

UNIVERZITA PARDUBICE
Fakulta elektrotechniky a informatiky

**Využití shlukové analýzy pro účely signálo-
vého zpracování FMCW radaru**
Bc. Suchý Petr

Diplomová práce
2019

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Petr Suchý**
Osobní číslo: **I15171**
Studijní program: **N2612 Elektrotechnika a informatika**
Studijní obor: **Komunikační a řídicí technologie**
Název tématu: **Využití shlukové analýzy pro účely signálového zpracování FMCW radaru**
Zadávací katedra: **Katedra elektrotechniky**

Z á s a d y p r o v y p r a c o v á n í :

Cíl diplomové práce:

Realizujte pomocí shlukové analýzy sjednocení jednotlivých detekcí cílů v konkrétní sledované objekty. Detekce cílů jsou poskytovány radarem, pracujícím s kontinuální vlnou a lineární frekvenční modulací, využívaným v automobilovém průmyslu.

Teoretická část práce: Seznamte se a popište signálové zpracování FMCW radaru a to zejména na úrovni s detekcí cíle s přesahem do sekundárního radarového zpracování, dále se seznamte se shlukovou analýzou. V teoretické části práce popište metody shlukové analýzy, jejich výhody a nevýhody s důrazem na signálové zpracování v radaru. V teoretické části také popište situace, ve kterých bude shluková analýza aplikována.

Praktická část práce: V praktické části práce navrhnete simulátor cílů, na kterém jednotlivé metody budete testovat, dále naprogramujte algoritmy, které budou vhodné pro daný typ úlohy a tyto algoritmy nejprve otestujte na syntetických datech a následně na datech reálných.

Rozsah grafických prací:

Rozsah pracovní zprávy:

Forma zpracování diplomové práce: **tištěná**

Seznam odborné literatury:

Constrained Clustering: Advances in Algorithms, Theory, and Applications. 1.
6000 Broken Sound Parkway NW, Suite 300: Chapman and Hall/CRC, 2008.
ISBN 978-1-58488-996-0.

Clustering. 1. New York City, United States: Wiley-IEEE Press, 2008. ISBN
978-0-470-27680-8.

Radarová technika. 1. Praha: ČVUT, 2007. ISBN 978-80-01-03036-3.

Vedoucí diplomové práce:

Ing. Michal Mandlík, Ph.D.

Katedra elektrotechniky

Datum zadání diplomové práce: **15. října 2018**

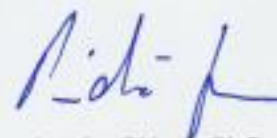
Termín odevzdání diplomové práce: **23. srpna 2019**



Ing. Zdeněk Němec, Ph.D.
děkan



L.S.



Ing. Jan Pidaník, Ph.D.
vedoucí katedry

V Pardubicích dne 15. listopadu 2018

Prohlášení autora

Prohlašuji:

Tuto práci 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., autorský zákon, 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. 9/2012, bude práce zveřejněna v Univerzitní knihovně a prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 22.8.2019

Bc. Suchý Petr

Poděkování

Rád bych poděkoval vedoucímu mé diplomové práce Ing. Michalovi Mandlíkovi, Ph.D. za odborné vedení, rady a pomoc při zpracovávání zejména praktické části této práce. Dále bych poděkoval za poskytnutá data a odborný popis. V neposlední řadě bych poděkoval celé své rodině za podporu při studiu.

Anotace

Cílem diplomové práce je výběr shlukových metod a optimalizace parametrů zvolených metod pro potřeby automobilového radaru pracujícího s kontinuální vlnou. Shluky jsou realizovány na detekcích, které jsou jedním z výstupů FMCW radaru. Práce je rozdělena na dvě části, teoretickou a praktickou. Teoretická část práce je pak dále rozdělena na dva bloky. V prvním bloku je uveden obecný popis FMCW radaru. Druhý blok je věnován shlukové analýze a jednotlivým metodám. V praktické části práce se věnuji popisu generátoru detekcí. Následně je uveden postup výběru shlukových metod a optimalizace jejich parametrů. Optimalizace byla provedena na základě závislosti parametru na rychlosti detekce. Generátor cílů, realizace metod a optimalizace parametrů je prováděna v prostředí MATLAB.

Klíčová slova

Automobilový průmysl, Radar, Frekvenčně modulovaná spojitá vlna, Anténní pole, Rychlá Fourierova transformace, Shluková analýza, DBSCAN, MATLAB.

Title

Using cluster analysis for signal processing FMCW radar.

Annotation

The aim of this diploma thesis is the selection of cluster methods and optimization of the parameters chosen methods for the automotive industry needs. Clusters are realized on detection, which are one of the outputs of FMCW radar. The thesis is divided into two parts, theoretical and practical. Theoretical part is divided into two blocks. The first block there is a general description of FMCW radar. The second block is dedicated to the cluster analysis and individual methods. In the practical part of the work I describe generator of detection. The following is a procedure for selecting concrete clustering methods and optimization of method parameters. Optimization is based on parameter depends on speed. Generator of detections, implementation of methods and parameters optimization are implemented in MATLAB.

Keywords

Automotive, Radar, Frequency modulated continuous wave, Antenna array, Fast Fourier transform, Cluster analysis, Density-based clustering, MATLAB.

Obsah

Úvod	8
1. Radar	9
1.1 Základní rozdělení radarů.....	9
1.1.1 Pulzní radar.....	10
1.1.2 Dopplerovský radar	10
1.2 FMCW radar.....	10
1.3 Lineární frekvenční modulace	10
1.4 Základní princip FMCW radaru	12
1.4.1 Frekvenční pásma používané v automobilovém průmyslu	15
1.4.2 FMCW radar v porovnání s konkurenční sensorikou	16
2. Shluková analýza	17
2.1 Vlastnosti shlukovačích metod.....	17
2.2 Základní metody a klasifikace.....	18
2.3 Hierarchické shlukování	19
2.3.1 Vstupní datová matice	20
2.3.2 Konstrukce matice (ne)podobnosti, Normalizace	21
2.3.3 Podobnost, Blížkost (Proximity)	21
2.3.4 Metriky pro matici (ne)podobnosti.....	22
2.3.5 Měření vzdálenosti mezi shluky.....	24
2.4 Nehierarchické metody shlukování	25
2.4.1 Metoda založena na centrálním bodu (K-Means).....	26
2.5 Metoda DBSCAN.....	26
2.5.1 Základní myšlenka DBSCAN algoritmu.....	27
2.5.2 Algoritmus DBSCAN.....	29
2.5.3 Výhody a nevýhody metody DBSCAN	29
2.5.4 Aplikace metody DBSCAN.....	30
3. Praktická část	31
3.1 Generátor cílů	31
3.1.1 Konfigurační soubor	31
3.1.1.1 Popis struktury objektů	32
3.1.2 Detekce objektů	33
3.1.3 Aplikace shlukové analýzy.....	37
3.1.3.1 K-MEANS	37
3.1.3.2 K-MEANS dosažené výsledky.....	37

3.1.3.3	Metoda DBSCAN.....	41
3.1.3.4	Funkce DBSCAN.....	43
3.1.3.5	Výsledky DBSCAN.....	43
3.1.3.6	Analýza odhadu parametrů DBSCAN.....	45
3.1.3.7	Vliv použitých metrik.....	49
3.2	Aplikace na reálných datech.....	51
3.2.1	Vývojový diagram funkce.....	51
3.3	Vstupní data.....	52
3.3.1	Import vstupních dat.....	53
3.4	Vizualizace vstupních dat.....	53
3.5	Aplikace DBSCAN na reálných datech.....	55
3.6	Vykreslení bounding boxu.....	57
	Závěr.....	59
	Seznam zkratk.....	60
	Seznam obrázků.....	61
	Seznam tabulek.....	63
	Seznam grafů.....	64
	Literatura.....	65

Úvod

V dnešní době, v době digitalizace, je kladen velký důraz na vývoj technologií. Požadavky na rozvoj technologií v automobilovém průmyslu byly kladeny již dříve, jako příklad můžeme uvést komfortní systémy v automobilech. Vrchol technologií ve vozidle můžeme pozorovat s nástupem elektromobility a nejmodernějších bezpečnostních a komfortních systémech.

Radar je jedním z hlavních senzorů, které jsou využívány pro realizaci komfortních a bezpečnostních systému. Pro realizaci bezpečnostních a komfortních systémů se využívá velké množství sensoriky a v dnešní době i různé kooperace (fúze) senzorů. Díky využívaným senzorům, jsou dnešní automobily schopné plnit různé stupně autonomní jízdy.

Důležitou roli v těchto systémech hraje právě FMCW radar. FMCW (*Frequency Modulated Continuous Wave*) Radar (*Radio Detection and Ranging*) poskytuje automobilu informaci o jeho okolí. Zpráva od radaru obsahuje velké množství dílčích informací o jednotlivých detekcích, jako např. poloha, azimut, elevace, pohyblivost, či nepohyblivost detekce (na základě Dopplerova jevu), výkon a další. Radar je schopen poskytovat informaci v určitém FOV (*Field of view*), ten popisuje schopnost radaru sledovat určitý prostor definovaný úhlem a vzdáleností. Podle různých FOV rozlišujeme typy radarů, jako je LRR (*Long range radar*) MRR (*Mid-range radar*) a SRR (*Short-range radar*).

Shluková analýza je využívána v digitálním signálovém zpracování radarů. A to zejména kvůli vysoké hustotě detekcí z radarů, které je nutné shlukovat a dále přiřazovat objektům, které již existují nebo na základě těchto shluků objekty zakládat. Vzhledem k velkému množství metod, je nutné identifikovat užitečné metody a následně optimalizovat parametry vybraných metod. Tato práce je zaměřena právě na oba dva zmíněné problémy.

Teoretická část je rozdělena na dvě části. První část je zaměřena na základní princip a fungování radaru. Druhá část je zaměřena na shlukovou analýzu, kde dochází k popisu shlukové analýzy v širším pojetí a následně je popsán výběr vhodných metod.

V praktické části jsou vybrané metody aplikované na datech ze simulátoru cílů, který je součástí praktické práce. Pomocí simulátoru cílů bylo možné nastavit optimální parametry shlukových metod. Optimální parametry byly nalezeny na základě rychlosti cíle. Po ověření správné funkce vybraných metod na simulátoru cílů bylo možné otestovat algoritmy shlukových metod na reálných datech. Po vytvoření jednotlivých klastrů byla na jednotlivé cíle implementována funkce, která vykresluje kolem detekovaného cíle bounding box. Funkce navíc vypisuje k danému bounding boxu informaci o natočení objektu ve směru jeho šíření. Každý zde popsaný krok praktické části doprovází názorná vizualizace a popis jednotlivých úkonů. Implementace shlukových metod a optimalizace parametrů těchto metod, tak simulátor cílů byly vytvořeny v prostředí Matlab.

1. Radar

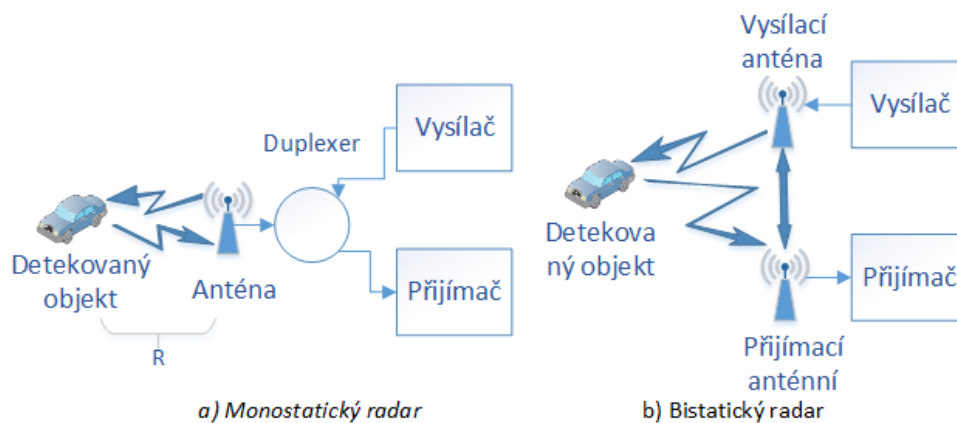
V této části práce dochází k rozdělení a popisu radarů, až s přechodem na detailnější popis FMCW (*Frequency Modulated Continuous Wave*) radaru z pohledu automobilového průmyslu. Ve druhé části dochází k základnímu popisu a rozdělení shlukovacích metod. Tyto metody jsou následně aplikovány v praktické části.

Bezpečnostní, ale i komfortní funkce mohou být postaveny právě na radarovém sensoru. Bezpečnostní funkcí může být např. AEB (*autonomní bezpečnostní brždění*) a komfortní funkcí může být např. ACC (*adaptivní tempomat*) a spousta dalších systémů podporující komfort a bezpečí řidiče.

1.1 Základní rozdělení radarů

Základní dělení radarů je na radary tzv. aktivní a radary pasivní. Pokud radar nevysílá elektromagnetický signál, jedná se o radar pasivní. Jestliže radar vysílá a přijímá elektromagnetický signál, jedná se o aktivní systém. Na základě principiální funkčnosti radaru rozlišujeme radary sekundární a primární.

Na základě konstrukce rozlišujeme *monostatické* a *bistatické* radary (obrázek číslo 1). Monostatické radary mají vysílací a přijímací anténu umístěnou na jednom místě. Kdežto u bistatických radarů se typicky vysílací a přijímací anténa nachází na různých místech.



Obrázek 1 - Radarová konfigurace

Dále dělíme radary podle časového schématu vysílání a příjmu na radary pracující s pulsní a kontinuální vlnou. Radary pracující s kontinuální vlnou můžeme ještě rozdělit na Dopplerovské a na radary s modulovaným signálem[23].

1.1.1 Pulzní radar

Základním rozdílem mezi pulzními radary a radary pracujícími s kontinuální vlnou je časování vysílání a příjmu. Pulzní radary vysílají velmi krátký elektromagnetický pulz s relativně velkým výkonem. Po vyslání pulzu se aktivuje přijímač a přijímá odražený signál. Po určitém čase se přijímač deaktivuje a opakuje se vyslání pulzu. Z rozdílu času mezi vyslaným a přijatým signálem je možné určit vzdálenost pozorovaného cíle od radaru [23].

1.1.2 Dopplerovský radar

Vysílač Dopplerovského kontinuálního radaru vysílá souvislý harmonický signál s konstantním kmitočtem. (Tento typ radaru značíme CW - Continuous Wave). Po odrazu vyslaného signálu je signál přijímán v přijímači. Pokud však dojde k odrazu od objektu, který má vůči radaru nenulovou rychlost, nastane takzvaný Dopplerův posuv. Z Dopplerova posuvu je následně určena rychlost detekovaného objektu.

Tato technologie tedy umožňuje určit rychlost pohyblivého cíle, avšak nedokáže určit jeho vzdálenost. Pro jistění vzdálenosti jsou CW radary doplněny o frekvenční nebo fázovou modulaci.

1.2 FMCW radar

FMCW radar řadíme do skupiny aktivních primárních radarů. FMCW radar, stejně jako Dopplerovský radar, vysílá kontinuální elektromagnetickou vlnu. Na rozdíl od Dopplerova radaru je FMCW radar schopen určit jak rychlost detekovaného objektu.


FMCW radar vysílá kontinuální frekvenčně modulovaný signál. Kmitočet nosné vlny se mění v čase a v závislosti na modulační funkci. Nejčastěji používanou frekvenční modulací je lineární frekvenční modulace a z hlediska jednoduchosti je obvykle volí trojúhelníkový průběh modulačního signálu.[22]

V případě automobilových radarů by měl radarový snímač poskytovat řidiči informace o relativní rychlosti objektů, kterými je řidič obklopen, a to s vysokým rozlišením a přesností. V bezpečnostních aplikacích automobilů musí být informace o rychlosti a rozsahu jednotlivých cílů měřeny současně a aktualizovány v krátkém časovém úseku, řádově desítky milisekund [19].

