž došlo k exponování větší plochy lopatek vůči radarovému paprsku (viz Obr. 38 vpravo).




Obr. 60: Ukázka orientace osy vysílání a měřeného objektu, pohled z boku (bokorys)

U tohoto scénáře nebyla provedena měření z různých azimutálních směrů z důvodu, že změna azimutálního úhlu pozorování neměla vliv na tvar μ - Dopplerova spektra.

Pro uvedené frekvence byly pomocí rovnice (51) vypočteny hodnoty maximálního Dopplerova posuvu následovně: $\pm f_d \cong 500, 950, 1799$ a 2901 Hz. Obr. 61 a Obr. 62 znázorňují vývoj tvaru spektrogramu v závislosti na rostoucí frekvenci otáčení vrtule. Je zde dobře patrný asymetrický jev, podrobně popsany v kapitole 6.2.2 (viz Obr. 61): spektrum v oblasti záporných Dopplerových frekvencí má výrazně větší šířku pásma a intenzitu než jeho kladná část. Tento efekt je způsoben geometrií lopatek a směrovostí odrazu v kombinaci s orientací cíle vůči radaru.



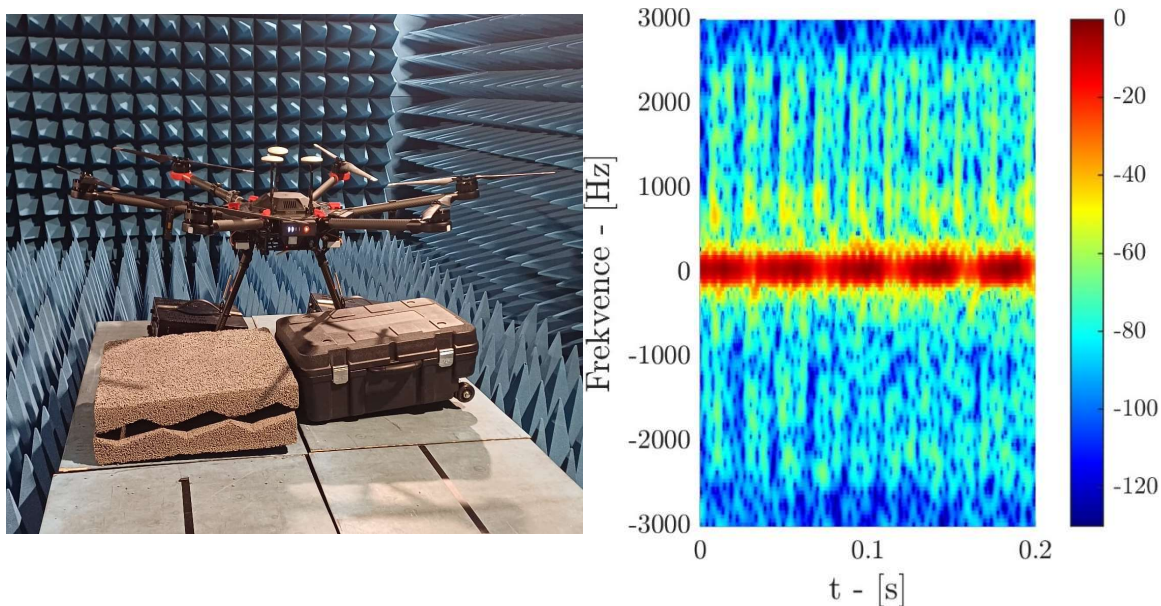
Obr. 61: Měření 1 – $f_z = 14.8$ Hz (Vlevo), měření 2 – $f_z = 28.1$ Hz (Vpravo)



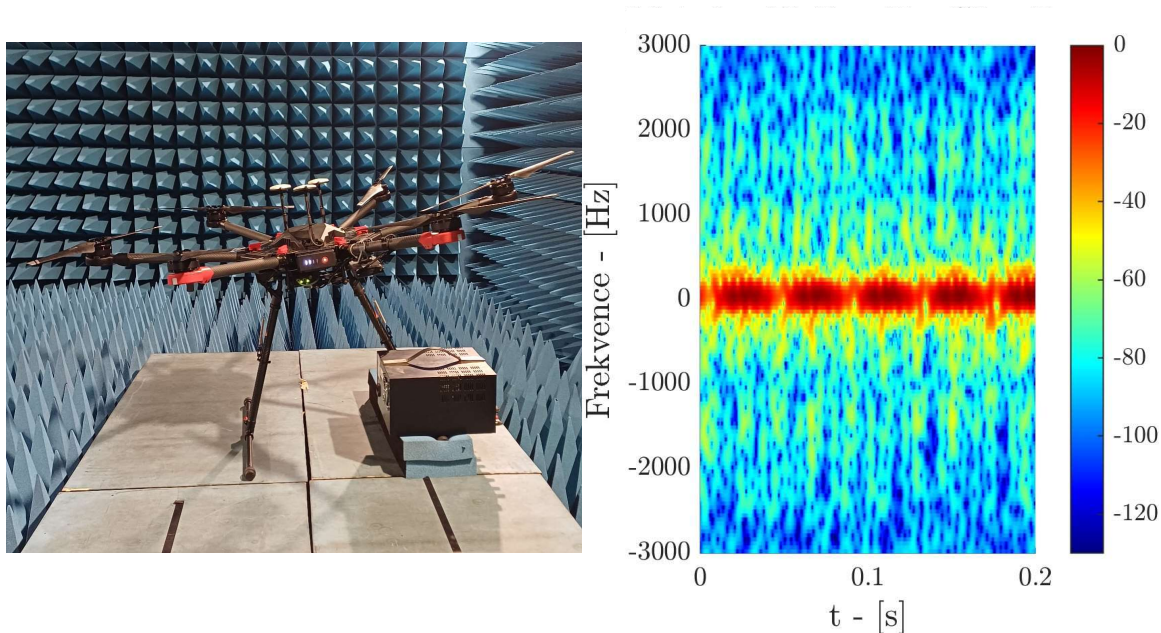
Obr. 62: Měření 1 – $f_z = 53.2$ [Hz] (Vlevo), měření 2 – $f_z = 85.8$ [Hz] (Vpravo)

Druhým testovaným dronem je MATRICE-600 PRO. Jedná se o komerční dron s délkou listů 27 cm s $N=2$ listy a $M=6$ vrtulemi. V tomto pokusu byla zkoumána závislost naklonění dronu vůči vysílači, pro $\theta = 90^\circ, 82^\circ$ a 75° . Frekvence otáčení vrtulí je v tomto případě konstantní $f_z = 23.8$ Hz. Pro uvedené θ byly pomocí rovnice (51) vypočteny hodnoty maximálního Dopplerova posuvu následovně: $\pm f_d \cong 2500, 2485, 2414$ Hz.