1.3 Lineární frekvenční modulace

Princip trojúhelníkového průběhu modulační funkce je lineární snižování nebo naopak zvyšování frekvence za čas. Na základě frekvenčního rozdílu vyslané a přijaté vlny (Obrázek 2) jsme schopni dopočítat vzdálenost. Výsledek tohoto rozdílu nazýváme tzv. beat frekvencí. Za předpokladu, že se objekt pohybuje, je nutné počítat i s Dopplerovým jevem. Lineární


frekvenční modulace pro statický objekt je zobrazena na obrázku 2. Kde T představuje časový posun mezi vyslaným a přijatým signálem a f_b frekvenční posun mezi těmito signály.



Obrázek 2 - Lineární frekvenční modulace [22]

Obrázek 3 popisuje trojúhelníkový průběh modulační funkce, kde v čase T_0 kmitá oscilátor na kmitočtu f_0 . Od doby T_0 až po dobu T dochází k lineárnímu nárůstu frekvence. V časovém okamžiku T dosahuje frekvence svého maxima a následně dochází k lineárnímu snižování frekvence až k její výchozí hodnotě. Tento děj se periodicky opakuje s periodou Tm . Rozdílem maximální a minimální hodnoty kmitočtu získáme tzv. zdvih modulace a ten je zároveň roven šířce pásma. Šířka pásma signálu B určuje rozlišovací schopnost radaru ve vzdálenosti. Rozlišovací schopnost symbolicky označujeme ΔR .

$$\Delta R = \frac{c}{2B} \tag{1.1}$$



Obrázek 3 - Trojúhelníkový průběh modulace

Okamžitý kmitočet oscilátoru závisí na vztazích (1.2) a (1.3)

$$f_n = f_0 + \frac{t-t_0}{T} B \text{ pro } t \in (t_0, t_0 + T) \quad (1.2)$$

$$f_n = f_0 - \frac{t-t_0-T(1+\alpha)}{\alpha T} B \text{ pro } t \in (t_0 + T, t_0 + T(1 + \alpha)) \quad (1.3)$$

B ... šířka pásma signálu [Hz],

f_0 ... počáteční frekvence [Hz],

t_0 ... počáteční čas [s],

t ... čas [s],

f_n ... okamžitý kmitočet oscilátoru [Hz],

α ... modulace [-].

Dalším používaným typem trojúhelníkového průběhu může být pilovitý nebo symetrický průběh.

1.4 Základní princip FMCW radaru

Na obrázku 4 je v podobě blokového schématu znázorněna základní funkce a princip FMCW radaru.



Obrázek 4 - Blokové schéma FMCW radaru

Signál kmitočtově modulovaného oscilátoru (VCO) je přes modulátor přiveden na výstup k anténě a zároveň přiváděn na jeden ze vstupů směšovače umístěného v přijímací cestě. Přijímaný signál, signál odražený, je přiváděn přes nízko šumový zesilovač na druhý vstup směšovače.

Ve směšovači dochází ke smíšení signálu VCO a přijatého signálu, který je vůči vyslanému signálu zpožděn o τ . Zpoždění τ je dáno dvojnásobkem vzdáleností mezi radarem a cílem. Kmitočet odraženého signálu:

$$f_p(t) = f_n(t - \tau) \quad (1.4)$$

Časový rozdíl mezi signály je možné zjistit výpočtem následujícího vztahu:

$$f_p(t) = \frac{2R}{c} \quad (1.5)$$

R ... vzdálenost k cíli [m]

c ... rychlost světla [m/s]

Pro kmitočet odraženého signálu můžeme vztah (1.2) a (1.3) upravit uvažováním časového zpoždění signálu:

$$f_p = f_0 + \frac{t-t_0-\tau}{T} B \text{ pro } t \in (t_0, t_0 + T) \quad (1.6)$$

$$f_p = f_0 - \frac{t-t_0-T(1+\alpha)-\tau}{\alpha T} B \text{ pro } t \in (t_0 + T, t_0 + T(1 + \alpha)) \quad (1.7)$$

Kombinační produkty těchto signálů jsou výstupem směšovače. Na výstupu tedy dostáváme signál s rozdílovým kmitočtem, pokud neuvažujeme vyšší kombinační složky. Pak platí:

$$f_{vys}(t) = |f_n(t) - f_p(t)| \quad (1.8)$$

Po dosazení do rovnice (1.8) z rovnic (1.2) a (1.6) dostaneme následující vztahy pro jednotlivé časové kroky:

$$f_{vys}(t) = f_n(t) \text{ pro } t \in (t_0, t_0 + \tau) \quad (1.9)$$

$$f_{vys}(t) = \left| f_0 + \frac{t-t_0}{T} B - f_0 + \frac{t-t_0-\tau}{T} B \right| = \left| \frac{\tau}{T} B \right| \text{ pro } t \in (t_0 + \tau, t_0 + T) \quad (1.10)$$

$$f_{vys}(t) = f_0 - \frac{t-t_0-T(1+\alpha)}{\alpha T} B - f_0 - \frac{t-t_0-T(1+\alpha)-\tau}{\alpha T} B \quad (1.11)$$

pro $t \in (t_0 + T, t_0 + T + \tau)$

$$f_{vys}(t) = \left| \frac{\tau}{\alpha T} \right| B \text{ pro } t \in (t_0 + T + \tau, t_0 + T + \alpha T) \quad (1.12)$$

$$f_{vys}(t) = f_n(t) \text{ pro } t \in (t_0 + T + \alpha T, t_0 + \alpha T + \tau) \quad (1.13)$$


Z rovnic (1.10) a (1.12) je patrné, že rozdílový kmitočet není závislý na čase, ale na zpoždění τ . Díky tomu je možné definovat nezávisle vzdálenost, avšak za předpokladu, že se objekt nepohybuje.

V případě pohybujících se cílů je nutné uvažovat tzv. Dopplerův jev. Dopplerův jev se projeví posunem frekvence o Dopplerův posuv f_d (obrázek 6). Pokud se tedy objekt pohybuje nějakým směrem, projeví se to posunutím absolutních hodnot frekvencí. Pokud je jedna frekvence větší, objekt se pohybuje a frekvence byla změněna Dopplerovým jevem. [22]

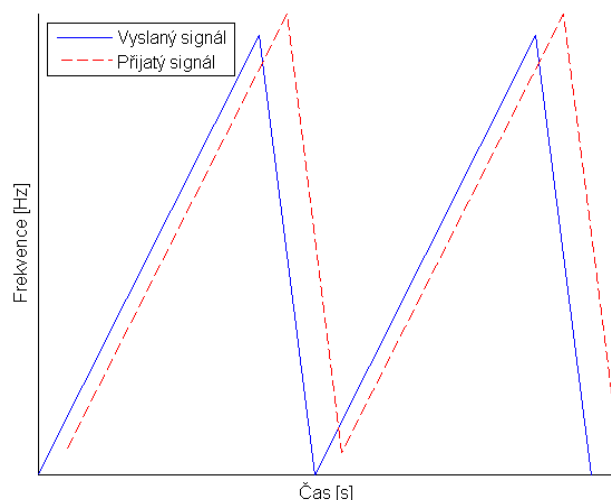
$$f_{vys1}(t) = \left| f_d - \frac{\tau}{T} B \right| \text{ pro } t \in (t_0 + \tau, t_0 + T) \quad (1.14)$$

$$f_{vys2}(t) = \left| f_d + \frac{\tau}{\alpha T} B \right| \text{ pro } t \in (t_0 + T + \tau, t_0 + \alpha T + \tau) \quad (1.15)$$

Ze vztahů (1.14) a (1.15) je možné dopočítat neznámé f_d a τ a následně pak i vzdálenost objektu R .



Obrázek 5 - Vyslaný a přijímaný signál FMCW



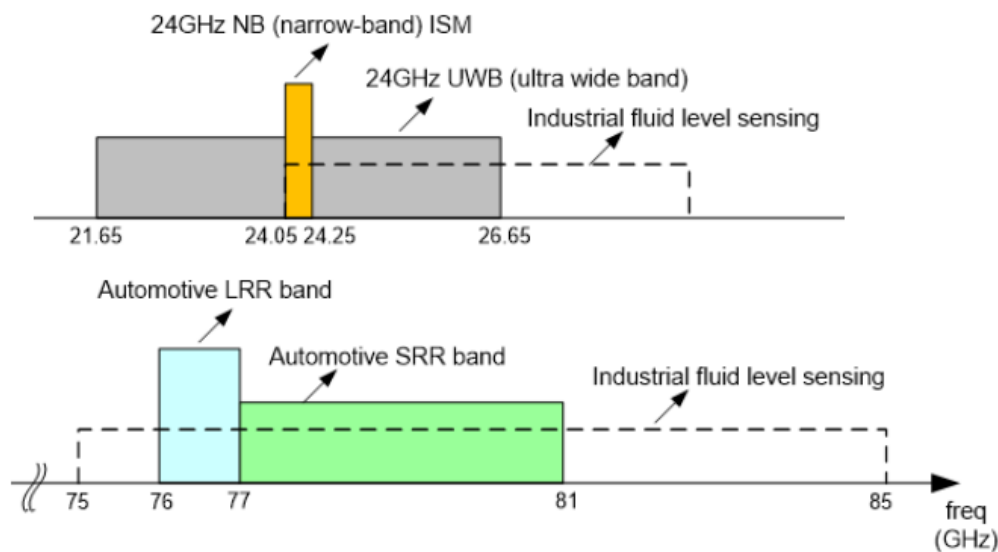
Obrázek 6 - Vliv Dopplerova posunu

1.4.1 Frekvenční pásma používané v automobilovém průmyslu

V automobilovém průmyslu se využívá pro funkci radarových systému dvou frekvenčních pásem. Pásmo okolo nosné frekvence 24 GHz a frekvenční pásmo okolo 77 GHz. Obě tyto pásma jsou vyobrazena na obrázku číslo 7.

Pásmo 24 GHz se skládá z úzkopásmové (NB) a širokopásmové oblasti. NB je vyhrazeno pro ISM (průmyslové, vědecké a lékařské rozhlasové pásma), proto dochází k omezení pásma v maximální možné šíři 200 MHz. Pásmo UWB (Ultra-wideband) se rozkládá od 21,65 GHz až do 26,65 GHz. Do roku 2022 by mělo být zrušeno na základně rozhodnutí ETSI (Evropský institut pro telekomunikační normy) a FCC (Federální komise pro komunikace).

Frekvenční pásmo 77 GHz, které je k dispozici od 77 GHz až do 81 GHz, poskytuje šířku pásma 4 GHz, což je v porovnání s pásmem 24 GHz NB vhodnější varianta a to zejména s ohledem na rozlišovací schopnost radaru ve vzdálenosti. Rozlišení je možné definovat, jako minimální vzdálenost dvou objektů tak, aby je radar rozlišil, že se jedná o dva objekty, nikoliv jeden. Přesností měření je myšlena přesnost měření vzdálenosti. Chyba při měření vzdálenosti a minimální rozlišitelná vzdálenost je nepřímo úměrná šířce využívaného pásma. Pásmo 77 GHz umožňuje měření přesnosti, rozlišení rozsahu a díky tomu lepší detekci více objektů blízko sebe. Dále pak díky vyšší frekvenci může docílit lepšího rozlišení rychlosti objektů. [17,33]



Obrázek 7 – Dostupná radarová pásma v automobilovém průmyslu [33]

1.4.2 FMCW radar v porovnání s konkurenční senzorkou

Radar sice nenabízí tak přesné měření v úhlu, jako jiné senzory, ale je méně ovlivňován různými podmínkami počasí, než jiné alternativy. Zmíněnou alternativou může být např. multifokální kamera (MFK). MFK přináší výhodu přesnějšího měření úhlu při rozpoznávání objektů, ale na druhou stranu je náchylná na vlivy nepříznivého počasí (mlha, hustý déšť...). Vhodnou variantou může být datová fúze těchto dvou senzorů.

Existuje velké množství systémových architektur pro radarové senzory, ale v automobilovém průmyslu je nejrozšířenější použití FMCW radaru. A to zejména z důvodu poskytnutí více výhod než ostatní architektury radarů [8,9].

Výhody FMCW radaru oproti jiným radarovým řešením: [19]

- Schopnost měřit malé rozsahy s velkou přesností.
- Schopnost měřit současně cíl a jeho relativní rychlost.
- Zpracování signálu se provádí v poměrně nízkých frekvencích. Výhoda jednoduššího HW a levnějšího výkonového stupně.
- FMCW radar pracuje dobře v mnoha typech počasí a atmosférických podmínkách jako je déšť, sníh, vlhkost, mlha a prašné podmínky.
- FMCW modulace je kompatibilní s polovodičovými vysílači a také představuje nejlepší využití výstupního výkonu dostupného z těchto zařízení.
- Malá hmotnost, rozměry a malá spotřeba energie.

2. Shluková analýza

V této části práce je popsán pojem shlukování dat a představeny metody obvykle používané k získávání znalostí z databází nebo určitého objemu dat.

Analýza shluků (Cluster Analysis) se zabývá vyšetřováním podobnosti vícerozměrných objektů a jejich klasifikací do jednotlivých tříd čili shluků. Jedná se o metodu učení bez učení a cílem je klasifikovat data podle přesně daných pravidel. Data v jednom shluku vykazují maximální podobnost, zatímco mezi objekty jiných shluků podobnost menší či minimální. Podobnost objektů je určována na základě hodnot daných atributů objektů. Takto popsaný postup by se mohl nazvat procesem klasifikace. Klasifikací rozumíme činnost, při které rozkládáme množinu objektů do systému disjunktních tříd. Množinu takových to tříd nazýváme klasifikační systém. Způsobů pro odhalování těchto tříd je v praxi několik. Shluková analýza nachází uplatnění např. v biologii, medicíně, elektrotechnice, ale i ve sportu a v dalších odvětvích. [6]

Vlastní shluková analýza neobsahuje techniku k rozlišení významných a nevýznamných znaků. Volba znaků musí být provedena na základě teoretických, pojmových a praktických hledisek. Nesprávné zařazení znaků vede ke shlukování i odlehlých objektů, které mohou mít nepříznivý vliv na výsledky analýzy. [2]

2.1 Vlastnosti shlukovačích metod

Metod pro shlukování existuje velké množství a některé z těchto metod budou popsány v kapitolách níže. U shlukovačích metod jsou důležité určité vlastnosti, které by měly metody splňovat. Jedna z těchto vlastností je škálovatelnost. Tato vlastnost je důležitá protože se většinou pracuje s velkým objemem dat a výpočet metody je potřeba provádět paralelně. V některých případech je možné velké množiny dat nahradit vzorkem. To však při nesprávné provedení může vést i ke zkreslení výsledků metody.

Další důležitá vlastnost je schopnost metody pracovat s různými datovými typy atributů datové množiny a vytváření shluků různých tvarů. Určitá část metod pracuje s numerickými daty, ale v praxi se setkáváme i se situacemi, kdy metody pracují s jinými datovými typy. Jelikož mnoho metod je přizpůsobeno k shlukování numerických dat, je zřejmé, že nejběžnější metodou určování vzdálenosti je Euklidovská metoda. Díky této skutečnosti mají metody sklon vytvářet kulovité shluky, které však nemusejí odpovídat. Efektivnější, s ohledem na využití v automobilovém průmyslu, jsou ty metody, které dokážou vytvářet libovolné shluky.

U některých metod je nutné zadat počet tříd, na které mají být data rozdělena. Jako je tomu např. u metod *K-Medoids* a *K-Means*. Pro tyto metody jsou nalezené shluky přímo ovlivněny zadanou hodnotou parametru. U rozsáhlejších datových objemů může být tento krok velice obtížný. Z tohoto důvodu jsou výhodnější metody, kde je potřeba minimální

znalost uživatele o datech a minimální počet nutných vstupních parametrů. Další vlastností metod je schopnost vypořádat se s neúplnými daty.

2.2 Základní metody a klasifikace

Základní rozdělení algoritmů shlukové analýzy je na hierarchické a nehierarchické metody. Hierarchické metody využívají dříve nalezené shluky a vytváří z nich shluky nové, kdežto nehierarchické metody rozkládají danou množinu do podmnožin.

A. Hierarchické

Vizualizace výsledků hierarchických metod se provádí pomocí binárního stromu nebo pomocí tzv. dendrogramu. Dendrogram svou strukturou připomíná strom, kde je na ose y vzdálenost mezi jednotlivými shluky.

(1) Podle směru utváření

- Aglomerativní – tento přístup bere každý prvek zpracovávané množiny jako shluk, shluky dále sjednocuje, až vznikne shluk obsahující všechny prvky dané množiny.
- Divizní – algoritmy berou vstupní množinu objektů jako celek a ten pak následně dělí. V každém kroku dochází k rozdělení na dva nové shluky, které nejlépe splňují dané kritéria rozkladu. Tento proces je náročný na výpočet a je realizovatelný pro malý počet vstupních objektů. Pro n prvků je nutno prozkoumat $2^{(n-1)}-1$ možností.

(2) Podle přístupu

- Monotetický (speciální typ Divizního shlukování) – Vytváření shluků probíhá na základě jedné proměnné.
- Polytetivký – Proměnné se berou v úvahu současně. [2]

B. Nehierarchické[7]

(1) k-průměr (K-Means)

Každý shluk reprezentován střední hodnotou objektů ve shluku.

(2) Modifikace k-průměru

- **k-medoid**
Každý shluk reprezentován jedním z objektů, a to umístěným blízko středu daného shluku.
- **k-mod**
- **k-histogram**

- **c-means (fuzzy means)**

C. Nové metody pro velké soubory (tato práce se zaměřuje hlavně na tuto skupinu metod, zejména na, metodu DBSCAN)

- **CLARA (Clustering LARge Applications)**
Vychází z metody k-metoidů.
- **CLARANS (Clustering LARge Applications based upon RANdomized Search)** - Vylepšení CLARA.
- **Metody založené na mřížce (BANG, STING, WaveCluster)**
Prostor objektů je rozdělen tzv. mřížkou. Jedná se o velice rychlou metodu.
- **Metody založené na hustotě (DBSCAN, OPTICS, DBCLASD)**
Velikost shluků se odvíjí od podobnosti, rozdílnosti sousedních objektů. Taková metoda může být použita k odstranění odlehlých hodnot (šumu), či nalezení libovolného tvaru. V kapitole 2.5 bude metoda DBSCAN probrána podrobněji.
- **Metody kombinované**
Kombinují více metod. [2,24]

D. Biologicky inspirované metody

- (1) Umělé neuronové sítě
- (2) Genetické algoritmy

2.3 Hierarchické shlukování

Jedna z hlavních metod shlukové analýzy. Základem této metody je přiřazování jednotlivých objektů do klastru na základě podobnosti. Graficky se hierarchicky uspořádané shluky zobrazují ve formě vývojového diagramu nebo dendrogramu. Jednotlivé uzly v dendrogramu reprezentují shluky.

Nevýhodou této metody je fakt, že se v každém kroku snaží dosáhnout nejlepšího výsledku pouze lokálně a nebere ohled na další postupy. Například u aglomerativního shlukování nelze jednou spojené shluky rozdělit a naopak při divizním shlukování, není možné rozdělené shluky v dalších krocích spojovat. Z těchto vlastností vyplývá, že metoda neumožňuje vylepšovat vlastnosti rozkladu.

2.3.1 Vstupní datová matice

Některé statistické metody vycházejí ze vstupní matice, v níž řádky reprezentují údaje o objektech a sloupce odpovídají jednotlivým proměnným. Vstupní datová matice má rozměr $n \times m$ a označujeme jí X .

Vstupní datová matice může vypadat takto:

$$X = \begin{bmatrix} x_{11} & \cdots & x_{1m} \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{nm} \end{bmatrix} \quad (2.1)$$

kde:

n ... objekt

m ... atribut (proměnná)

Dalším typem datové matice pro dvě kategoriální proměnné je dvourozměrná tabulka sdružených četností, tzv. kontingenční tabulka.

Některé metody vycházejí z matice vzdáleností, kde prvky matice charakterizují vztahy mezi všemi dvojicemi objektů. Vzdálenosti mohou být vypočítány na základě původní vstupní matice nebo v některých případech může být přímo k dispozici. Shlukovány nemusí být pouze objekty, ale předmětem shlukování můžou být i např. kategorie.

Ze statistického pohledu je žádoucí, aby vstupní datová matice obsahovala proměnné statisticky nevýznamné.

Podle typu škály měření rozlišujeme proměnné:

Nominální – nelze stanovit pořadí hodnot, hodnoty jsou různé.

Ordinální – je možné určit pořadí, ale nelze stanovit o kolik je hodnota větší nežli druhá.

Kvantitativní:

- *Intervalové* – lze určit o kolik je určitá hodnota větší.
- *Poměrové* – lze určit o kolik a kolikrát je hodnota větší.

Dichotomické (nabývá jen dvou hodnot):

- *Symetrické* – obě kategorie stejně důležité.
- *Asymetrické* – jedna kategorie má větší důležitost.

Kvantitativní můžeme dále rozdělit na:

- *Diskrétní* – celočíselné hodnoty.
- *Spojitě* – v určitém intervalu mohou nabývat libovolných hodnot.

Pokud jsou identifikovány odlehlé objekty, mělo by dojít k jejich vynechání ve vstupní matici.

2.3.2 Konstrukce matice (ne)podobnosti, Normalizace

Matici podobností získáme pomocí výpočtu jednotlivých vzdáleností mezi objekty tzv. Euklidovské vzdálenosti. Vzdálenosti vypočítáme pomocí rovnice (2.5). Do rovnice se dosazují hodnoty ze vstupní nebo standardizované matice.

Na hlavní diagonále ($a_{11}, a_{22}, a_{33}, \dots$) jsou vzdálenosti, respektive podobnosti objektů sama sebe. To je důvod, proč hlavní diagonála zůstává vždy nulová. Jedná se o jednu z možných forem. Používá se pro lepší matematickou interpretaci.

Před samotným výpočtem podobnosti/nepodobnosti objektů je dobré provést normalizaci vstupních dat, tedy přiřadit všem proměnným stejnou váhu. [2,7]

Postup normování může být následující [24]:

- 1) Výpočet středních absolutních hodnot odchylek, tím se redukuje vliv odlehlých hodnot [2]:

$$S_f = \sqrt{\frac{\sum_{i=1}^n (x_{if} - \bar{x}_f)^2}{n - 1}} \quad (2.2)$$

kde \bar{x}_f představuje aritmetický průměr:

$$\bar{x}_f = \frac{\sum x_{if}}{n} \quad (2.3)$$

- 2) Výpočet normovaných hodnot [2,24]

$$z_{if} = \frac{x_{if} - \bar{x}_f}{S_f} \quad (2.4)$$

Nová proměnná z_{if} má střední hodnotu 0 a směrodatnou odchylku 1.

2.3.3 Podobnost, Blížkost (Proximity)

Zde můžeme rozdělit na dvě skupiny:

- 1) **Konvenční shlukování**

Základní princip je založen na blízkosti bodů, objektů. Kde jsou objekty shlukovány na základě matice (ne)podobnosti a konkrétní metriky.

- 2) **Konceptuální shlukování**

Základní princip je založen na prošetření vlastností nejen dvou objektů, ale i okolí (množina sousedních vzorů) [2].

2.3.4 Metriky pro matici (ne)podobnosti

1) Míry vzdálenosti [25]:

- **Euklidovská vzdálenost** (Tuto metriku můžeme považovat za nejznámější.)

$$a_{ij} = \sqrt{\sum_{i=1}^m (x_{il} - x_{jl})^2} = \|x_i - x_j\| \quad (2.5)$$

- **Euklidovská vzdálenost vážená**

$$a_{ij} = \sqrt{w_l^2 \sum_{i=1}^m (x_{il} - x_{jl})^2} \quad (2.6)$$

- **Euklidovská vzdálenost čtvercová**

$$a_{ij} = \sum_{i=1}^m (x_{il} - x_{jl})^2 \quad (2.7)$$

- **Čebyševova**

$$a_{ij} = \max_l (|x_{il} - x_{jl}|) \quad (2.8)$$

- **Minkovského**

$$a_{ij} = \sqrt[q]{\sum_{i=1}^m |x_{il} - x_{jl}|^q} \quad (2.9)$$

- **Lanceyova-Williamova**

$$a_{ij} = \sum_{i=1}^m \frac{|x_{il} - x_{jl}|}{|x_{il}| + |x_{jl}|} \quad (2.10)$$

- **Manhattanská**

$$a_{ij} = \sum_{i=1}^m |x_{il} - x_{jl}| = |x_i - x_j| \quad (2.11)$$

- **Mahalanobisova vzdálenost**

$$a_{ij} = ((x_i - x_j)^T S^{-1} (x_i - x_j))^{\frac{1}{2}} \quad (2.12)$$

kde S je varianční matice dat.

- **A další ...**

2) Míry podobnosti [2]:

Míra podobnosti je další prvek, který je často používán na místo vzdálenosti.

Podobnost objektů je využita jako kritérium pro tvorbu shluků objektů. Velmi důležitý je způsob porovnávání podobnosti objektů. Vždy hledáme vhodný předpis π , který dané dvojici objektů O_j, O_k přiřadí číslo $\pi(O_j, O_k)$, které vyjadřuje míru podobnosti objektů. Takový předpis by měl splňovat alespoň tyto podmínky:

$$\pi(O_j, O_k) \geq 0 \quad (2.13)$$

$$\pi(O_j, O_k) = \pi(O_k, O_j) \quad (2.14)$$

Pokud tedy π považujeme za míru podobnosti, pak musí kromě podmínek (2.13) a (2.14) platit, že podobnost objektu se sebou samým je maximální. Tedy, čím více jsou si objekty podobné, tím více hodnota π narůstá.

Pro účely shlukování se velmi často používá tzv. míra nepodobnosti V . I v tomto případě musí platit podmínky (2.13) a (2.14), ale pro podobnost totožných objektů musí platit $V(O_j, O_k) = 0$.

I přesto, že jsou pravidla pro míru přesnosti či nepřesnosti přesně stanovena, neexistuje univerzální míra, kterou lze použít na všechny typy dat a typy úloh. [7]


- **Kosinova míra**

$$S_{ij} = \frac{\sum_{l=1}^m x_{il}x_{jl}}{\sqrt{\sum_{l=1}^m x_{il}^2 \sum_{l=1}^m x_{jl}^2}} \quad (2.15)$$

- **Jaccardův koeficient**

$$S_{ij} = \frac{\sum_{l=1}^m x_{il}x_{jl}}{\sum_{l=1}^m x_{il}^2 + \sum_{l=1}^m x_{jl}^2 - \sum_{l=1}^m x_{il}x_{jl}} \quad (2.16)$$

- **A další...**




Obrázek 8 - Ukázka vybraných metrik[26]

2.3.5 Měření vzdálenosti mezi shluky

Tento pojem se uplatňuje hlavně u Hierarchických metod. Metody dělíme na [27]:

1) Metoda nejbližšího souseda (nearest-neighbour, sigle-linkage)


Vzdálenost dvou shluků je dána vzdáleností dvou nejbližších objektů těchto shluků.



Obrázek 9 - Metoda nejbližšího souseda[27]

2) Metoda nejvzdálenějšího souseda (furthest-neighbour, complete-linkage)


Tato metoda funguje na opačném principu nežli metoda předchozí, tedy vzdálenost určují dva nejvzdálenější objekty dvou shluků.



Obrázek 10 - Metoda nejvzdálenějšího souseda[27]

3) Metoda průměrné vazby

Metoda průměrné vazby je takzvaným kompromisem mezi metodou nejbližšího a nejvzdálenějšího souseda. Vzdálenost dvou shluků je průměrem vzdáleností všech dvojic.




Obrázek 11 - Metoda průměrné vazby[27]

4) Mediánová metoda

Tato metoda byla vyvinuta na základě centroidní metody, neboť rozdílné počty objektů shluků způsobují rozdílné váhy prvních dvou složek předpisu centroidní metody, a tím se vlastnosti malých shluků ztrácejí. [2]

5) Centroidní metoda

Vzdálenost dána vzdáleností dvou centroidů shluků.



Obrázek 12 - Centroidní metoda

6) Wardova – Wishartova metoda

Odlišný přístup, než-li metody předešlé. Slučuje takové shluky, u kterých sloučením dochází k minimalizaci kritéria euklidovského součtu vzdáleností mezi centroidy a jednotlivými shluky. Algoritmus této metody má tendence odstraňovat malé shluky a vytvářet shluky podobných velikostí.

2.4 Nehierarchické metody shlukování

Tato metoda nevytváří hierarchickou strukturu, ale dochází k rozkladu do podmnožin podle daného kritéria. Rozklad na podmnožiny se dále nedělí, ale dochází k optimalizaci vzájemné vzdálenosti a odlišnosti shluků, tak aby objekty byly rovnoměrně rozloženy. Ve většině případů začíná nehierarchické shlukování s předem daným rozkladem, ten se dále upravuje a hledá se optimální rozklad. Nevýhodou však může být pouze lokálně optimalizovaný rozklad.

Před zahájením samotné analýzy je nutnost zjistit optimální počet shluků. Podle této skutečnosti můžeme nehierarchické shlukování rozdělit na metody s pevně daným počtem shluků a metody, kdy se počet shluků mění i v průběhu procesu shlukování. Pro určení ideálního počtu shluků se využívá různých vypočtených indexů na základě proměnlivého faktoru K , jako je například Goodman-Kruskal, C index a další. A nakonec je nutné určit počáteční rozklad.

Nehierarchických metod je velké množství, v této práci bude uveden příklad metody založené na centrálním bodu, tzv metoda *K-Means*.

2.4.1 Metoda založena na centrálním bodu (K-Means)

Jedná se o jeden z nejjednodušších algoritmů využívaných pro shlukování. Na základě předem definovaného parametru k (počet shluků musí být zadáno uživatelem), dochází k rozdělení datové množiny n objektů do k -tříd. Třídy jsou prezentovány pomocí fiktivního centrálního bodu, který je získán jako střední hodnota objektů třídy. Výběr třídy závisí na vzdálenosti k centrálnímu bodu. Proces přerozdělování do tříd končí právě tehdy, když v právě probíhající iteraci nedojde k přesunu žádného objektu do jiné třídy.

Postup algoritmu:

1. *Zadání počtu shluků k , vygenerování nebo zadání těžiště shluků.*
2. *Výběr shluku pro každý objekt, který je nejvíce podobný a to z pohledu vzdálenosti k centrálním bodům třídy.*
3. *Aktualizace centrálních bodů tříd spočítáním průměru hodnot pro jednotlivé atributy všech objektů třídy.*
4. *Pokud již nedochází k přesouvání objektů do tříd, proces je ukončen (jinak následuje návrat do bodu 2.)*

Jednoznačnou výhodou je jednoduchost, rychlost a aplikovatelnost na větší objemy dat. Naopak nevýhodou je, že výsledky jsou ovlivňovány výběrem shluků a jelikož dochází k přepočítávání těžiště, výsledek ovlivňuje i původní pořadí objektů. Metoda K-Means není vhodná aplikovat tam, kde očekáváme překrývající se objekty. [2,7]

2.5 Metoda DBSCAN

Při shlukování založeném na hustotě jsou shluky považovány za oblasti s vysokou hustotou objektů v datovém prostoru. Tyto shluky jsou odděleny oblastmi s nižší hustotou objektů. Algoritmus DBSCAN popisuje shlukování pomocí dvou parametrů: [4]

2.5.1 Základní myšlenka DBSCAN algoritmu

Centrální hustota patří mezi nejpoužívanější typy hustot. Princip spočívá v odhadování hustoty pro určité body v množině dat, kdy je počítáno množství bodů v určitém okruhu kolem centra. Centrum se počítá také jako součást shluku. Tato technika je ilustrována na obrázku číslo 13, kde body ve stanovené kružnici, včetně bodu *A*, reprezentují centrální hustotu.