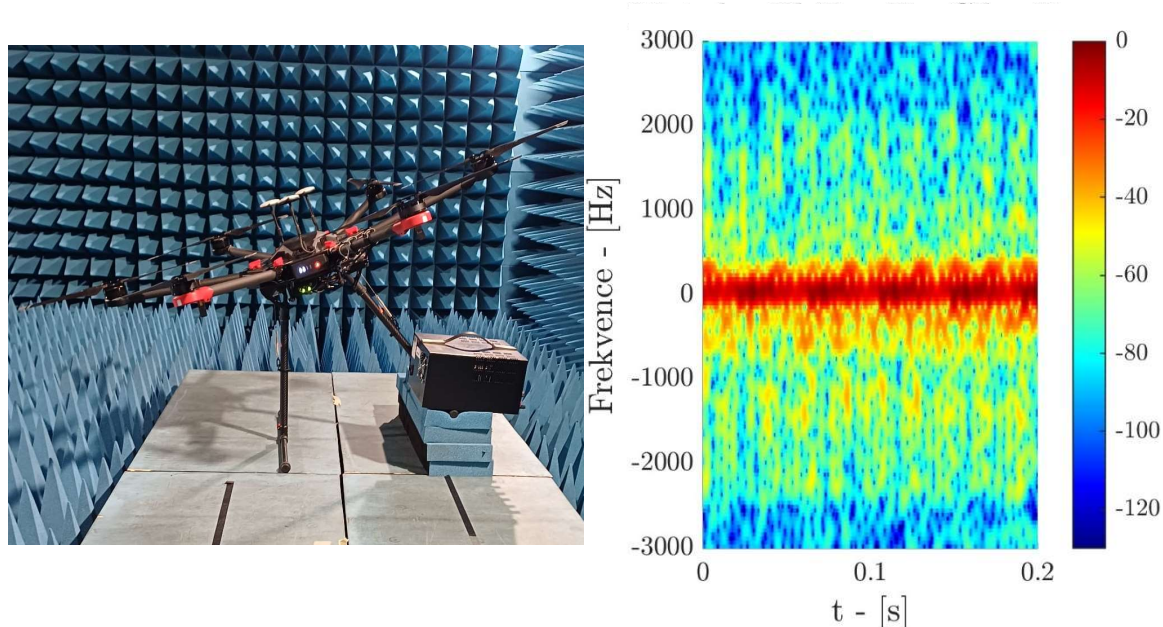
Dron musel být zabezpečen proti nechtěnému uvolnění a případnému poškození vybavení bezodrazové komory. Na Obr. 63, Obr. 64 a Obr. 65 jsou ukázky MATRICE-600 PRO s výše uvedenými úhly naklonění a jejich spektrogramy.



Obr. 63: Dron typu MATRICE-600 PRO – $\theta = 90^\circ$ (vlevo), spektrogram (vpravo)



Obr. 64: Dron typu MATRICE-600 PRO – $\theta = 82^\circ$ (vlevo), spektrogram (vpravo)




Obr. 65: Dron typu MATRICE-600 PRO – $\theta = 75^\circ$ (vlevo), spektrogram (vpravo)

Zvyšující se úhel θ má za následek pozvolný pokles velikosti μ - dopplerovských kmitočtů. Přínosem je zvýšení intenzity odrazu, protože se se zvětšujícím úhlem θ současně zvětšuje odrazná plocha jednotlivých listů.


7.2 Kolo

Zde uvádím výsledky měření spektra roztočeného kola při různém natočení kolem vertikální osy vůči vysílači. Parametry jízdního kola jsou popsány v kapitole 4.3.3, Tab. 11. Úhel natočení φ je úhel mezi osou vysílání –a osou rotace kola, viz Obr. 66.




Obr. 66: Ukázka orientace osy vysílání a osy měřeného objektu, pohled se shora (půdorys)

Pro různá natočení kola vůči vysílači je spektrum symetrické a má při podrobném prohlédnutí stejnou strukturu složenou z jednotlivých maxim. Tato vlastnost může být základem pro klasifikaci objektu pomocí μ - Dopplerova spektra. Nyní se podívejme na případy spekter pro různé úhly natočení $\varphi = 10^\circ, 30^\circ, 50^\circ$ a 90° . Pro uvedené φ byly pomocí rovnice (51) vypočteny hodnoty maximálního Dopplerova posuvu následovně: $\pm f_d \cong 94, 272, 417$ a 544 Hz.



Obr. 67: Měření 1 – $\varphi = 10^\circ$ (vlevo), měření 2 – $\varphi = 30^\circ$ (vpravo)




Obr. 68: Měření 3 – $\varphi = 50^\circ$ (vlevo), měření 4 – $\varphi = 90^\circ$ (vpravo)

Výsledný spektrogram je symetrický kolem nulových dopplerovských kmitočtů. Tato symetrie není závislá na natočení jízdního kola v azimutu, čehož bude využito při klasifikaci. Průběh spektra pro pozorovací úhly větší jak 90° je stejný jako v případě pozorování do 90° . Výsledky dalších měření jsou uvedeny v příloze C.


7.3 Ventilátor

Zde uvádím vybrané výsledky měření spektra ventilátoru v závislosti na úhlu natočení φ viz Obr. 69.




Obr. 69: Ukázka orientace osy vysílání a osy měřeného objektu, pohled ze shora (půdorys)


V tomto případě, na rozdíl od kola, můžeme vidět, že spektrogram není vždy symetrický vůči nulovému kmitočtu. Při pohledu ze strany výtlačku vzduchu (Úhel natočení $\varphi = 90^\circ$) je mohutnější pro kladné Dopplerovy kmitočty a při měření ze strany nasávání vzduchu (Úhel natočení $\varphi = 180^\circ$) je mohutnější na straně záporných Dopplerových kmitočtů, jak už bylo vysvětleno v kapitole 6.2.2. Pro úhly mezi 30° až 120° je nesymetrie spekter málo výrazná. Tyto jevy jsou postupně ukázány na Obr. 71, Obr. 72 a Obr. 73. Ukázka ventilátoru je na Obr. 70.




Obr. 70: Ukázka experimentálního měření ventilátoru



Obr. 71: Měření 1 – $\varphi = 0^\circ$ (vlevo), měření 2 – $\varphi = 30^\circ$ (vpravo)



Obr. 72: Měření 3 – $\varphi = 60^\circ$ (vlevo), měření 4 – $\varphi = 90^\circ$ (vpravo)



Obr. 73: Měření 5 – $\varphi = 120^\circ$ (vlevo), měření 6 – $\varphi = 150^\circ$ (vpravo)

Pro jednotlivé úhly $\varphi = 0^\circ, 30^\circ, 60^\circ, 90^\circ, 120^\circ, 150^\circ$ jsou očekávané Dopplerovy posuvy. $\pm f_d \cong 0, 603, 1045, 1206, 1045$ a 603 Hz. Z definice funkce \sin v rov. (51) bude mít Dopplerův posuv hodnotu $\pm f_d \cong 0$ Hz, pro $\varphi = 0^\circ$. Nicméně na Obr. 71 (vlevo) spektrogram obsahuje i nenulové Dopplerovy kmitočty. Toto může být způsobeno malým odchýlením osy rotace vrtule od spojnice s radarem. Nesymetrie spektra kolem nulového Dopplerova kmitočtu pak souvisí se specifickým tvarem lopatek.

8 Klasifikace

V běžné praxi se ke klasifikaci využívá dvou hlavních přístupů:

- A) „Klasické“ statistické/metrické přístupy nad příznaky či přímo nad obrazy, vzdálenosti, korelace a šablonové porovnávání.
- B) Hluboké neuronové sítě operující nad spektrogramy CNN/TCN, Siamese/kontrastní učení, transfer learning.