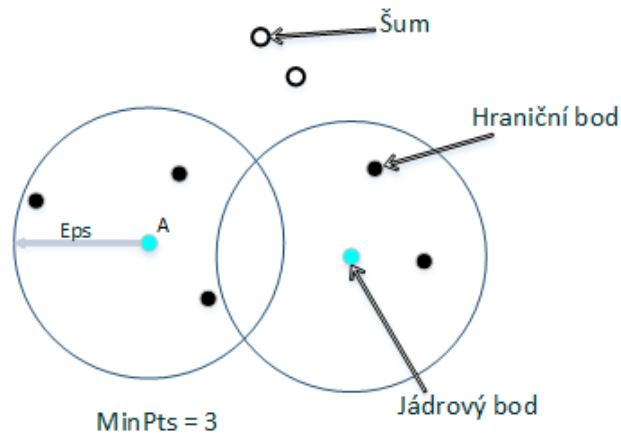


Obrázek 13 - Centrální hustota

Klasifikace bodů vzhledem k centrální hustotě

Díky centrální hustotě klasifikujeme body:

- *Jádrový bod* – tento bod se nachází uvnitř shluku. Bod považujeme za jádrový, pokud počet bodů uvnitř daného sousedství okolo bodu určeného funkcí vzdálenosti a parametrem vzdálenosti daného uživatelem dosahuje nějaké hranice.
- *Hraniční bod* – tento bod není jádrový, ale je zařazen do sousedství kolem jádrového bodu. Hraniční bod může spadat pod několik jádrových.
- *Šumy a body v pozadí* – ostatní body, které jsou náhodně rozptýleny a vyskytují se v řídké obsazených oblastech.



Obrázek 14 - Jádrové, okrajové a šumové body

DBSCAN je klastrovací algoritmus založen na hustotě. DBSCAN rozděljuje oblast, která má dostatečný počet vzorků do různých shluků a objevuje náhodné shluky v prostorové bázi, která má šum (hluk) [4]. DBSCAN využívá dva důležité vstupní parametry Epsilon (Eps) a minimum bodů ($MinPts$). Základní myšlenka DBSCAN algoritmu obsahuje řadu definic, tyto definice jsou uvedeny níže a ilustrovány na obrázku číslo 18.

ϵ -okolí: každý bod v okolí rádiusu $\epsilon(Eps)$ se nazývá ϵ -okolí P a je definován:

$$N_{Eps}(p) = [q \in D \text{ dist}(p, q) < Eps] \quad (2.17)$$


Klíčový bod: Pokud je ϵ -okolí v daném bodě Q větší nebo rovno $MinPts$, pak Q nazýváme klíčovým bodem.

Přímo dosažitelný: Pokud P je v ϵ -okolí Q a Q je středový bod, pak můžeme říct, že P je přímo dosažitelné z Q .

Dosažitelný: Pokud máme sít' bodů $P_1, \dots, P_N, P_1=P$ a $P_N=Q$ a během toho P_i je přímo dosažitelné z $P_{i+1} (1 \leq i < n)$, pak můžeme říct P je dosažitelné z Q .

Hustotně - připojené: P je hustotně - připojené na Q vyjádřené tak, že existuje bod O , který je dosažitelný z bodu P a Q s ohledem na Eps a $MinPts$.

Shluk: Shluk je maximální množina hustotně – připojených bodů.



Obrázek 15 - Definice DBSCAN

DBSCAN vyhledává klíčové body tak, že prohledává ε -okolí každého bodu v databázi. Je-li bod P klíčový bod, pak hledá všechny hustotně dosažitelné body z P . Mezitím vyhledává všechny klíčové body v ε -okolí P a všechny body, které jsou hustotně připojené s těmito klíčovými body. Dalším krokem je shlukování těchto bodů do shluku. Následně DBSCAN prověřuje zbývající body a opakuje výše uvedené kroky. Tento proces se ukončí, pokud nejsou přidány žádné nové body do jakéhokoliv shluku. Body, které nebyly přidány do žádného shluku, jsou považovány za šum.

DBSCAN má několik výhod, jako je třeba, reprezentace libovolného tvaru shluků, dobrá detekce šumu a vysoká rychlost klastrování. A na rozdíl od metody K-Means, DBSCAN nevyžaduje, aby uživatel zadal počet clusterů, které mají být generovány. Avšak existují i určité nevýhody. Algoritmus je citlivý na parametry. Pokud se v databázi vyskytne oblast s nízkou hustotou a hodnota *Eps* bude příliš malá, pak budou užitečná data klasifikována jako šum, a naopak by mohlo dojít k rozdělení šumu do shluku. K tomuto dochází díky nerovnoměrnému rozložení databáze. Na druhou stranu, pro velké databáze dochází k ovlivnění výkonu v reálném čase. [5]

2.5.2 Algoritmus DBSCAN

Algoritmus vyžaduje zadání parametrů *Eps* (určuje vzdálenost bodů, aby byly považovány za součást klastru) a *MinPts* (minimální počet bodů pro vytvoření klastru) potřebných pro vytvoření klastru. Po zadání parametrů DBSCAN začne v libovolně zvoleném bodě, který nebyl navštíven. Pokud sousedství tohoto bodu obsahuje dostatečné množství bodů, zahájí se klastrování. V opačném případě je bod označen jako šum.

Tento proces probíhá až do úplného nalezení klastru. Dále dochází k načtení a zpracování nového nenavštíveného bodu a to vede k nalezení dalšího klastru nebo šumu.

DBSCAN může být použit s libovolnou vzdálenostní funkcí. [34]

2.5.3 Výhody a nevýhody metody DBSCAN

Vzhledem k tomu, že DBSCAN pracuje se shluky založenými na hustotě, je poměrně odolný vůči šumu a umí pracovat se shluky libovolné velikosti a libovolných tvarů. Díky těmto důvodům často nalézá shluky, které jiné algoritmy nedovedou nalézt. Proto je DBSCAN často využíván.

Výhody:

- Nevyžaduje určit konkrétní počet shluků v datech.
- Vyžaduje zadání pouze dvou parametrů a většinou nereaguje na pořadí bodů databáze.
- Bere v potaz šum.

- Dokáže najít shluky libovolného tvaru. Dokáže rozpoznat shluky, které se těsně obklopují.

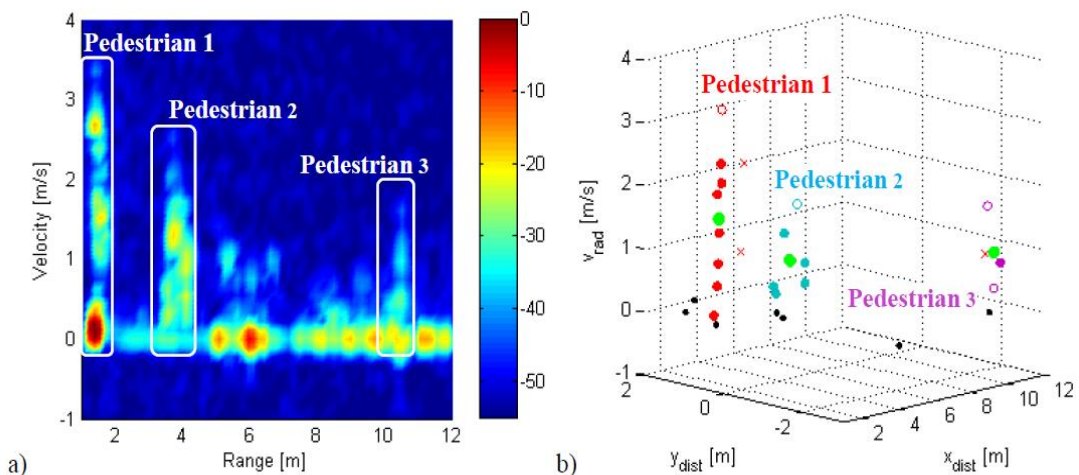
Nevýhody:

- Běžně používanou metrikou je Euklidovská vzdálenost, avšak pro vysoko-dimenzionální data tato metoda ztrácí efektivitu.
- Nepracuje dobře s hierarchickými datovými množinami (datová množina s měnící se hustotou).
- Kvůli obtížnému definování hustoty se nehodí pro vysoko-dimenzionální data.
- Pro vysoko-dimenzionální data velmi náročné v případě, kdy je zapotřebí výpočet nejbližšího souseda mezi každými dvěma sousedy.
- Vyšší časová náročnost oproti metodě Kmeans.

2.5.4 Aplikace metody DBSCAN

Jako důkaz, že metoda DBSCAN je vhodná pro použití v automobilovém průmyslu, bude v následující části práce popsána ukázka z měření tří chodců procházejících před radarovým senzorem. Na obrázku 18a můžeme vidět Dopplerovské spektrum s jednou sekvencí z měření. Vedle stacionárních bodů jsme schopni rozlišit přítomnost tří cílů s kinetickým šířením. Zatímco první osoba prochází radiálně, tedy vykazuje největší kinetické šíření, třetí osoba se vůči radaru pohybuje téměř tangenciálně směrem a vykazuje šíření nejmenší.

Obrázek 18b zobrazuje tři oddělené klastry a jejich centroidy po aplikaci DBSCAN metody. V tomto konkrétním případě byla hodnota parametru Eps nastavena na 1 m, $MinPts$ na hodnotu dvou. Centroidy shluků jsou vyznačeny zelenou tečkou, stacionární detekce jsou vyznačeny černými tečkami a šum červenými křížky. Stacionární a pohyblivé cíle byly odděleny zavedením prahové hodnoty $v_{min} = 0,1 \text{ m/s}$. [15]



Obrázek 16 - Aplikace DBSCAN [15]

3. Praktická část

Cílem praktické části této práce bylo určit vhodnou metodu a parametry shlukové analýzy. Pomocí shlukové analýzy byly vytvářeny konkrétní shluky (klastry) z detekcí poskytnutých FMCW radarem.

Praktická část je rozdělena na dvě základní části. Generátor cílů, kde dochází k vytvoření syntetických dat, určení parametrů shlukových metod a ověření správné funkčnosti aplikovaných algoritmů. A část dva, kde jsou metody shlukové analýzy aplikovány na reálná data ze silničního provozu. Závěrem práce je vyhodnocení použitých metod a vyhodnocení optimálních parametrů daných metod.

3.1 Generátor cílů

Cílem generátoru je ověření správné funkčnosti algoritmů a zvolení optimálních parametrů shlukových metod na syntetických datech.

Jeden ze základů generátoru cílů je konfigurační soubor. Ten specifikuje jak pozice, tak rychlost a směr jízdy objektů v daném časovém kroku.

Referenční vozidlo disponuje čtyřmi radary (radar umístěn v každém rohu vozidla). Detekce okolních objektů jsou založeny na principu vysílání linie s určitým vzorkovacím krokem, do určitého FOV (*Field Of View*) a s určitým rozsahem. Po vizualizaci zaznamenaných detekcí dochází k aplikaci shlukových metod. Detailnější popis generátoru bude rozdělen do jednotlivých bloků níže.

3.1.1 Konfigurační soubor

Konfigurační soubor je vytvořen a načítán v textovém formátu. Konfigurační soubor se skládá z hlavičky a těla. Hlavička (*header*) souboru specifikuje počáteční hodnoty pozice x_0 , y_0 a počáteční rychlost v_0 . Tělo souboru obsahuje informace o směru φ a zrychlení a v jednotlivých časových okamžicích.

```
%Konfigurační soubor: řádek 2 - statické informace objektu, sloupce - dynamické informace objektu
%x_0|y_0|v_0;0;0;0;-2.5;0;1;-2.1;-5;1;0;4.5;0;0;-9;1
1      0      90      0      90      0      90      0      90      0      90
2      0      90      0      90      0      90      0      90      0      95
3      0      90      0      90      0      90      0      90      0      100
4      0      90      0      90      0      90      1      90      0      110
5      0      90      0      90      0      90      0      90      0      120
```

Obrázek 17 - Ukázka konfiguračního souboru

3.1.1.1 Popis struktury objektů


Pro lepší práci a případné modifikace byla vytvořena struktura. Struktura obsahuje:

Statické informace:

- Index objektu id
- Počáteční pozice x_0
- Počáteční pozice y_0
- Počáteční rychlost v_0
- Rozměry vozidla

Dynamické informace:

- Pro každý časový úsek obsahuje informaci o poloze, rychlosti a zrychlení (počítáno z předešlého časového úseku), směr a souřadnice nově orodovaného objektu.



Obrázek 18 - Popis výpočtu pozice objektu

Výpočet pozice objektu pro první časový okamžik probíhá z počátečních hodnot a směru. Pomocí následujících vztahů určujeme polohu objektu.

$$x_1 = x_0 + d * \cos\varphi \quad (3.1)$$

$$y_1 = y_0 + d * \sin\varphi \quad (3.2)$$

Hledaná vzdálenost d_1 k bodu A:

$$d_1 = v * t \quad (3.3)$$

Pro další časové okamžiky již uvažujeme zrychlení a a výpočet je následující:

$$v_{i+1} = v_i + a_i * t \quad (3.4)$$

$$d_2 = v_1 * t + \frac{1}{2} a_1 * t \quad (3.5)$$

3.1.2 Detekce objektů

Základním principem vytvoření detekce je průnik dvou přímek. Z místa pozice radaru dochází k vysílání linie a v případě protnutí této linie s jakoukoliv hranou potenciálního objektu, tedy dvou přímek, dochází k vykreslení detekce.

Principem je tedy průsečík vysílaného paprsku a hrana vozu. Pro výpočet průsečíku bylo nejprve nutné nadefinovat vektor úsečky a z něho vytvořit normálový vektor. Následně vyřešením soustavy rovnic o dvou neznámých došlo k získání hledaného průsečíku.

Základem pro hledání průsečíku je obecná rovnice přímky (3.5) a její směrnicový tvar (3.6):

$$k: ax + by + c = 0 \quad (3.5)$$

$$p: y = kx + q \quad (3.6)$$

Dalším krokem je určení směrového vektoru \vec{u} a z něho následné vytvoření normálového vektoru n :

$$\vec{u} = [x_2 - x_1, y_2 - y_1] \quad (3.7)$$

$$n = [u_2, -u_1] \quad (3.8)$$

Sestavení matic A a b pro řešení soustavy rovnic. Řešením soustavy rovnic je průsečík.


$$A = \begin{bmatrix} n1 & n2 \\ -k & 1 \end{bmatrix} \quad (3.7)$$

$$b = \begin{bmatrix} n1 * x1 + n2 * y1 \\ -k * stred_X + stred_Y \end{bmatrix} \quad (3.8)$$

Hledaný průsečík dostaneme po dosazení do následujícího vztahu:

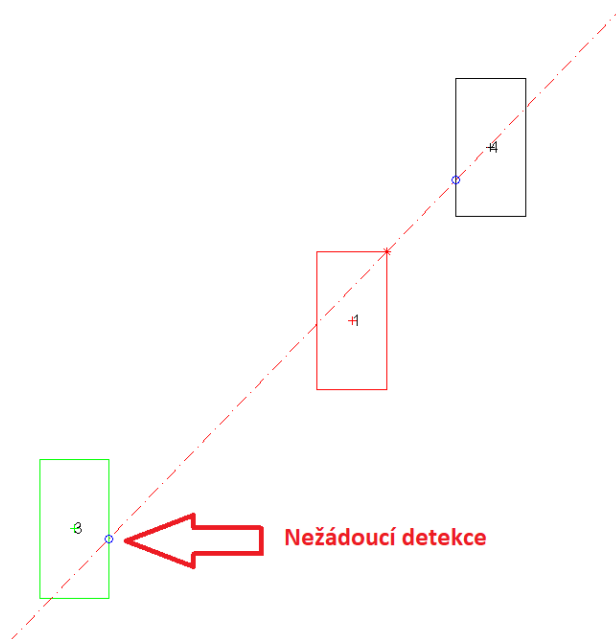
$$x = A \setminus b \quad (3.9)$$

Vykreslením výše popisovaných rovnic, můžeme názorně vidět na obrázku 19, kdy červený objekt představuje referenční vozidlo. Na referenčním vozidle jsou umístěny v každém rohu radary. Vyzařování radaru v určitém FOV reprezentují červené přerušované čáry. Detekce jsou vizualizovány modrým kroužkem na hraně objektu. Jedná se tedy o místo, kde dochází k protnutí vysílané linie a hrany detekovaného vozidla (průsečík dvou přímek, jak je popsáno v horní části této kapitoly).




Obrázek 19 - Vykreslení detekcí objektů

Vykreslení detekcí bylo nutné ošetřit několika podmínkami. Nejprve bylo nutné omezit vysílání generovaného paprsku pouze ve směru FOV radaru a uvažovat pouze detekce v kvadrantu kam FOV směřuje. Na obrázku 20 je zobrazena situace, kdy dochází k obousměrné detekci průsečíku.




Obrázek 20 - Obousměrně vykreslované detekce

Další podmínkou, která byla nezbytná pro správné určení hledané detekce, byla detekce pouze na hraně vozu. Obrázek 21 je rozdělen na dvě části a) a b), kde obrázek a) popisuje situaci vykreslení detekcí na všech místech, kde dochází k průsečíku dvou přímek. Pro naše účely ovšem nežádoucí, a proto musela být aplikována podmínka omezující vykreslení pouze na hraně vozidla. Obrázek 21b) popisuje stav po aplikování podmínky pro detekci pouze na hraně vozidla a zároveň aplikaci další podmínky pro vykreslení pouze detekce na základě nejkratší vzdálenosti (tato podmínka bude detailněji rozvinuta níže).



Obrázek 21 – Ošetření vykreslení detekcí na hraně vozidla

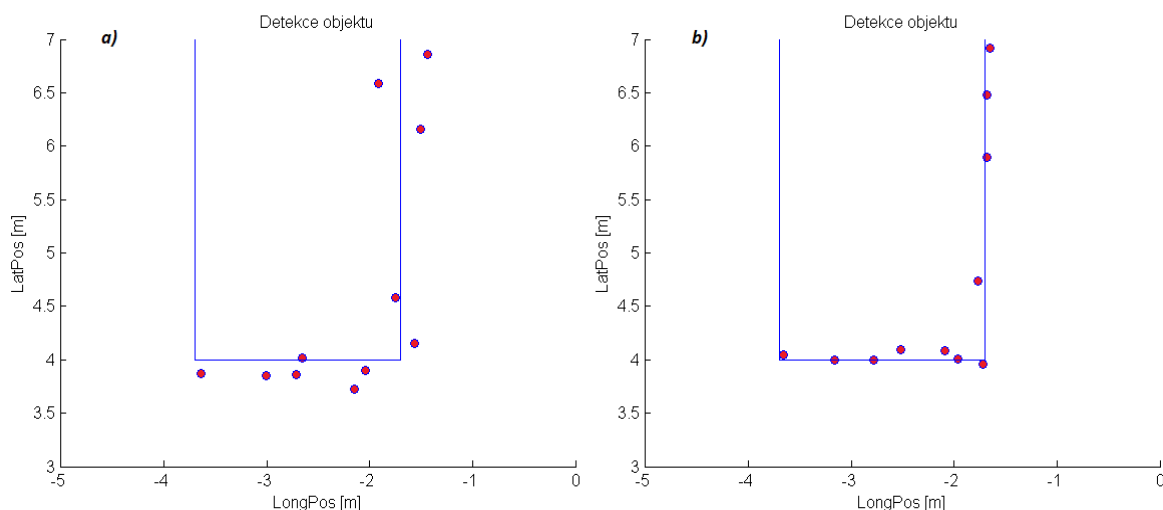
Poslední nutnou podmínkou bylo nastavení vykreslení pouze detekce s nejkratší vzdáleností od místa vyzařování. Touto elementární podmínkou předcházíme vykreslení více detekcí na jedné linii. Předcházíme tím vykreslení falešných detekcí, jako např. vykreslení více detekcí na jedné linii u jednoho objektu (obrázek 21a). Nebo případné vykreslení detekcí na objektu v zákrytu, tedy na objektu, který radar prakticky není schopen detekovat (viz obrázek 22).



Obrázek 22 – Ošetření detekcí v zákrytu

Obrázek 22a) popisuje nesprávné vykreslení detekcí zákrytu, tedy nežádoucí situaci. Na obrázku 22b) je situace s ošetrovací podmínkou a získáváme požadovaný výstup.

Po úspěšné vizualizaci detekcí na hraně sledovaného objektu bylo aplikováno do místa detekcí Gaussovské rozdělení. Gaussovské rozdělení bylo aplikováno z důvodu realistické vizualizace. Na obrázku 23 můžeme vidět rozložení detekcí v okolí hrany objektu. Bod vytvořené detekce představuje střed pomyslné kružnice, ve které dochází ke generování n -objektů podle Gaussova rozdělení. Velikost kružnice je dána svým poloměrem a pravděpodobnost výskytu n -detekcí je ovlivňována směrodatnou odchylkou σ . Vliv směrodatné odchylky je znázorněn na obrázku 23. Čím nižší hodnota směrodatné odchylky je zvolena, tím je větší pravděpodobnost generování detekcí v bodě průsečíku, resp. na hraně objektu. Obrázek 23 je rozdělen na dvě části. Část a) popisuje Gaussovo rozdělení s poloměrem kružnice $r = 0,3$ parametrem $\sigma = 0,5$, a část b) s parametry $r = 0,3$ $\sigma = 0,03$.



Obrázek 23 – Gaussovské rozdělení detekcí

3.1.3 Aplikace shlukové analýzy

Za pomoci konfiguračního souboru s různými druhy jízdních scénářů bylo možné vizualizovat detekce na vozidlech. V první fázi došlo k vykreslení scénáře pouze z konfiguračního souboru. V druhé fázi byla přidána funkce pro vytvoření detekcí na hranách vozidel a aplikace shlukových metod. Zde bylo důležité ověřit správnou funkci algoritmu a určení optimálních parametrů jednotlivých shlukových metod. Z teoretického popisu shlukových metod byly vybrány metody DBSCAN a K-MEANS. Metoda K-MEANS byla zvolena pro svou jednoduchost, rychlost a aplikovatelnost na větší objemy dat. Metoda DBSCAN byla zvolena na základě svých předností. Hlavními výhodami metody DBSCAN je práce s libovolným počtem shluků bez nutné definice před zahájením klastrování a práce s libovolným tvarem klastrů. Další výhodou této metody je zadávání pouze dvou parametrů. Problematika určení parametrů shlukové metody je popsána v práci níže.

3.1.3.1 K-MEANS

Vstupem funkce jsou souřadnice bodu v n -dimenzionálním prostoru, které chceme klastrovat a počet n -klastrů. Parametr n -klastrů musí být definovaný před zahájením klastrování.


Vstupní body se rozprostřou náhodně do n -klastrů a určí se tzv. centroidy. V této práci je centroidem průměrná hodnota souřadnic pro osu x a y .

Dále se v cyklu spočítá vzdálenost od centroidů pro každý bod a vybere se vzdálenost minimální, index pro který je vzdálenost nejmenší, a vloží se do příslušného klastru. Po aktualizaci centroidu dochází ke zjištění, zda se klastr změnil oproti předchozímu kroku. Pokud ano, jede se dál, pokud ne, cyklus se ukončí a klastrování je ukončeno. V této práci je navíc ošetřeno podmínkou maximálního počtu iterací, kdy při dosažení maximálního nastaveného počtu iterací dochází také k ukončení klastrování.

3.1.3.2 K-MEANS dosažené výsledky

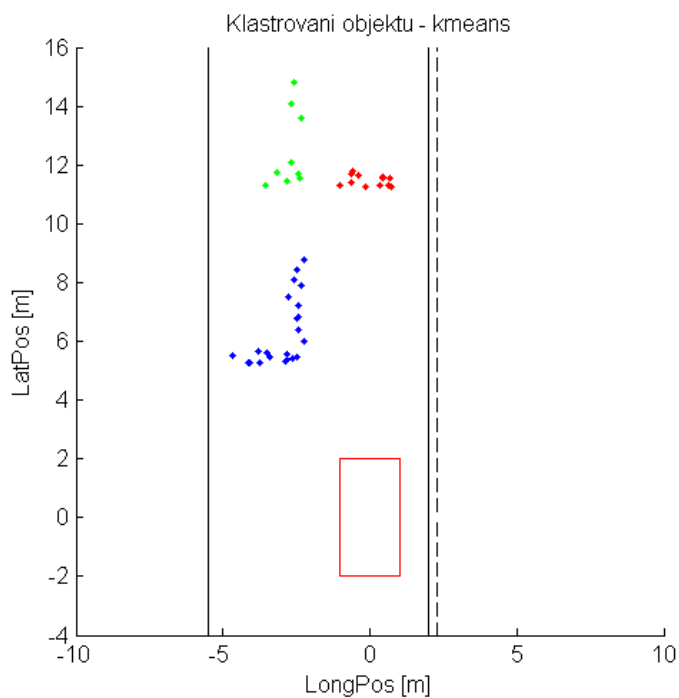
U metody K-MEANS nebylo nutné zjišťovat náležitě parametry, jako tomu bylo u metody DBSCAN. Není tedy nutné provádět studii a analýzu potřebných parametrů, což může být značnou výhodou. Na druhou stranu, jak bylo zmíněno v teoretické části, K-MEANS potřebuje před zahájením klastrování definovat počet klastrů. Na následujících obrázcích jsou naznačeny výsledky metody v různých situacích.

Obrázek 24 popisuje jednoduchou situaci, kde jsou radarem detekovány tři objekty. Situace slouží jako příklad pro aplikaci metody. Detekované objekty nesou označení 2, 3, 4.




Obrázek 24 - Ukázka detekcí pro ukázkou K-MEANS

V případě, kdy známe počet detekovaných objektů k , metoda K-MEANS je vhodnou a velice dobře fungující metodou. Při zadání počtu shluků $k=3$, metoda správně vyhodnotí situaci z předchozího obrázku. Výsledek metody je uveden na obrázku 25, kde objekt 2 reprezentuje zelený klastr, objekt 3 červený klastr a objekt 4 modrý klastr.



Obrázek 25 - Správná klasifikace metody K-MEANS


V případě, kdy počet klastrů není definovaný, metoda není schopna sama rozpoznat jednotlivé objekty. V tomto případě dochází ke špatnému zařazení detekcí a následnému vytváření nesprávných klastrů. Obrázek 26 popisuje totožnou situaci, ale hodnota počtu objektů je nyní zvolena $k = 2$.



Obrázek 26 - Nesprávná klasifikace metody K-MEANS

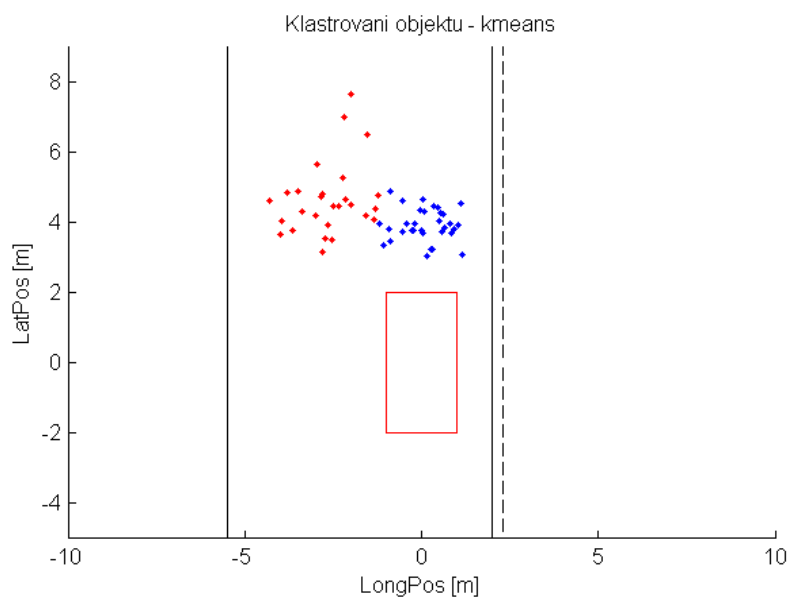
V případě zvolení počtu klastrů $k = 2$ bylo dosaženo nežádoucích výsledků. Objekt 4 (*modrý klastr*) byl klasifikován správně, ale u objektů 2 a 3 došlo ke sloučení v jeden velký klastr (*červený klastr*). Tento fakt je nežádoucí a metoda bez znalosti počtu klastrů nemůže být aplikována.

Na druhou stranu bylo z pozorování chování metod zjištěno, že nastávají situace, kdy metoda K-MEANS prokazuje lepší výsledky než metoda DBSCAN. V případech, kdy se objekty nacházejí v těsné blízkosti, může docházet k vytváření nepřehledných shluků detekcí. Na následujícím obrázku jsou detekce nasimulovány s větším rozptylem σ . Záměrem bylo simulovat méně přehlednou situaci většího shluku a pozorovat chování metody.



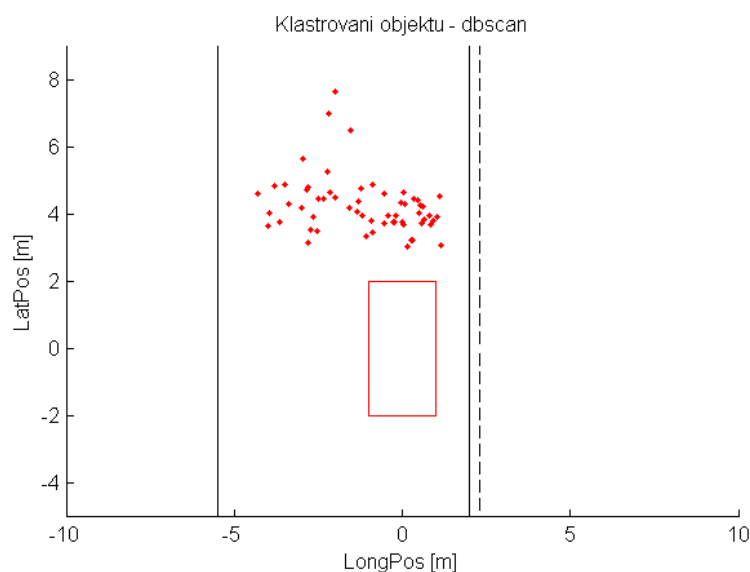
Obrázek 27 - Detekce objektů s větším rozptylem

Výsledek klastrování ukázal, že pro situace tohoto typu je vhodnější metoda K-MEANS. Na obrázku 28 je vidět správné rozdělení objektů 2 (červený klastr) a 3 (modrý klastr) do dvou klastrů.



Obrázek 28 - Aplikace KMEAN

Naopak metoda DBSCAN není schopna na takových to datech rozpoznat, zda se jedná o objekt větších rozměrů, či více objektů v těsné blízkosti. Výsledkem DBSCAN shlukování je vytvoření jednoho velkého shluku, což by v dané situaci znamenalo ztrátu objektu (obrázek 29).



Obrázek 29 - Aplikace DBSCAN

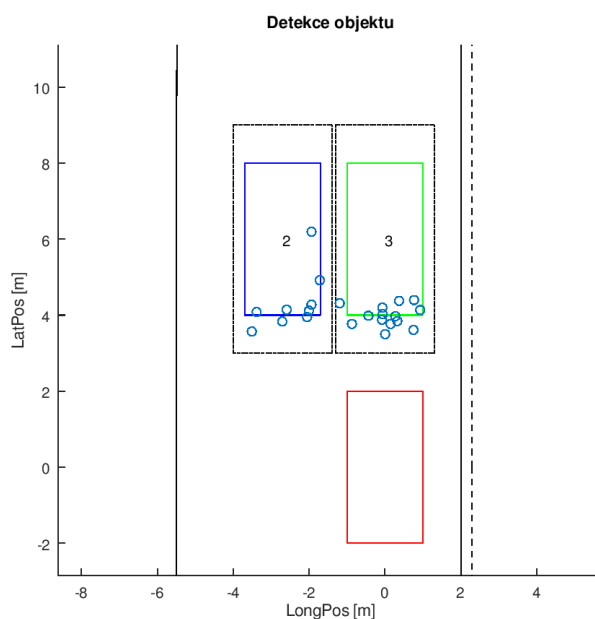
Z dosažených výsledků z generátoru a teoretických znalostí byla metoda K-MEANS uznána za nevhodnou pro použití na reálných datech. Zejména z důvodu neznámého počtu potřebných klastrů před zahájením algoritmu. Reálná data byla naměřena v silničním provozu a každý scénář obsahuje neznámý počet objektů.