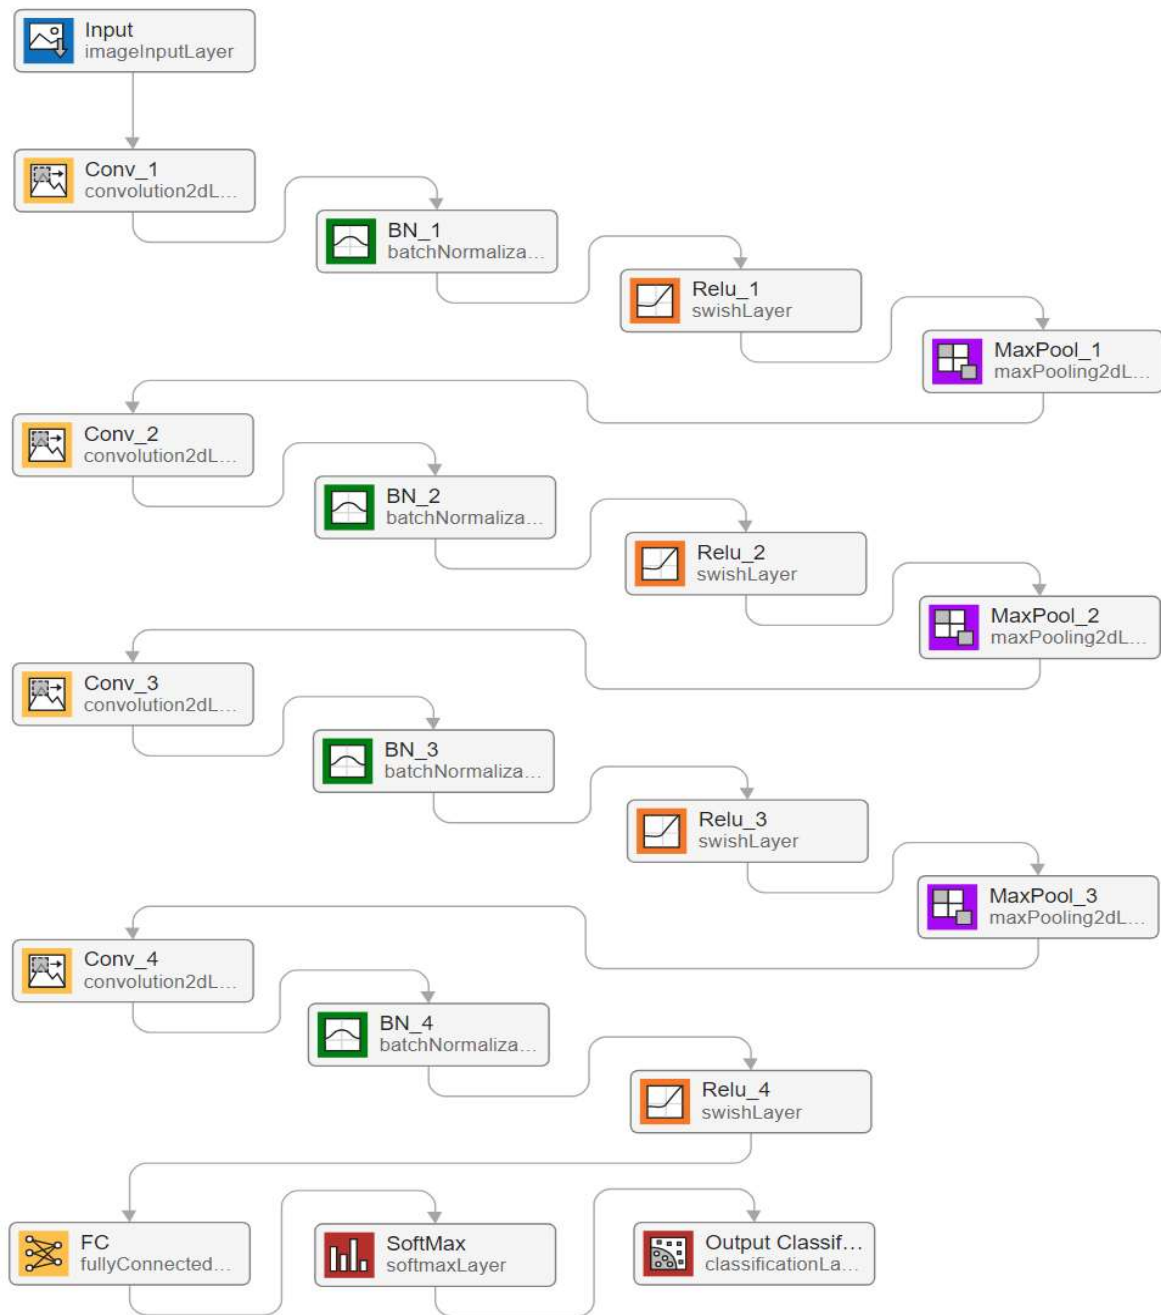
Statistické a metrické metody

Typicky se extrahují příznaky ze spektra/spektrogramu (energetické momenty, entropie, periodičita), provádí se snížení dimenze (Principal Component Analysis – PCA, Linear Discriminant Analysis – LDA) a klasifikuje se pomocí (k-Nearest Neighbors – k-NN, Support Vector Machine – SVM). Pro robustnost vůči malým posunům v čase se používá také Dynamic Time Warping – DTW či korelační/strukturální metriky podobnosti (Structural Similarity Index – SSIM) přímo nad spektrogramy [52]–[55].

Hluboké učení

Konvoluční neuronová síť (CNN) se na spektrogramu (analogicky k obrazu) učí přímo diskriminativní rysy, čímž překonává ručně navržené příznaky, které by člověk vytvořil na základě doménových znalostí. Temporal Convolutional Network – TCN a kombinace 1D-CNN + Gated Recurrent Unit – GRU modelují časovou dynamiku. Nově se také uplatňují (Swin/Vision) Transformers a dvouproudé architektury (spektrogram + odvozené reprezentace). Důležitou roli hrají simulace a augmentace μ - Dopplerových dat (Auxiliary Classifier GAN – ACGAN, Generative Adversarial Network – GAN), stejně jako denoising/restaurování spektrogramů pro zvýšení podobnosti „měření \leftrightarrow simulace“ a stability klasifikace [56]–[60].

Cílem klasifikace je především odlišit drony od jiných předmětů a tím minimalizovat rozsah dat, předávaných dalším systémům (například optickým) k podrobné klasifikaci a identifikaci. Abych ukázal, že popisovaným způsobem lze získat data, která mohou být k této funkci u objektů s rotujícími částmi použita, sestavil jsem demonstrační neuronovou síť pro klasifikaci tří studovaných objektů [61]. Data pro trénink byla získána ze simulací objektů a verifikační data byla jednak jiná data ze simulací, jednak data získaná měřením spekter objektů. Na Obr. 74 vidíme architekturu použité neuronové sítě.



Obr. 74: Architektura neuronové sítě

První vrstvou je vstupní vrstva, jejímž úkolem je definovat rozměr vstupní datové matice jednoho obrázku. V našem případě to je matice o rozměru $\mathbf{H} = k \times l \times m$, kde $k = 128$, $l = 2048$ a $m = 2$. Rozměr k , reprezentuje rozlišení v Dopplerovu posuvu. Jedna buňka odpovídá rozlišení dané následující rovnicí:

$$df = \frac{PRF}{k} \cong 47 \text{ [Hz]} \quad (56)$$

Hodnoty l reprezentují časovou historii. Časový úsek odpovídající této hodnotě je $t_l = 330 \text{ ms}$. Na základě analýz spektrogramů provedených v kap. 6 je nejdelší

periodicita lokálních extrémů rovna $T_{y_1} = 60$ ms (ventilátor). Pro případy dronu a jízdního kola jsou tyto periodicity mnohem kratší (11 – 16 ms) respektive. Na základě této znalosti považují zvolené l za dostatečné.

Důvodem, proč rozměr $m = 2$, je to, že připravené spektrogramy obsahují komplexní čísla. Reálné a imaginární složky jsou rozděleny a vstupují do neuronové sítě jako třetí rozměr matice \mathbf{H} .

Druhou vrstvou je 2D konvoluční vrstva. Tato vrstva je zodpovědná za detekci lokálních rysů (např. hran, textur) pomocí učících se neuronů, které tyto vzory v obraze zachycují. Velikost filtru této vrstvy je zvolen na 3×3 , s počtem filtrů 8. Je nutné podotknout, že „padding“ je nastavený na „same“ tak, aby zůstal zachovaný rozměr matice po filtraci.

Třetí vrstvou je normalizační vrstva. Tato vrstva pomáhá zlepšit efektivitu a stabilitu trénování pomocí normalizace vstupů do následující vrstvy.

Následující vrstvou je ReLU. Tato vrstva je jednou z nejpoužívanějších aktivačních vrstev v neuronových sítích. Vnáší do modelu nelinearitu, která je rozhodující pro to, aby se neuronové sítě mohly z dat učit složité vzory [62]. Konkrétní aktivační funkce byla zvolena tzv. „Swish“, s touto funkcí bylo dosaženo nejlepších výsledků klasifikace. Swish funkce je definována následovně:

$$f(x) = \frac{x}{1 - e^x} \quad (57)$$

Poslední základní vrstvou je „MaxPooling“. Jedná se o typ vrstvy, ve které se provede decimace vstupních dat. Cílem je zmenšení rozměrů $k \times l$ vstupních dat, což vede ke snížení výpočetní náročnosti sítě.

Popsaná sekvence vrstev se čtyřikrát opakuje pro cyklickou extrakci dominantních rysů ve vstupním signálu. Na konci této kaskády je pak trojice výstupních vrstev. Tyto vrstvy jsou následující.

„FullyConnected“ je typ vrstvy v neuronových sítích, kde je každý neuron ve vrstvě propojen s každým neuronem v předchozí vrstvě. Jedná se o jednu z posledních vrstev v mnoha architekturách neuronových sítí, zejména v klasifikačních, protože kombinuje všechny rysy získané předchozími vrstvami a transformuje tyto rysy na požadované predikce.

Předposlední vrstvou je „SoftMax“. Tato vrstva převádí hrubé výstupní skóre (nazývané také logity – „logit“) z předchozí vrstvy na pravděpodobnosti, takže výstup lze interpretovat jako rozdělení pravděpodobnosti pro více tříd.

Poslední vrstvou je vrstva klasifikační. Vstupem do této vrstvy je obvykle vektor pravděpodobností tříd generovaný předchozí aktivační funkcí. Výstupem klasifikační vrstvy je předpovězená třída na základě pravděpodobností [63]–[64].

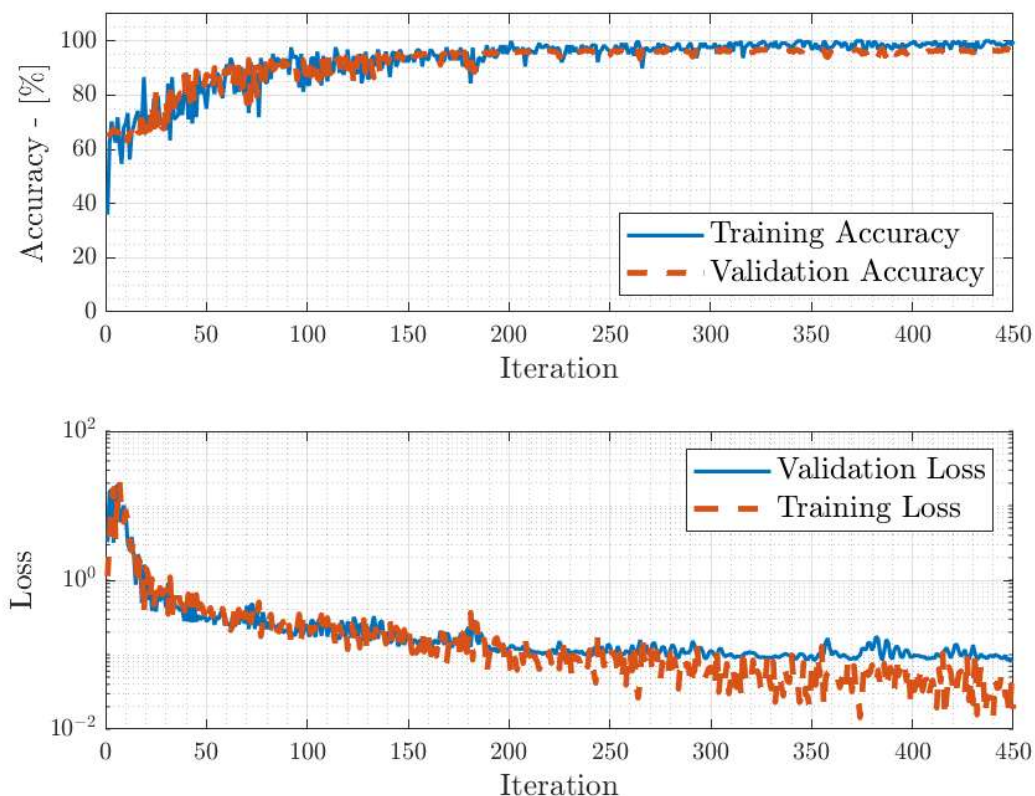
Podrobnější rozbor neuronové sítě je v příloze D.

Celkem bylo simulátorem vytvořeno 3000 spektrogramů, kdy zastoupení jednotlivých objektů (dron, kolo, ventilátor) bylo shodné. Pro trénink byla tato data dále rozdělena do dvou skupin a to následovně: První tzv. učící skupina obsahovala 800 spektrogramů pro každý objekt. Druhá tzv. validační skupina obsahovala zbývající data, tedy 200 spektrogramů pro každý objekt. Variace mezi jednotlivými daty jsou tvořeny tak, že je vždy zvolen náhodný úhel natočení cíle v azimutu φ , elevaci θ a náhodná frekvence otáčení vrtulí a kola. V Tab. 14 je shrnuto nastavení sítě.

Tab. 14: Nastavení sítě

Parametr	Hodnota
Učící algoritmus	SGDM
Koeficient rychlosti učení	1E-3
Ztrátová funkce	Cross-Entropy
Randomizace dat	každou epochu
Počet epoch	25
Validační frekvence	30

Proces učení je ukázán na Obr. 75.



Obr. 75: Proces učení sítě

Zde si můžeme všimnout, jak v průběhu učení se zvyšuje přesnost klasifikace a klesá ztráta. Přesnost je měřítkem toho, kolik předpovědí ze všech předpovědí model správně vyhodnotil. V následující rovnici je popsáno, jakým způsobem se tato hodnota vyjádří.

$$\text{Přesnost} = \frac{\text{Počet správných predikcí}}{\text{Celkový počet dat}} = \frac{1}{p} \sum_{i=1}^p 1(\hat{y}_i == y_i) \quad (58)$$

kde,

p – je celkový počet dat,

\hat{y}_i – je predikovaná značka i -tého data,

y_i – je skutečná značka i -tého data,

$1(\cdot)$ – je indikátor výsledku funkce. Správná predikce = 1, chybná predikce = 0.