Pro úvahu použití metody K-MEANS by bylo nutné provést analýzu zpracovávaných dat a na základě pravděpodobností určit počet objektů v datech. Analýza zpracovávaných dat za účelem použití metody K-MEANS, popřípadě lepší kontroly dosažených výsledků by mohla být jedním z potenciálních vylepšení této práce.

3.1.3.3 Metoda DBSCAN

S ohledem na charakter shlukovaných dat se metoda DBSCAN jeví jako vhodná varianta. Shlukované detekce obvykle kopírují konturu sledovaného objektu s relativně velkou hustotou bodu. Hlavními důvody, proč zvolit metodu DBSCAN pro aplikaci na reálných datech z provozu, byla její flexibilita a dynamičnost vůči datům, schopnost vytvářet shluky takřka libovolných tvarů, schopnost pracovat s libovolným počtem klastrů bez definice před zahájením algoritmu.


Základem metody DBSCAN jsou parametry *Eps* a *MinPts*, kde *Eps* určuje velikost oblasti pro potenciální detekce a vytvoření shluku. *MinPts* určuje minimální počet detekcí pro vytvoření shluku. Nastavení hodnoty těchto parametrů výrazně ovlivňuje výsledky, a proto jim musela být věnována značná pozornost. Pro určení optimálních parametrů metody byly vytvořeny tzv. klastrovací brány. Na obrázku číslo 30 jsou znázorněny brány na objektech číslo 2 a 3. Brány jsou vizualizovány přerušovanou čarou a určují maximální velikost klastru.



Obrázek 30 - Klastrovací brány


Velikost klastrovacích bran je závislá na absolutní rychlosti objektů. Pro větší rychlosti (větší rozestupy objektů) je možné zvolit větší brány a naopak pro menší rychlosti (menší rozestup bran) je nutné nastavit brány menších rozměrů. Limitním případem je jízda objektů ve městě, kde předpokládáme nejmenší rychlosti. Na základě definovaných bran dochází ke zvolení optimálních parametrů klastrovacích metod.

Na následujícím obrázku (obrázek 31) je naznačena situace, kdy jsou brány zvoleny nesprávně, tedy dochází k tzv. vykrádání detekcí jiného objektu. Vykrádání detekcí je možné omezit shlukovou metodou K-MEAN nebo navržením snížení klastrovacích bran (Obrázek 32).



Obrázek 31 - Vykrádání detekce sousedního objektu

Obrázek 32 popisuje správné nastavení klastrovacích bran, kde brány obsahují pouze detekce daného objektu. Klastr nenabývá větších rozměrů, než je rozměr definované brány.



Obrázek 32 - Správné nastavení klastrovacích bran

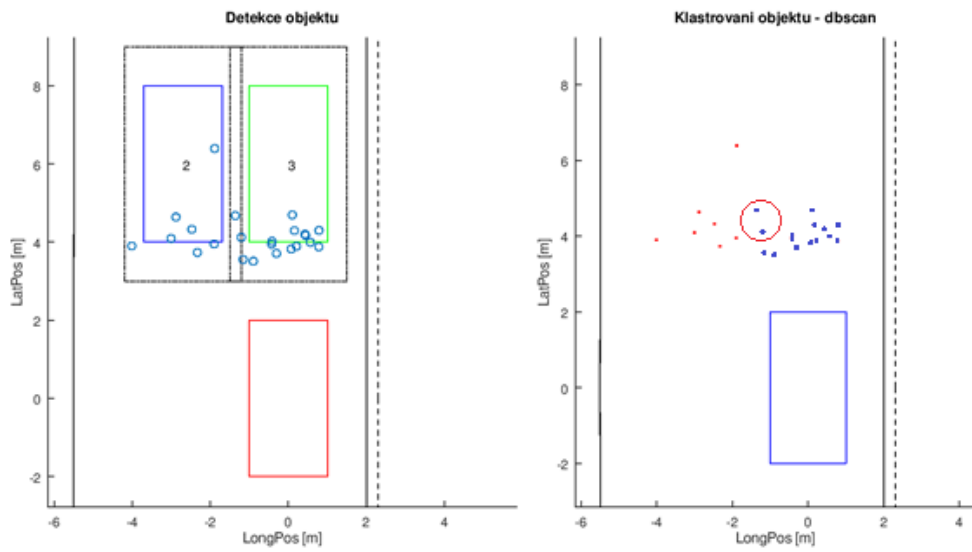
3.1.3.4 Funkce DBSCAN

Základ funkce DBSCAN spočívá ve spočítání matice vzdáleností D . Vzdálenost všech detekcí je počítaná pomocí Euklidovské metriky. Funkce spočítá vzdálenost mezi všemi detekcemi a dále již pracuje pouze s maticí vzdáleností. Funkce nepracuje s velkým množstvím dat, ale pouze s indexy matice, které splňují zadané podmínky. Výsledná matice vzdálenosti je rozměru $M \times N$, kde rozměr $M \times N$ je závislý na vstupních datech. Matice vzdáleností obsahuje nulové hodnoty na hlavní diagonále a indexy kolem hlavní diagonály jsou symetrické. Nulová hlavní diagonála je dána tím, že detekce má rozdíl vzdáleností sama se sebou nulový.

V dalším kroku funkce dochází k ošetření již navštívených detekcí a prochází matici D řádek po řádku a vyhledává pouze indexy matice D , které jsou menší než zadaný parametr Eps . Pokud je počet detekcí menší než $MinPts$, pak je detekce označena jako šum. V opačném případě dochází k přiřazení k potenciálnímu klastru a pokračuje v prohledávání. Funkce je ukončena, pokud již nejsou indexy matice D ke klastrování.


3.1.3.5 Výsledky DBSCAN

V případě, kdy klastrovací brána nebyla zvolena optimálně, docházelo k vykradení detekce sousedního objektu a k nekorektnímu vytvoření shluků. Na obrázku 33 je v levé části popsána situace nejprve z pohledu generátoru cílů, kde se nacházejí detekce (*modré kroužky*) objektů 2 a 3 a v pravé části obrázku vytvořené shluky metodou DBSCAN. Červeným kroužkem jsou označeny chybně zařazené detekce, které patří do sousedního shluku.



Obrázek 33 - Nesprávné nastavení klastrovací brány

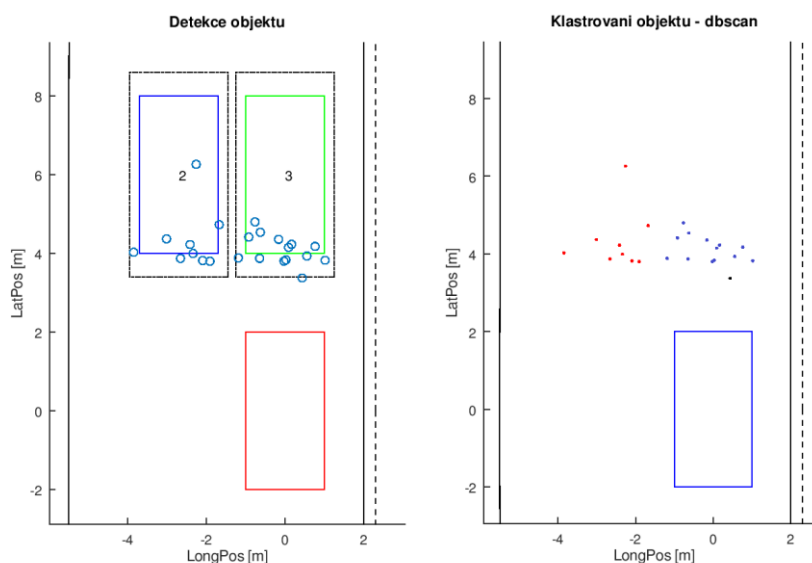
Tento problém se dá řešit aplikací metody KMEANS, která na základě definovaného počtu shluků rozpozná i objekty s menším rozestupem (obrázek 34). Nebo druhou variantou řešící tento problém, je vhodné zvolení rozměrů klastrovací brány (obrázek 35).



Obrázek 34 - Správné klastrování metody KMEAN

Při optimálním nastavení klastrovacích bran, kdy nedochází k vykrádání sousedních detekcí a klastrované shluky nepřesahují hranice nastavených bran, dostáváme pomocí metody


DBSCAN vyhovující výsledky. Pro získání takových to výsledků je nejprve nutné provést odhad optimálních parametrů metody, této problematice se věnuje kapitola číslo 3.1.3.6.



Obrázek 35 - Správně zvolené rozměry klastrovací brány

3.1.3.6 Analýza odhadu parametrů DBSCAN

Odhad optimálních parametrů byl založen na znalosti pozice a tvaru detekovaných objektů v každý časový okamžik. Pro účely testování parametrů byl vytvořen scénář (obrázek 36), kdy se kolem referenčního vozidla pohybují další tři objekty v podélném směru. Vytvořený scénář simuluje pohyb vozidel po rovné silnici, kdy objekty kolem referenčního vozidla pomalu akcelerují a referenčnímu objektu se pomalu vzdalují.




Obrázek 36 - Scénář pro analýzu parametrů

Pro experimentální pozorování chování vlivu parametrů a zároveň závislost parametru Eps na rychlosti bylo pro různé rychlosti vygenerováno několik výstupů s různými hodnotami parametrů Eps a $MinPts$. Pro parametr Eps byly pomocí vygenerovány výstupy v rozsahu od $Eps=0,6$ až $Eps=1,8$, s krokem $0,2$. Pro $MinPts$ platí pravidlo odvozené z počtu dimenzí D v daném souboru. Pravidlo můžeme zapsat jako: $MinPts \geq D + 1$. Hodnota $MinPts = 1$ nemá význam, protože každý bod by byl klastrem. Při zvolení $MinPts = 2$ bude dosahovat stejného výsledku jako hierarchické klastrování s metrikou single link. Proto by měla být hodnota $MinPts$ volena alespoň na hodnotu $MinPts = 3$. Jako pravidlo můžeme použít $MinPts = 2 * D$. [34] Pro parametr $MinPts$ byly vygenerovány výstupy v rozsahu od hodnoty $MinPts=2$ až do hodnoty $MinPts=5$.


Na obrázcích 37, 38 a 39 je ukázka vlivu parametru Eps na výsledky metody při rychlosti 14,4 km/h. $MinPts$ je pro ukázkou vlivu parametru Eps nastavena na stejnou hodnotu ($MinPts=5$).

Na obrázku 37 je $Eps=0,6$. Tato malá hodnota Eps zapříčinila kompletní ztrátu objektu, ten označila černými kroužky jako šum. Na dalším objektu správně detekuje zadní část vozu (důvodem je velké množství detekcí), ale vzdálenější část označila také jako šum. Pouze červený objekt je klasifikován korektně.



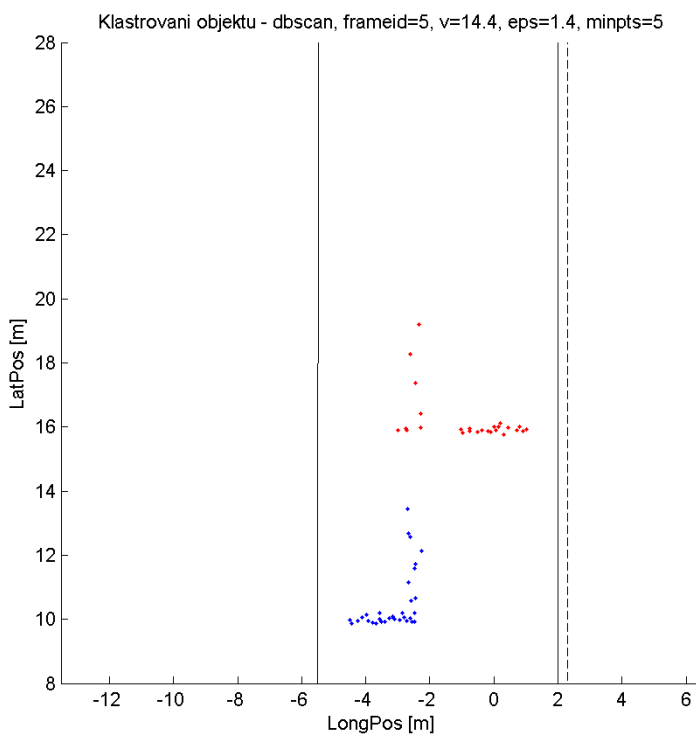
Obrázek 37 - DBSCAN $Eps=0,6$

Pro hodnotu $Eps=1$ (obrázek 38) podává metoda nejkvalitnější výsledky. Toto tvrzení koresponduje s výsledkem zaznamenaným v tabulce 1. Při této hodnotě byly korektně klasifikovány všechny objekty.



Obrázek 38 - DBSCAN Eps=1

Při hodnotě Eps=1,4 již metoda zanášela chybovost. Modrý objekt byl ještě klastrován správně, ale vzdálenější dva objekty byly nesprávně spojeny do jednoho shluku.




Obrázek 39 - DBSCAN Eps=1,4

Po vizuální kontrole dosažených výsledků byla pro každou testovanou rychlost přiřazena optimální hodnota parametrů. Z experimentálního pozorování byla zhotovena tabulka optimálních hodnot a graf závislosti *Eps* na rychlosti detekcí. Část tabulky optimálních hodnot pro nízké rychlosti (městský provoz) je zobrazena níže.

Tabulka 1 - Optimální hodnoty parametrů DBSCAN

Optimální hodnoty parametru DBSCAN		
Absolutní rychlost [km/h]	<i>Eps</i> [m]	<i>MinPts</i> [-]
0,0	0,6	5
3,6	0,6	5
7,2	0,8	5
10,8	1	5
14,4	1	5
18	1,2	5
21,6	1,4	5
25,2	1,4	5
28,8	1,6	2
32,4	1,4	5
36	1,8	4
39,6	1,8	3
43,2	1,8	2
46,8	2	3



Graf 1 - Závislost *Eps* na rychlosti

Z provedené analýzy parametrů je tedy patrné, že veličina *Eps* je závislá na absolutní rychlosti detekcí. Parametr *MinPts* nabýval většího významu při vyhodnocování výsledků na

větší vzdálenost, kdy dosažených detekcí nebylo takové množství jako při krátkých vzdálenostech. $MinPts$ je tedy závislý na vzdálenosti od radaru a v případě generátoru objektů této práce také na zvolené vzorkovací frekvenci radaru. Vzorkovací frekvence tohoto generátoru byla zvolena: $theta_step = 2,5$.

Optimální hodnoty parametrů pro nízké rychlosti (0-50 km/h):

- $Eps = 1,4$
- $MinPts = 4$

Optimální hodnoty parametrů pro nízké rychlosti (50-70 km/h):

- $Eps = 1,8$
- $MinPts = 4$

V případě, kdy budou objekty měnit svou rychlost ve větším rozsahu a s velkou akcelerací, pak je zapotřebí parametry úměrně měnit v průběhu klastrování. Tento krok není součástí této práce. Tato práce je omezena pouze na scénáře v malém rozsahu rychlostí a s nastavením optimálních parametrů.

Kompletní analýza byla provedena pro rychlosti od 0 - 70km/h a testování proběhlo na několika různých jízdních scénářích. Kompletní dosažené výsledky analýzy jsou přiloženy v příloze práce.