Dále proces učení zobrazuje ztrátovou funkci. Ztrátová funkce kvantifikuje chybu mezi předpovídanými hodnotami modelu a skutečnými cílovými hodnotami. Jedná se o funkci, kterou se proces trénování snaží minimalizovat. V prostředí MATLAB se používají různé ztrátové funkce v závislosti na typu problému. Pro klasifikace se standardně používá tzv. „Cross-Entropy“, její vyjádření je v následujícím vztahu:


$$Loss = - \sum_{i=1}^C y_i \log(p_i) \quad (59)$$

kde,

C – je počet tříd,

p_i – je predikovaná pravděpodobnost, že vstupní data patří do i -té třídy.

Dosaženou úspěšnost metody klasifikace, založené na měření μ - Dopplerova spektra, lze posoudit z matic záměn na Obr. 76.



Obr. 76: Matice záměn pro validační data ze simulátoru (vlevo), matice záměn pro měřená data (vpravo)

Tyto matice vyjadřují, míru úspěšných a neúspěšných klasifikací. Způsob, jakým se čte v těchto maticích je následovný. Hodnoty na hlavní diagonále vyjadřují úspěšné klasifikace a hodnoty mimo vyjadřují chybné klasifikace. Celková úspěšnost je pak vyjádřena následovně:

$$P = \frac{\sum_{i=1}^n \mathbf{A}_{ii}}{\sum_{i=1}^n \sum_{j=1}^n \mathbf{A}_{ij}} \quad (60)$$

kde,

\mathbf{A}_{ii} – jsou hodnoty na hlavní diagonále matice záměn,

\mathbf{A}_{ij} – jsou všechny hodnoty obsažené v této matici,

P – je míra úspěšnosti klasifikace.

Posledním krokem je číselné vyjádření úspěšností klasifikací pro validační a měřená data.

Úspěšnost klasifikace na validačních datech je $P = \frac{582}{600} = 0.97 \rightarrow 97\%$.

Úspěšnost klasifikace na reálných datech je $P = \frac{55}{61} = 0.901 \rightarrow 90.1\%$.

Závěr

Cílem této práce bylo zlepšení klasifikace a detekce zájmových objektů, zejména UAV, pomocí pokročilé analýzy μ - Dopplerova spektra získaného z radarového signálu.

Prvním krokem bylo provedení rešerše současných radarových systémů, určených k detekci dronů. Zde jsem ukázal soubor tuzemských a zahraničních výrobců těchto systémů, zabývajících se problematikou detekce a klasifikace UAV s využitím μ - Dopplerova jevu (kapitola 2). Výsledkem této rešerše bylo vyhodnocení převážně používaných nosných kmitočtů a důvodů pro tyto volby. Dále byla probírána problematika měření signálů. Pro impulsní a FMCW radary. Nakonec byla uvedena metodika a zpracování radarových signálů ve vztahu k μ - Dopplerovým jevům.

Ve třetí kapitole jsem se zaměřil na úvod do problematiky primárních radarových systémů. Byl popsán RS z pohledu signálového zpracování, dále jsem se zaměřil na problematiku měření vzdálenosti a Dopplerových posuvů. Závěr této kapitoly byl věnován radarové rovnici a jejímu vlivu na výkon přijatého signálu.

V kapitole 4 byl realizován komplexní model odražených signálů od zájmových objektů. Tento model zahrnuje modulaci vysílaného signálu (FLAMENCO), šíření volným prostorem, odraz vlny od překážky a signálové zpracování. V této části práce se podařilo vytvořit novou modulaci vysílaného signálu (FLAMENCO) s výrazně lepšími vlastnostmi, než u podobných typů modulací. Na Obr. 21 byl ukázán průběh autokorelační funkce pro FLAMENCO a NLFM-Taylor. Zde je možné povšimnout si rozdílu v odstupů postranních laloků, který u nové modulace dosahuje 82 dB.

Dále byla provedena analýza metod zpracování signálu ve spektrální oblasti. Po důkladném prozkoumání řady vybraných metod byla nakonec vybrána jako nejvhodnější metoda Blackman-Tukey. Důvodem bylo nejlepší prokreslení spektrogramů i pro nízké počty vzorků vstupujících do transformace a jednoduchost výpočtu.

Zbývajících kroky bylo vytvoření modelu odrazu vlny od překážky včetně zahrnutí modelu odrazu vlny na základě materiálových vlastností (Fresnelův odraz) a nakonec tvorba modelu šíření signálu volným prostorem (kapitola 4.5 a 4.6).

Dalším krokem bylo vytvoření měřicího pracoviště. V této kapitole jsem popsal provedení měření, použité vybavení a úlohy jednotlivých komponent v měřícím řetězci (kapitola 5).

V závěru této práce jsem se zabýval porovnáním modelů μ - dopplerovských spekter s naměřenými daty. V této kapitole jsem vysvětlil rozdíly mezi teoreticky očekávanými spektry a jejich reálnými protějšky. Upozornil jsem zde na rozdíly ve spektrech dronu, ventilátoru a jízdního kola. Dále jsem poukázal na vliv tvaru

lopatky (listu) vrtule na μ - Dopplerovo spektrum v závislosti na úhlu pozorování. Specifický tvar těchto objektů má za následek nesymetrii spektra kolem osy nulových kmitočtů. Tato znalost může být využita v oblasti klasifikace (kapitola 6).

Úplným závěrem této práce bylo navržení efektivního klasifikačního postupu za pomoci neuronové sítě, která byla natrénována na datech připravených simulátorem. Klasifikátor dosáhl vysoké přesnosti 97 % na validačních datech pořízených z modelu a přesnosti 90.1 % na validačních datech z měření. Tyto výsledky potvrzují správnost zvolených metod a přístupů, čímž se ověřuje, že navržený postup dokáže s dobrou spolehlivostí rozpoznávat a klasifikovat zájmové objekty (kapitola 8).

Úspěšně byly splněny všechny stanovené cíle a výsledky této práce, které přinesly významný příspěvek k vývoji radarových systémů nové generace. Implementované postupy mohou být základem pro budoucí aplikace v oblasti sledování vzdušného prostoru, kde je klíčová rychlá a spolehlivá detekce i klasifikace UAV. Další rozvoj navržených metod by se mohl zaměřit na zlepšení výkonu na reálných datech a zvýšení robustnosti klasifikace vůči různým podmínkám prostředí.

Literatura

- [1] BEZOUŠEK, P. a ŠEDIVÝ, P. (2007). *Radarová technika*. Praha: ČVUT. ISBN 978-80-01-03036-3.
- [2] BROWN, A. D. (2023). Radar Challenges, Current Solutions, and Future Advancements for the Counter Unmanned Aerial Systems Mission. *IEEE Aerospace and Electronic Systems Magazine*, 38(9), 34–50. DOI: 10.1109/MAES.2023.3289928.
- [3] ROBIN RADAR (2020). [online]. Dostupné z: <https://www.robinradar.com/elvira-anti-drone-system> [cit. 2024-05-27].
- [4] ZDTECH. Online 2020. Dostupné z: <https://www.zdtelecom.com/high-power/radio-detection/full-frequency/anti-drone/system-for/uav-detector.html>. [cit. 2025-02-02].
- [5] SPEED-MR. Online. 2020. Dostupné z: <https://www.aeroexpo.online/prod/controp-precision-technologies-ltd/product-169577-70980.html>. [cit. 2025-02-02].
- [6] TERRAHEXEN (2018). CTRL+SKY. [online]. Dostupné z: <https://terrahexen.com/en/oferta/produkt/uav-detection-systems/> [cit. 2025-02-02].
- [7] CHEN, V. C. (2011). *The Micro-Doppler Effect in Radar*. Norwood: Artech House.
- [8] CHEN, V. C., LI, F., HO, S. a WECHSLER, H. (2006). Micro-Doppler effect in radar: phenomenon, model, and simulation study. *IEEE Transactions on Aerospace and Electronic Systems*, 42(1), 2–21. DOI: 10.1109/TAES.2006.1603402.
- [9] SHI, L., FU, X., WANG, C., LI, T. a GAO, M. (2013). The performance analysis of micro-Doppler extracted from radar echoes under different bandwidth. *IET International Radar Conference 2013*, Xi'an, 1–5. DOI: 10.1049/cp.2013.0294.
- [10] GONG, J., YAN, D., KONG, D. a LI, D. (2023). Introduction to cognitive micro-Doppler radar: Optimization and Experiment. *IEEE International Radar Conference (RADAR)*, Sydney, Australia, 1–6. DOI: 10.1109/RADAR54928.2023.10371121.
- [11] CAMMENGA, Z. A., BAKER, C. J., SMITH, G. E. a EWING, R. (2014). Micro-Doppler target scattering. *IEEE Radar Conference*, Cincinnati, OH, USA, 1451–1455. DOI: 10.1109/RADAR.2014.6875829.

- [12] DU, L., LI, L., WANG, B. a XIAO, J. (2016). Micro-Doppler Feature Extraction Based on Time-Frequency Spectrogram for Ground Moving Targets Classification With Low-Resolution Radar. *IEEE Sensors Journal*, 16(10), 3756–3763. DOI: 10.1109/JSEN.2016.2538790.
- [13] CHEN, V. C., LI, F., HO, S. a WECHSLER, H. (2003). Analysis of Micro-Doppler Signatures. *IEE Proceedings – Radar, Sonar and Navigation*, 150, 271–276. DOI: 10.1049/ip-rsn:20030743.
- [14] ZHANG, R., LI, G. a ZHANG, Y. D. (2016). Micro-doppler interference removal via histogram analysis in time-frequency domain. *IEEE Transactions on Aerospace and Electronic Systems*, 52(2), 755–768. DOI: 10.1109/TAES.2015.150112.
- [15] GONG, J., YAN, J., KONG, D. a LI, D. (2023). Introduction to cognitive micro-Doppler radar: Optimization and Experiment. *IEEE International Radar Conference (RADAR)*, Sydney, Australia, 1–6. DOI: 10.1109/RADAR54928.2023.10371121.
- [16] BOASHASH, B. (ed.) (2016). *Time-Frequency Signal Analysis and Processing: A Comprehensive Reference*. 2nd ed. Academic Press.
- [17] GIERULL, C. H. (2004). Statistical analysis of multilook SAR interferograms for CFAR detection of ground moving targets. *IEEE Transactions on Geoscience and Remote Sensing*, 42(4), 691–701.
- [18] ZHANG, Z., LIN, Z. a LI, Z. (2014). Adaptive interference removal in joint time-frequency domain for micro-Doppler radar. *IET Radar, Sonar & Navigation*, 8(7), 752–759.
- [19] REN, L., SUN, G. a CAO, H. (2021). Robust micro-Doppler feature extraction in complex backgrounds using morphological filtering. *IEEE Sensors Journal*, 21(14), 16062–16070.
- [20] CORTES, C. a VAPNIK, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. DOI: 10.1007/BF00994018.
- [21] LI, G., CHEN, V. C. a XU, L. (2007). Micro-Doppler signature extraction and analysis of human motion using radar. *IET Radar, Sonar & Navigation*, 1(2), 133–139.
- [22] KIM, Y. a LING, H. (2009). Human activity classification based on micro-Doppler signatures using an artificial neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 47(5), 1328–1337.
- [23] RESEARCHGATE (2025). An Overview of Cognitive Radar: Past, Present, and Future – Scientific Figure on ResearchGate. [online]. Dostupné z: https://www.researchgate.net/figure/Perception-Action-Cycle-for-Radar-Remote-Sensing_fig2_338649769 [accessed 15 Apr 2025]

- [24] CHEN, V. C., LI, F., HO, S. a WECHSLER, H. (2006). Micro-Doppler effect in radar: phenomenon, model, and simulation study. *IEEE Transactions on Aerospace and Electronic Systems*, 42(1), 2–21.
- [25] HAYKIN, S. (2012). *Cognitive Dynamic Systems: Perception-action Cycle, Radar and Radio*. Cambridge: Cambridge University Press.
- [26] FRIEDLANDER, B. (1999). Time-Frequency and Wavelet Methods in Radar Processing. *IEEE Signal Processing Letters*, 6(10), 269–271.
- [27] GRECO, M. S., GINI, F. a FARINA, A. (2020). Cognitive approaches to radar detection, tracking, and classification. *IEEE Signal Processing Magazine*, 37(2), 93–103.
- [28] ZHOU, Y., HONG, W. a WU, Y. (2017). Application of sparse time-frequency distribution for micro-Doppler signature extraction. *IEEE Sensors Journal*, 17(3), 733–742.
- [29] IEEE XPLORE (2025). IEEE Xplore Digital Library. [online]. Dostupné z: <https://ieeexplore.ieee.org> [Accessed 7 April 2025].
- [30] WIKIPEDIA (2024). Mie scattering. In: *Wikipedia: the free encyclopedia*. San Francisco (CA): Wikimedia Foundation. [online]. Dostupné z: https://en.wikipedia.org/wiki/Mie_scattering. [cit. 2024-06-03].
- [31] SCHEER, J. a HOLM, W. A. (2010). *Principles of modern radar*. 1st ed. [s.l.]: [s.n.].
- [32] SKOLNIK, M. I. (2001). *Introduction to Radar Systems*. 3rd ed. New York: McGraw-Hill. ISBN 978-0-07-118189-1.
- [33] RICHARDS, M. A. (2014). *Fundamentals of Radar Signal Processing*. 2nd ed. New York: McGraw-Hill Education.
- [34] SYMONS, S. J., MILES, J. A. H. a MOON, J. R. (1998). A practical method for specifying radar track extraction performance. *IEE Colloquium on Specifying and Measuring Performance and Modern Radar Systems*. DOI: 10.1049/ic:19980150.
- [35] NOUR, N., BELHAJ-SOULLAMI, R., BURON, C. L. R., PERES, A. a BARBARESCO, F. (2021). Multi-Radar Tracking Optimization for Collaborative Combat. *21st International Radar Symposium (IRS)*. DOI: 10.23919/irs51887.2021.9466227.
- [36] ROTHWELL, E. J. a CLOUD, M. J. (2022). *Electromagnetics*. 3rd ed. CRC Press.
- [37] LEVANON, N. a MOZESON, E. (2004). *Radar signals*. Hoboken, NJ: John Wiley & Sons. ISBN 978-0-471-45948-7.