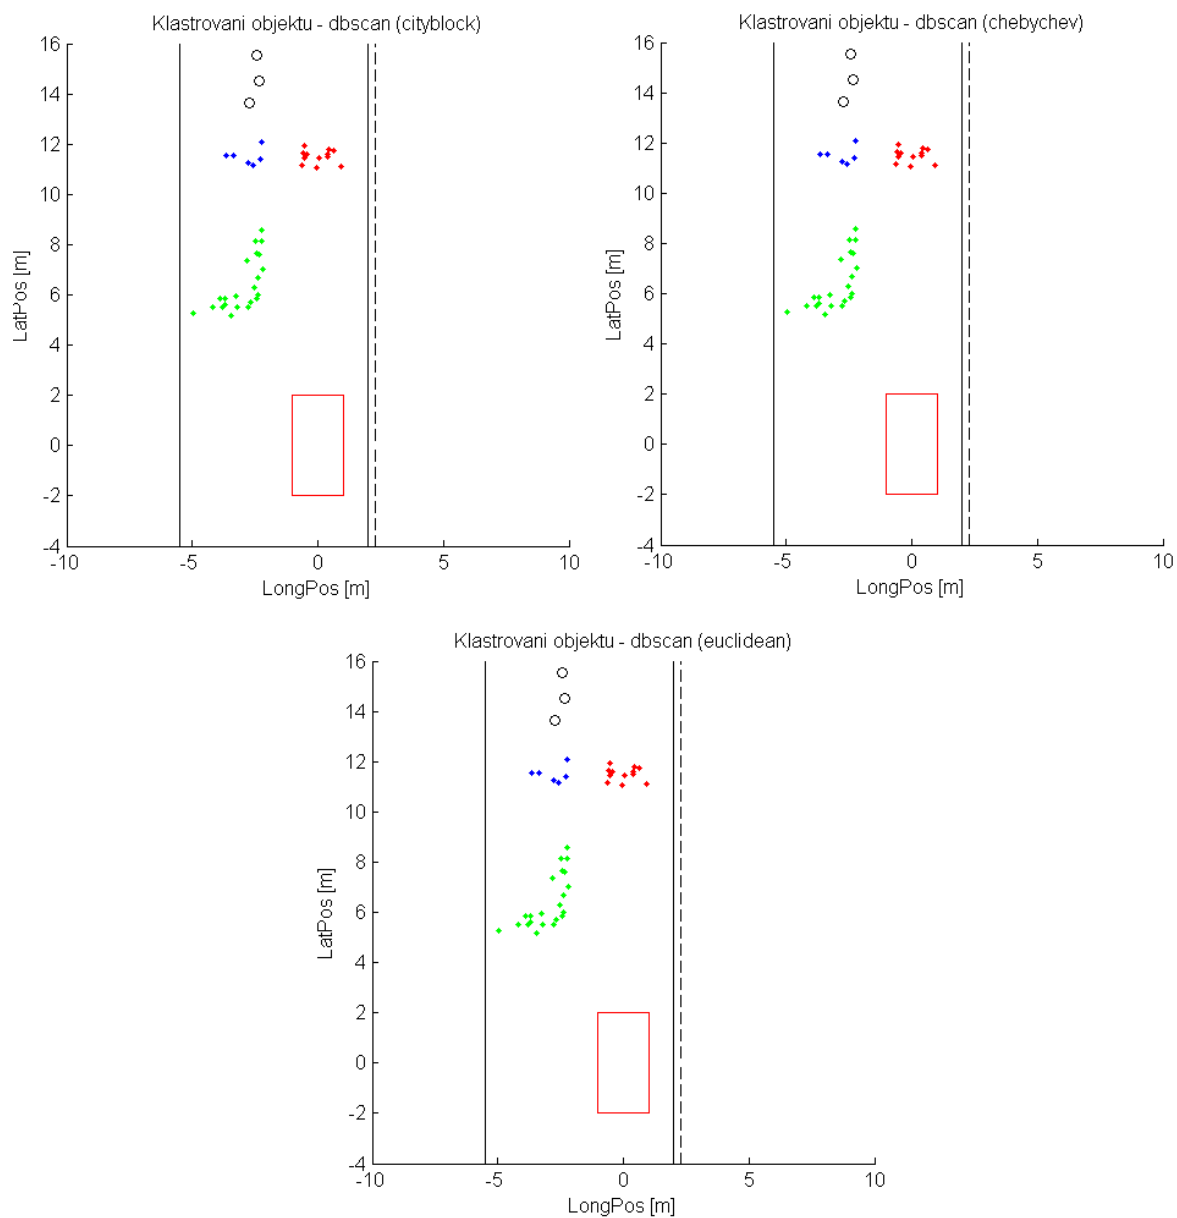
3.1.3.7 Vliv použitých metrik

Základní metrikou použitou na této diplomové práci byla zvolena Euklidovská metrika. Tato metrika se dá považovat za nejpoužívanější a figuruje ve všech vizualizacích této práce. Analýza vlivu metrik byla provedena na následujících metrikách:

- Euklidovská metrika,
- Čebyševova metrika,
- Mahalanobisova metrika,
- Manhattan metrika.

Všechny metriky byly pomocí generátoru analyzovány na stejném scénáři a stejných parametrech metody DBSCAN. Parametry DBSCAN byly $Eps = 1,3$ a $MinPts = 4$.


Výsledky vizuálního testování různých druhů metriky ukázaly, že metrika Euklidovská, Čebyševova a metrika Manhattan dosahují stejných výsledků. Tedy zvolená metrika nemá významný vliv na výsledky klastrování metody DBSCAN. Výsledky jednotlivých metrik jsou zobrazeny na obrázku 40.



Obrázek 40 - Metriky Manhattan, Čebyšev a Euklid

Jediná metrika Mahalanobisova dosahovala jiných výsledku. Vliv této metriky byl natolik silný, že došlo ke kompletnímu ovlivnění dosažených výsledku.

Při použití předchozích metrik metoda DBSCAN klasifikovala na zadaném scénáři tři různé klastry. Metrika Mahalanobisova, na stejném scénáři a se stejnými parametry, klasifikuje pouze jeden velký klastr (obrázek 41).



Obrázek 41 - Mahalanobisova metrika

Důvod takového vlivu na výsledky klastrovací metody spočívá ve způsobu výpočtu Mahalanobisovy metriky:

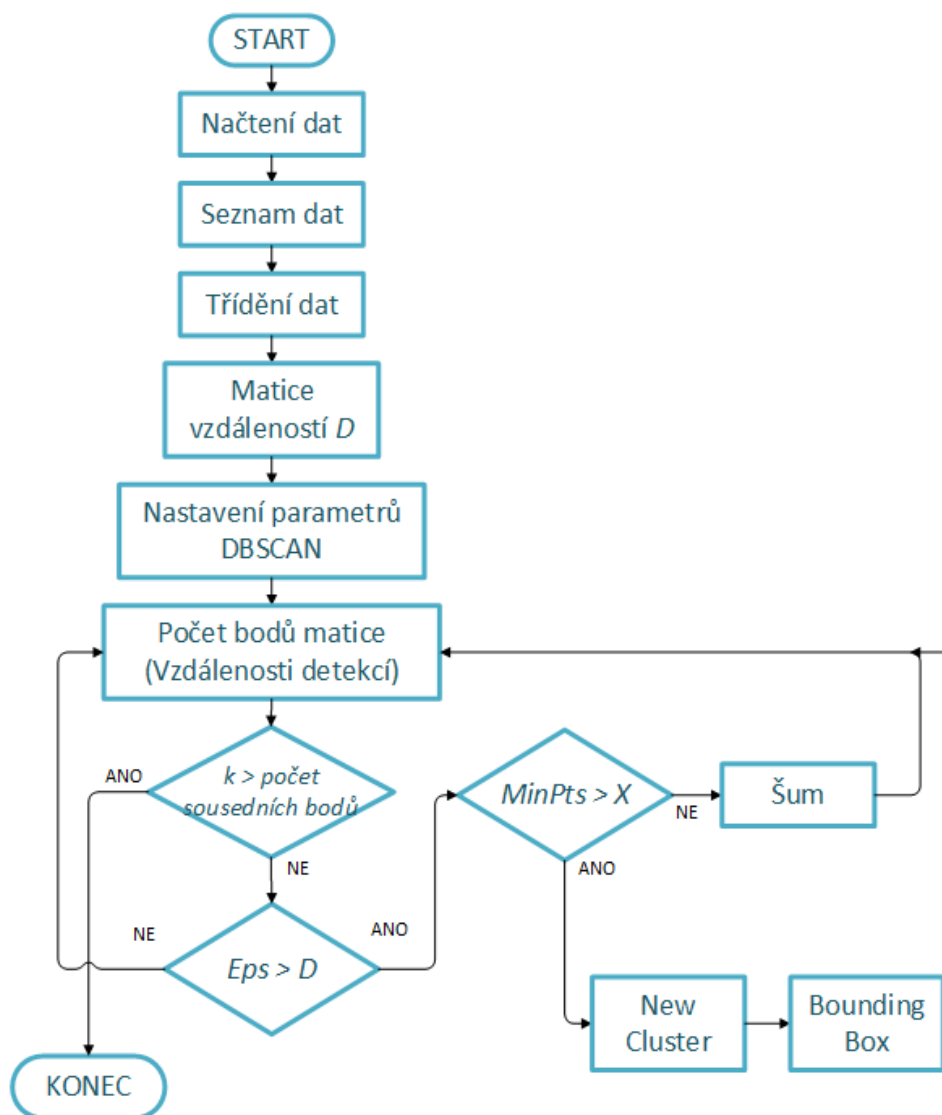
$$a_{ij} = ((x_i - x_j)^T S^{-1} (x_i - x_j))^{\frac{1}{2}} \quad (3.9)$$

3.2 Aplikace na reálných datech

Zpracovávaná data byla zaznamenána FMCW radarem v reálném silničním provozu. Data jsou uložena ve formátu *csv* (*Comma-separated value*). Data v tomto formátu byla naimportována do prostředí MATLAB a dále upravovány a zpracovávány. Vytvořený skript byl aplikován na různých scénářích, kdy automobil míjí pouze jeden objekt v laterálním směru, až po scénáře se složitější infrastrukturou a více objekty.

3.2.1 Vývojový diagram funkce

Popis funkce je zobrazen v podobě vývojového diagramu na obrázku 42. Vývojový diagram popisuje proces počátečního načtení dat až po samotnou vizualizaci výsledku. Funkce skriptu je postupně popsána v kapitolách níže.



Obrázek 42 - Vývojový diagram funkce

3.3 Vstupní data

Prvním krokem, nezbytným pro vizualizaci, byla orientace ve vstupních datech. Data jsou rozdělena do jednotlivých *CycleNumber*. Hodnota proměnné *CycleNumber* se dá označit jako smyčka naměřených hodnot od všech čtyř senzorů. Informace o tom, jaký senzor poskytl určitá data, je uložena pod proměnnou *NSensor*. Další velice významnou proměnnou je samotná pozice detekce. Ta je uložena pod proměnnou *LatPos_m* a *LongPos_m*. Hodnoty jsou vztaženy k zadní poloose automobilu. Určení vlastnosti detekce, zda je dynamická či statická, udává proměnná *Infrastructure* nebo také *NoInfrastructure*. Jedná se o logický datový typ, tedy statický a dynamický cíl rozlišuje na základě informace *True* nebo *False*. Vzdálenost mezi detekcí a senzorem určuje proměnná *CoGRange*. *CoGDoppler* obsahuje rychlosti detekcí v metrech za sekundu a proměnná *Azimuth*, jak vyplývá z názvu, definuje právě azimut detekcí. Pro hodnoty určující azimut, Dopplerovu rychlost a vzdálenost detekce


od senzoru jsou k dispozici také hodnoty jejich směrodatných odchylek. Dále pak můžeme zmínit proměnnou *NumDetections*. Hodnota této proměnné udává počet detekcí na jeden *CycleNumber* a proměnná *PowerDB* nám udává výkon detekce. V neposlední řadě je možné z dat vyčíst i čas, kdy byla detekce naměřena.

3.3.1 Import vstupních dat

Import dat probíhá pomocí funkce, která na základě adresářové struktury požadovaného souboru naimportuje data do prostředí MATLAB. Dále funkce načítá informace ze sloupců, potřebných pro další práci v programu. Funkce využívá vestavěných funkcí, jako je *fopen*, *textscan* a dále jen naformátování sloupců po importu.

3.4 Vizualizace vstupních dat


Prvním krokem vizualizace bylo vykreslení detekcí jednotlivých senzorů (obrázek 43). Pro orientaci v datech a vizuální představivost byly detekce každého senzoru vykresleny odlišnou barvou. Pro vykreslení jednotlivých detekcí postačily hodnoty *LongPos_m* a *LatPos_m* z jednoho *CycleNumber*. Referenční vůz s měřícími radary je vizualizován jako černý box s rozměry běžného automobilu. Šířka referenčního vozu byla zvolena dva metry a délka vozu na čtyři metry.



Obrázek 43 - Detekce NSensor


Pro lepší představu o situaci, která byla zaznamenána v datech, bylo vytvořeno video. Za pomoci funkce MATLABu *writeVideo* bylo vytvořeno video se snímkováním 15 snímků za sekundu a uloženo ve formátu AVI.

Za pomoci funkce MATLABu *unique* došlo k vytvoření unikátního seznamu *CycleNumber*. Na základě tohoto seznamu bylo možné provádět vizualizace kompletních dat od všech senzorů. Vizualizace všech detekcí je zobrazena na obrázku níže. Scénář na obrázku není nikterak složitý, ale i přesto není možné definovat přesnou situaci a scénář s jistotou popsat.



Obrázek 44 - Vizualizace všech detekcí

V dalším kroku jsou detekce rozlišeny na statické a dynamické. Statické objekty jsou vizualizovány černými tečkami a dále se s nimi nepracuje. Dynamický objekt je reprezentován tečkami červenými. Metoda DBCAN je aplikována pouze na dynamické detekce. Pro realizaci tohoto kroku bylo využito proměnných *Infrastructure* a *NoInfrastructure*. *Infrastructure* reprezentuje detekce statické a *NoInfrastructure* naopak detekce dynamické. Vzhledem k tomu, že proměnné jsou datovým typem, bylo možné na základě jednoduché podmínky vizualizovat (obrázek).



Obrázek 45 - Zobrazení dynamických detekcí

3.5 Aplikace DBSCAN na reálných datech


Pro aplikaci metody na datech z reálného provozu, bylo využito dosažených výsledků z experimentálního zkoumání na datech syntetických. Základem byla tabulka se závislostmi parametru Eps na rychlosti objektů. Podle výsledů závislostí byly vybrány scénáře se stejnými rychlostmi objektů. Rychlost objektů byla z reálných dat zjištěna pomocí proměnné $CoGDoppler$. Ta udává relativní rychlost detekce k referenčnímu vozidlu v metrech za sekundu.

Data vybraná pro testování obsahují objekty pohybující rychlostmi od 30 km/h až po 45 km/h a pravděpodobně se jedná a průjezd vozidel křižovatkou. S pomocí tabulky závislostí (tabulka 2) Eps na rychlosti byl zvolen optimální parametr, pro rychlostní rozsah 30 – 45 km/h na hodnotu $Eps=1,8$.

Tabulka 2 - Výtazek z tabulky číslo 1


Absolutní rychlost [km/h]	Eps [m]	$MinPts[-]$
36	1,8	4
39,6	1,8	3
43,2	1,8	2

Ukázka výsledku DBSCAN metody při nastaveném $Eps=1,8$ je uvedena na obrázku 46. Metoda zde klasifikuje pět objektů. Po sledování výsledků na více snímcích se dá s určitou pravděpodobností říci, že metoda klasifikuje objekty v tomto scénáři správně.



Obrázek 46 - Reálná data $Eps=1,8$

Výsledky metody při nastavení většího Eps je uvedena na obrázku 47. Zde je Eps nastaven na hodnotu 3. Pro tuto hodnotu již byly pozorovány chyby. Metoda začala spojovat více objektů a vytvářet klastry nereálných tvarů a velikostí. Naopak při zvolení $Eps < 1,8$ docházelo k rozdělování objektů a vytváření velice malých objektů.