- [38] PORAT, B. (1997). *A Course in Digital Signal Processing*. John Wiley & Sons. ISBN 0-471-14961-6.
- [39] TABATABAEI MAJD, S. M. M. a MOHAMMADZADEH ASL, B. (2021). Adaptive Spectral Doppler Estimation Based on the Modified Amplitude Spectrum Capon. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 68(5), 1664–1675. DOI: 10.1109/TUFFC.2020.3044774.
- [40] JAKOBSSON, A. a STOICA, P. (2000). Combining Capon and APES for estimation of spectral lines. *Circuits, Systems and Signal Processing*, 19, 159–169. DOI: 10.1007/BF01212468
- [41] STOICA, P. a NEHORAI, A. (1989). Music, maximum likelihood, and cramer-rao bound. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 37(5), 720–741.
- [42] RIFE, D. C. a BOORSTYN, R. R. (1976). Multiple tone parameter estimation from discrete-time observations. *Bell Labs Technical Journal*, 55(9), 1389–1410.
- [43] SWINDLEHURST, A. L., OTTERSTEN, B., ROY, R. a KAILATH, T. (1992). Multiple invariance ESPRIT. *IEEE Transactions on Signal Processing*, 40(4), 867–881.
- [44] WAELE, S. a BROERSEN, P. M. T. (2000). The Burg algorithm for segments. *IEEE Transactions on Signal Processing*, 48(10), 2876–2880.
- [45] POTTER, L. C. a MOSES, R. L. Attributed scattering centers for SAR ATR. *IEEE Transactions on Image Processing*. 1997, 6(1), s. 79–91. DOI: 10.1109/83.552098.
- [46] STOICA, P., FRIEDLANDER, B. a SÖDERSTRÖM, T. (1988). A high-order Yule-Walker method for estimation of the AR parameters of an ARMA model. *Systems & Control Letters*, 11(2), 99–105.
- [47] MARPLE, S. L. (1991). A fast computational algorithm for the modified covariance method of linear prediction. *Digital Signal Processing*, 1(3), 124–133.
- [48] BALANIS, C. A. (2012). *Advanced Engineering Electromagnetics*. 2nd ed. John Wiley & Sons.
- [49] PASSIVE COMPONENTS BLOG (2024). What is Dielectric Constant of Plastic Materials? [online]. Dostupné z: <https://passive-components.eu/what-is-dielectric-constant-of-plastic-materials>. [cit. 2024-09-19].
- [50] NOVODNÁ, J. (2021). Dielektrické vlastnosti epoxidových kompozitů plněných recyklovanými uhlíkovými vlákny. [online]. Disertační práce. Dostupné z: <https://dspace.tul.cz/handle/15240/161306>. [cit. 2024-09-19].


- [51] EVERYTHING RF. Antenna Near Field & Far Field Distance Calculator [online]. [cit. 2025-09-01]. Dostupné z: <https://www.everythingrf.com/rf-calculators/antenna-near-field-distance-calculator>
- [52] SKOLNIK, M. I. (1990). *Radar Handbook*. 2nd ed. McGraw-Hill.
- [53] MILLER, A. W., CLEMENTE, C., ROBINSON, A., GREIG, D., KINGHORN, A. M. a SORAGHAN, J. J. (2013). Micro-Doppler based target classification using multi-feature integration. *IET Intelligent Signal Processing Conference (ISP 2013)*, London, 1–6. DOI: 10.1049/cp.2013.2042.
- [54] MARKOPOULOS, P. P., ZLOTNIKOV, S. a AHMAD, F. (2019). Adaptive Radar-Based Human Activity Recognition With L1-Norm Linear Discriminant Analysis. *IEEE Journal of Electromagnetics, RF and Microwaves in Medicine and Biology*, 3(2), 120–126. DOI: 10.1109/JERM.2019.2893587.
- [55] HE, Y., LI, X., LI, R., WANG, J. a JING, X. (2020). A Deep-Learning Method for Radar Micro-Doppler Spectrogram Restoration. *Sensors*, 20, 5007. DOI: 10.3390/s20075007.
- [56] TANG, C., LI, W., VISHWAKARMA, S., WOODBRIDGE, K., JULIER, S. a CHETTY, K. (2021). Learning from Natural Noise to Denoise Micro-Doppler Spectrogram. arXiv preprint. DOI: 10.48550/arXiv.2102.06887.
- [57] CHEN, Z. a LI, G. (2020). Human activity classification with neural network using radar micro-doppler and range signatures. *IET International Radar Conference (IET IRC 2020)*, Online Conference, 222–227. DOI: 10.1049/icp.2021.0810.
- [58] ADDABBO, P., BERNARDI, M. L., BIONDI, F., CIMITILE, M., CLEMENTE, C. a ORLANDO, D. (2021). Temporal Convolutional Neural Networks for Radar Micro-Doppler Based Gait Recognition. *Sensors*, 21(2), 381. DOI: 10.3390/s21020381.
- [59] JI, R., LI, J., HE, W., REN, J. a JIANG, X. (2023). Dual-Stream Siamese Vision Transformer With Mutual Attention For Radar Gait Verification. *ICASSP 2023*, 1–5. DOI: 10.1109/ICASSP49357.2023.10095141.
- [60] CHEN, S., HE, W., REN, J. a JIANG, X. (2022). Attention-Based Dual-Stream Vision Transformer for Radar Gait Recognition. *ICASSP 2022*, 3668–3672. DOI: 10.1109/ICASSP43922.2022.9746565.
- [61] GOODFELLOW, I., BENGIO, Y. a COURVILLE, A. (2016). *Deep Learning*. MIT Press.
- [62] BISHOP, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.

- [63] LECUN, Y., BOTTOU, L., BENGIO, Y. a HAFFNER, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- [64] HAYKIN, S. (2009). *Neural Networks and Learning Machines*. 3rd ed. Pearson.
- IOFFE, S. a SZELEGY, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *International Conference on Machine Learning (ICML)*.


Vlastní publikace a výstupy VaV

- [65] JORDÁN, J. (2019). Vibration Measurement and Analysis of Mechanical Design of the Antenna Radar System. *2019 29th International Conference Radioelektronika (RADIOELEKTRONIKA)*, Pardubice, Czech Republic, 1–4. DOI: 10.1109/RADIOELEK.2019.8733435.
- [66] MATOUŠEK, D., B. BRTNÍK a J. JORDÁN. (2020). Streamlined Fibonacci Charge Pump. *2020 International Conference on Applied Electronics (AE)*, Pilsen, Czech Republic, 1–4. DOI: 10.23919/AE49394.2020.9232866.
- [67] JORDÁN, J. a B. BRTNÍK. (2020). Finding the Sensitivity to Transfer Branch by Graphs. *2020 New Trends in Signal Processing (NTSP)*, Demanovska dolina, Slovakia, 1–4. DOI: 10.1109/NTSP49686.2020.9229527.
- [68] JORDÁN, J. (2023). Modeling and Measurement of Reflected Signals with μ -Doppler Effect from Various Targets using a Pulse Radar. *2023 33rd International Conference Radioelektronika (RADIOELEKTRONIKA)*, Pardubice, Czech Republic, 1–6. DOI: 10.1109/RADIOELEKTRONIKA57919.2023.10109079.
- [69] PAINE, S., W. P. FRANCOIS SCHONKEN, D. W. O'HAGAN, C. SCHÜPBACH, J. PIDANIC a J. JORDÁN. (2025). Evaluation of Different Range-Doppler Processing Techniques for OFDM-Based DVB-T2 Passive Radar. *IEEE Access*, 13, 116643–116653. DOI: 10.1109/ACCESS.2025.3583054.


Příloha A: Měřená data – DRON




Obr. 77: DYI – Měření 1 - $f_z = 14.8$ Hz, $\theta = 15^\circ$ (Vlevo), DYI – Měření 2 - $f_z = 28.1$ Hz, $\theta = 15^\circ$ (Vpravo)




Obr. 78: DYI – Měření 3 - $f_z = 53.2$ Hz, $\theta = 15^\circ$ (Vlevo), DYI – Měření 4 - $f_z = 85.8$ Hz, $\theta = 15^\circ$ (Vpravo)




Obr. 79: MATRICE600-PRO – Měření 5 - $f_z = 10.8$ Hz, $\theta = 15^\circ$ (Vlevo), MATRICE600-PRO – Měření 6 - $f_z = 14.8$ Hz, $\theta = 15^\circ$ (Vpravo)




Obr. 80: MATRICE600-PRO – Měření 7 - $f_z = 8.8$ Hz, $\theta = 15^\circ$ (Vlevo), MATRICE600-PRO – Měření 8 - $f_z = 19.7$ Hz, $\theta = 15^\circ$ (Vpravo)




Obr. 81: MATRICE600-PRO – Měření 9 - $f_z = 21.7$ Hz, $\theta = 15^\circ$ (Vlevo), MATRICE600-PRO – Měření 10 - $f_z = 24.8$ Hz, $\theta = 0^\circ$ (Vpravo)



Obr. 82: MATRICE600-PRO – Měření 11 - $f_z = 23.8$ Hz, $\theta = 0^\circ$ (Vlevo), MATRICE600-PRO – Měření 12 - $f_z = 22.9$ Hz, $\theta = 6^\circ$ (Vpravo)




Obr. 83: MATRICE600-PRO – Měření 13 - $f_z = 20.7$ Hz, $\theta = 15^\circ$ (Vlevo), MATRICE600-PRO – Měření 14 - $f_z = 21.6$ Hz, $\theta = 15^\circ$ (Vpravo)




Obr. 84: MATRICE600-PRO – Měření 15 - $f_z = 25.1$ Hz, $\theta = 15^\circ$ (Vlevo), MATRICE600-PRO – Měření 16 - $f_z = 26.1$ Hz, $\theta = 15^\circ$ (Vpravo)


Příloha B: Měřená data – VENTILÁTOR




Obr. 85: Měření 1 – $f_y = 17.23\text{Hz}$, s krytem – $\varphi = 45^\circ$ (vlevo), Měření 2 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 45^\circ$ (vpravo)




Obr. 86: Měření 3 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 0^\circ$ (vlevo), Měření 4 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 10^\circ$ (vpravo)




Obr. 87: Měření 5 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 20^\circ$ (vlevo), Měření 6 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 30^\circ$ (vpravo)




Obr. 88: Měření 7 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 40^\circ$ (vlevo), Měření 8 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 45^\circ$ (vpravo)




Obr. 90: Měření 9 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 50^\circ$ (vlevo), Měření 10 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 60^\circ$ (vpravo)




Obr. 89: Měření 11 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 80^\circ$ (vlevo), Měření 12 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 90^\circ$ (vpravo)




Obr. 91: Měření 13 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 100^\circ$ (vlevo), Měření 14 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 110^\circ$ (vpravo)




Obr. 92: Měření 15 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 120^\circ$ (vlevo), Měření 16 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 130^\circ$ (vpravo)




Obr. 93: Měření 17 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 140^\circ$ (vlevo), Měření 18 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 150^\circ$ (vpravo)



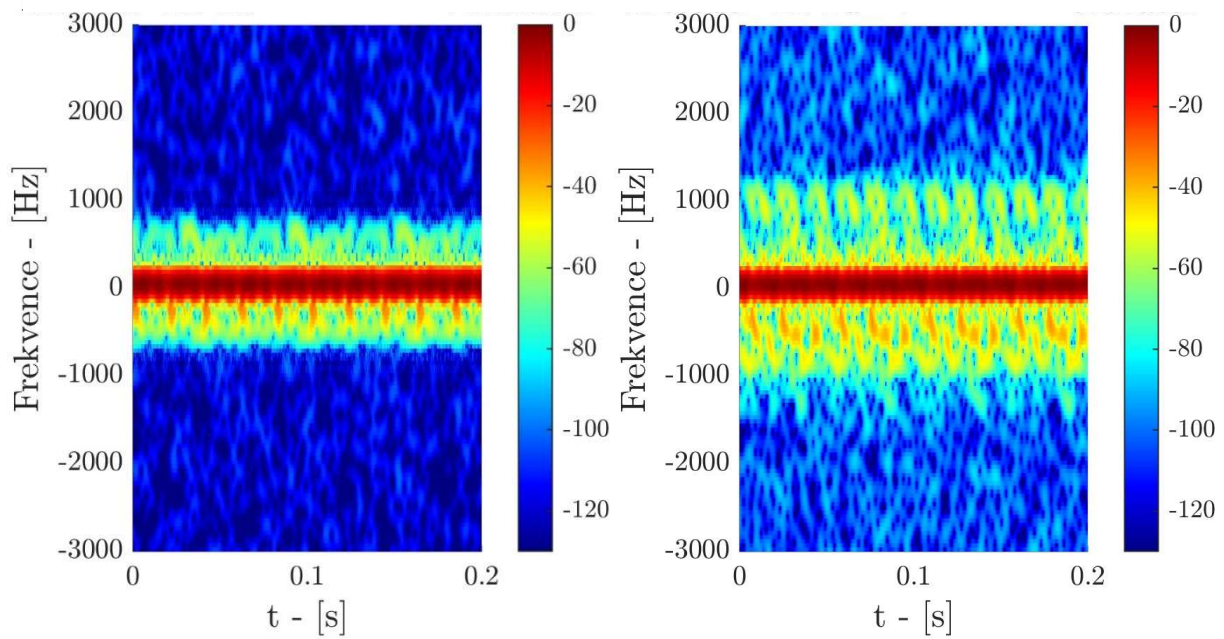
Obr. 94: Měření 19 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = 170^\circ$ (vlevo), Měření 20 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vpravo)




Obr. 95: Měření 21 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 22 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vpravo)



Obr. 96: Měření 23 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 24 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vpravo)




Obr. 98: Měření 25 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 26 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vpravo)




Obr. 97: Měření 27 – $f_y = 17.23\text{Hz}$, bez krytu – $\varphi = \text{náhodný}^\circ$ (vlevo)


Příloha C: Měřená data – JÍZDNÍ KOLO




Obr. 99: Měření 1 – $\varphi = 10^\circ$ (vlevo), Měření 2 – $\varphi = 30^\circ$ (vpravo)




Obr. 100: Měření 3 – $\varphi = 40^\circ$ (vlevo), Měření 4 – $\varphi = 50^\circ$ (vpravo)




Obr. 101: Měření 5 – $\varphi = 60^\circ$ (vlevo), Měření 6 – $\varphi = 80^\circ$ (vpravo)




Obr. 102: Měření 7 – $\varphi = 90^\circ$ (vlevo), Měření 8 – $\varphi = \text{náhodný}^\circ$ (vpravo)




Obr. 103: Měření 9 – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 10 – $\varphi = \text{náhodný}^\circ$ (vpravo)




Obr. 104: Měření 11 – $\theta = \text{náhodný}^\circ$ (vlevo), Měření 12 – $\varphi = \text{náhodný}^\circ$ (vpravo)



Obr. 105: Měření 13 – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 14 – $\varphi = \text{náhodný}^\circ$ (vpravo)



Obr. 106: Měření 15 – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 16 – $\varphi = \text{náhodný}^\circ$ (vpravo)



Obr. 107: Měření 17 – $\varphi = \text{náhodný}^\circ$ (vlevo), Měření 18 – $\varphi = \text{náhodný}^\circ$ (vpravo)

Příloha D: Stavba Neuronové Sítě