Obrázek 47 – Reálná data $Eps=3$

Výsledkem aplikace na reálných scénářích bylo potvrzení dosažených výsledků na datech syntetických. Pro přesnější ověření správného klastrování metody by byla nutná podrobnější analýza vytvořených klastrů. Analýza v podobě rozpoznávání detekovaných objektů a určování o jaký objekt se jedná (osobní automobil, dodávka, nákladní auto ...).

3.6 Vykreslení bounding boxu

Bounding box je prostorová obálka určité plochy či objektu. V této práci se jedná o prostorovou obálku reprezentující automobil. Bounding box představuje nejmenší možný obdélník, do kterého je možné vtěsnat automobil.


Bounding box byl nejprve vykreslen za pomoci výpočtu minimální a maximální hodnoty v ose X a Y pro jednotlivé klastry. Tento způsob vykreslení neposkytne správnou velikost klastru a ani jeho orientaci (viz obrázek níže).



Obrázek 48 - BBox bez orientace a velikosti

Z obrázku 48 je patrné, že velikost boxu nemusí zcela odpovídat rozměrům automobilu. Jelikož je velikost vypočítávána na základě rozměru klastru pro daný časový snímek, je patrné, že velikost boxu se bude pro každý snímek lišit.

Pro dosažení přesnějšího boxu byla vytvořena funkce *LWestimation*, která vypočítá střed a následně délku a šířku klastru. Orientaci, neboli aktuální natočení vůči měřenému objektu počítá funkce *Orientation*. Způsob výpočtu tohoto natočení je popsán níže.




Obrázek 49 - Princip orientace objektu

Za účelem nalezení orientace objektu se odhaduje vektor rychlosti (v_x, v_y). Pokud se objekt pohybuje lineárně, pak je úhlová rychlost a orientace stejná.

$$\text{Orientace} = \alpha = \tan^{-1}\left(\frac{v_y}{v_x}\right) \quad (3.1)$$

$$\text{Rychlost} = v = \sqrt{v_x^2 + v_y^2} \quad (3.2)$$

V principu nám stačí pouze dvě detekce k odhadu v_x, v_y , k tzv. vektoru rychlosti (v) a úhlu orientace α . Většinou jsou však zachycovány a seskupovány detekce většího počtu, což umožňuje odhad okamžité orientace.



Obrázek 50 - BBox s orientací a odhadovanou velikostí

Závěr

Cílem této práce bylo vytvoření skriptu, který bude aplikovat vlastnosti shlukové analýzy pro seskupování objektů z detekcí FMCW radaru. Téma shlukové analýzy je velice rozsáhlé. V této práci byl uveden pouze základ a podrobněji byly popsány pouze metody DBSCAN a KMEAN, které byly využívány v praktické části práce. U metody byly popsány základní vlastnosti a popsán princip jejich vlastního algoritmu.

V praktické části byl nejprve vytvořen generátor cílů. Generátor sloužil jako zdroj syntetických dat, na kterých bylo možné provádět analýzu parametrů a ověřit správnou funkci algoritmů. Po provedení implementace metod DBSCAN a KMEANS na syntetická data bylo rozhodnuto, že metoda DBSCAN je vhodnější variantou a KMEANS tedy nebyl dále používán. Pomocí syntetických dat byla vytvořena analýza závislostí parametrů metody na rychlostech objektů. Analýza spočívala ve vytvoření několika jízdních scénářích a generování různých výstupů s postupně se měnícími parametry metody DBSCAN pro jednotlivé rychlosti objektů. Analyzované parametry byly v rozsahu *Eps* od 0,6 do 3, *MinPts* od 2 do 5 a testované rychlosti 0-100km/h. Výstupem analýzy vznikla tabulka závislostí parametrů na jednotlivých rychlostech. Pro zkvalitnění optimálních parametrů by bylo zapotřebí aplikovat více jízdních scénářů. Případné zlepšení práce by mohlo spočívat v automatickém vygenerování různých scénářů a automatickém vyhodnocování. V této práci je řešeno pouze ručně a kontrola probíhá vizuálně.

Po určení optimálních parametrů byla provedena aplikace na reálných datech. Po importu dat do prostředí MATLAB, byly detekce vykresleny na základě jejich LatPos a LonPos. Metoda DBSCAN byla aplikována pouze na dynamické detekce. Aplikace metody na reálných datech vycházela z tabulky závislostí parametrů *Eps* a *MinPts*. Pro scénáře s určitými rychlostmi objektů byly aplikovány odpovídající parametry metody. Dosažené výsledky byly vizuálně testovány a vyhodnoceny jako správné. Součástí praktické části byla i analýza metrik výpočtu vzdáleností jednotlivých detekcí. Všechny metriky poskytly prakticky totožné výsledky, až na metriku Mahalanobis. Tato metrika, za stejných podmínek a parametrů, silně ovlivňovala výsledky.

Po správné klasifikaci objektů byly klastry doplněny o tzv. bounding box. Ten byl vykreslován kolem klastru a představoval jeho ohraničení. Barva boxu byla nastavena totožná s klastrem. Pro zlepšení vizualizace byla vytvořena funkce pro odhad velikosti klastru a metoda výpočtu orientace klastru. Funkce *LWestimation* vrací délku, šířku a výpočet středu klastru. Funkce *Orientation* vrací hodnotu úhlu, který odpovídá natočení objektu vůči měřícímu. Aplikace těchto funkcí je vizualizována v příloze práce.

Seznam zkratek

ACC – Adaptive Cruise Control
ADC – Analog digital convertor
AEB – Autonomous Emergency Breaking
AVI – Audio Video Interleave
CLARA – Clustering Large Applications
CLARANS – Clustering Large Applications Randomized Search
CSV – Comma-separated value
CW – Continuous Wave
DAC – Digital analog convertor
DBSCAN – Density based Clustering
EPS – Epsilon
ETSI – European Telecommunications Standards Institute
FCC – Federal Communications Commission
FFT – Fast Fourier Transform
FOV – Field Of View
FMCW – Frequency Modulated Continuous Wave
ISM – Industrial, Scientific and Medical radio bands
LNA – Low noise amplifier
LPF – Low pass filter
MFK – Multifocal camera
MinPts – Minimum Points
NB – Narrow band
SRR – Short-range radar
UWB – Ultra wide band
VCO – Voltage controlled oscillator
VF – Vysokofrekvenční

Seznam obrázků

Obrázek 1 - Radarová konfigurace	9
Obrázek 2 - Lineární frekvenční modulace [22].....	11
Obrázek 3 - Trojúhelníkový průběh modulace	11
Obrázek 4 - Blokové schéma FMCW radaru.....	12
Obrázek 5 - Vysílaný a přijímaný signál FMCW	14
Obrázek 6 - Vliv Dopplerova posunu	15
Obrázek 7 – Dostupná radarová pásma v automobilovém průmyslu [33]	16
Obrázek 8 - Ukázka vybraných metrik[26]	24
Obrázek 9 - Metoda nejbližšího souseda[27]	24
Obrázek 10 - Metoda nejvzdálenějšího souseda[27]	24
Obrázek 11 - Metoda průměrné vazby[27].....	25
Obrázek 12 - Centroidní metoda.....	25
Obrázek 13 - Centrální hustota	27
Obrázek 14 - Jádrové, okrajové a šumové body	28
Obrázek 15 - Definice DBSCAN.....	28
Obrázek 16 - Aplikace DBSCAN [15]	30
Obrázek 17 - Ukázka konfiguračního souboru	31
Obrázek 18 - Popis výpočtu pozice objektu	32
Obrázek 19 - Vykreslení detekcí objektů	34
Obrázek 20 - Obousměrně vykreslované detekce.....	34
Obrázek 21 – Ošetření vykreslení detekcí na hraně vozidla.....	35
Obrázek 22 – Ošetření detekcí v zákrytu	36
Obrázek 23 – Gaussovské rozdělení detekcí	36
Obrázek 24 - Ukázka detekcí pro ukázkou K-MEANS.....	38
Obrázek 25 - Správná klasifikace metody K-MEANS	38
Obrázek 26 - Nesprávná klasifikace metody K-MEANS	39
Obrázek 27 - Detekce objektů s větším rozptylem	40
Obrázek 28 - Aplikace KMEAN.....	40
Obrázek 29 - Aplikace DBSCAN	41
Obrázek 30 - Klastrovací brány	42
Obrázek 31 - Vykrádání detekce sousedního objektu	42
Obrázek 32 - Správné nastavení klastrovacích bran	43
Obrázek 33 - Nesprávné nastavení klastrovací brány.....	44
Obrázek 34 - Správné klastrování metody KMEAN	44
Obrázek 35 - Správně zvolené rozměry klastrovací brány	45
Obrázek 36 - Scénář pro analýzu parametrů.....	45
Obrázek 37 - DBSCAN Eps=0,6	46
Obrázek 38 - DBSCAN Eps=1	47

Obrázek 39 - DBSCAN Eps=1,4	47
Obrázek 40 - Metriky Manhattan, Čebyšev a Euklid	50
Obrázek 41 - Mahalanobisova metrika	51
Obrázek 42 - Vývojový diagram funkce.....	52
Obrázek 43 - Detekce NSensor.....	53
Obrázek 44 - Vizualizace všech detekcí	54
Obrázek 45 - Zobrazení dynamických detekcí	55
Obrázek 46 - Reálná data Eps=1,8.....	56
Obrázek 47 – Reálná data Eps=3	56
Obrázek 48 - BBox bez orientace a velikosti.....	57
Obrázek 50 - Princip orientace objektu	57
Obrázek 49 - BBox s orientací a odhadovanou velikostí.....	58

Seznam tabulek

Tabulka 1 - Optimální hodnoty parametrů DBSCAN	48
Tabulka 2 - Výtažek z tabulky číslo 1	55

Seznam grafů

Graf 1 - Závislost Eps na rychlosti	48
---	----

Literatura

1. IGOR V. KOMAROV, SERGEY M. SMOLSKIY, Igor V. Komarov, Sergey M. Smol ski a ENGLISH TRANSLATION EDITED BY DAVID K. BARTON. *Fundamentals of Short-Range FM Radar*. Norwood: Artech House, 2003. ISBN 9781580537339.
2. Řezánková Hana, Dušan Húšek, Václav Snášel: *Shluková analýza dat*, Professional Publishing, Praha 2007
3. W. Wiesbeck, *Radar System Engineering*. Karlsruhe Institute of Technology, 2009. Lecture Script.
4. M. Ester, H.-P. Kriegel, J. Sander, and X. Xu. A Density- Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise. In KDD, pages 226{231, 1996.
5. Jie Zhao, Liu Yang. An Improved Density-based Clustering Algorithm[J]. *Microelectronics & Computer*, 2009 26(11):189-192.
6. IS MUNI [online]. 2017 [cit. 2017-04-11]. Dostupné z: <https://is.muni.cz/>
7. LUKASOVÁ A., Šarmanová J.: *Metody shlukové analýzy*. SNTL, Praha 1985
8. KOMAROV, I. – SMOLSKIY, S. *Fundamentals of Short-range FM Radar*. Artech House radar library. Artech House, 2003. Source: <<https://books.google.co.in/books?id=Am0FKx37IysC>>. ISBN 9781580537339.
9. SKOLNIK, M. I. *Radar Handbook*. Electronic engineering series. McGraw-Hill, 1990. Source: <https://books.google.cz/books?id=m_rvUQswj3sC>. ISBN 9780070579132.
10. MAHAFZA, B. R. *Radar Systems Analysis and Design Using MATLAB*. Boca Raton, FL, USA: CRC Press, Inc., 1st edition, 2000. ISBN 1584881828.
11. RICHARDS, M. A. (Ed.). *Principles of Modern Radar: Basic principles*. Radar, Sonar & Navigation. Institution of Engineering and Technology, 2010. Source: <<http://digital-library.theiet.org/content/books/ra/sbra021e>>.
12. SONG, M. – LIM, J. – SHIN, D. J. The velocity and range detection using the 2D-FFT scheme for automotive radars. In 2014 4th IEEE International Conference on Network Infrastructure and Digital Content, s. 507–510, Sept 2014. doi 10.1109/IC-NIDC.2014.7000356

13. WOJTKIEWICZ, A. et al. Two-dimensional Signal Processing in FMCW Radars. In XX th National Conference on Circuit Theory and Electronic Networks, 2, 1997.
14. MAHAFZA, B. Introduction to Radar Analysis. Advances in Applied Mathematics Series. Taylor & Francis, 1998. Source: <<https://books.google.cz/books?id=HnbERpIirX0C>>. ISBN 9780849318795.
15. ResearchGate, Clustering of High Resolution Automotive Radar Detection [online]. [cit.2018-08-20] Dostupné z: https://www.researchgate.net/publication/281370738_Clustering_of_High_Resolution_Automotive_Radar_Detections_and_Subsequent_Feature_Extraction_for_Classification_of_Road_Users
16. MAHAFZA, B. R. Radar Systems Analysis and Design Using MATLAB. Boca Raton, FL, USA : CRC Press, Inc., 1st edition, 2000. ISBN 1584881828.
17. Rohde & Schwarz, FMCW Radar in Automotive Applications [online]. [cit.2018-08-19].Dostupné z: <https://en.wikipedia.org/wiki/DBSCAN>
18. SKOLNIK, Merrill. *Radar Handbook, Third Edition* USA: The McGraw-Hill Companies, 2008. ISBN 978-0-07-148547-0.
19. V. Issakov, Microwave Circuits for 24 GHz Automotive Radar in Silicon-based Technologies. Springer, 2010.
20. V. Winkler, "Range Doppler Detection for Automotive FMCW Radars," Proceedings of the 4th European Radar Conference, 2007.
21. WIKIPEDIA, Phase-comparison monopulse [online]. [cit.2018-08-15].Dostupné z: https://en.wikipedia.org/wiki/Phase-comparison_monopulse
22. SKOLNIK, Merrill. *Introduction to Radar Systems* USA: The McGraw-Hill Companies, 1981. ISBN 0-07-057909-1.
23. BEZOUŠEK, P. a ŠEDIVÝ, P., Radarová technika. Vydavatelství ČVUT. ISBN 9788001030363.
24. Řezánková Hana: *Shlukování a velké soubory dat*, VŠE Praha, poslední revize: 3.3.2018.Dostupné z: http://nb.vse.cz/~rezanka/Shlukova_analyza2004.pdf.
25. Ježek K.: <Bez názvu>, poslední revize: 21.3.2018. Dostupné z: http://www.kiv.zcu.cz/~jezek_ka/vyuka/DB2%202005/Datamining/

26. Chris Mueller: Data Clustering, poslední revize: 20.3.2018. Dostupné z: <http://www.osl.iu.edu/~chemuell/projects/presentations/data-clusteringoverview.pdf>
27. Tan, Steinbach, Kumar, S. Parthasarathy: *Introduction to Data Mining*, poslední revize: 11.3.2018. Dostupné z: <http://www.cse.ohiostate.edu/~srini/674/chap8.ppt>
28. B. Dehlink, *Integrated Millimeter Wave Front-End Design in SiGe Bipolar Technology*, Dissertation, Institut für Nachrichten- und Hochfrequenztechnik der TU Wien, 2007.
29. Tutusaus, M. M.: Evaluation of automotive commercial radar for human detection. Master of science thesis, Helsinki University of Technology, 2008.
30. Eugin Hyun, J.-H. L.: A method for multi-target range and velocity detection in automotive FMCW radar. Radar Conference, IEEE, 2009, ISBN 978-1-4673-0656-0.
31. VON URS LÜBBERT. *Target position estimation with a continuous wave radar network*. Göttingen: Cuvillier, 2005. ISBN 9783865375469.
32. Rohde & Schwarz webinar. *YouTube: Analysis of FMCW radar signals in automotive applications* [online]. 2014 [cit. 2018-22-07]. Dostupné z: <https://www.youtube.com/watch?v=8qaCSQ83ZyU>
33. TEXAS INSTRUMENTS, Why are Automotive radar systems moving from 24GHz to 77GHz [online]. [cit.2018-08-14]. Dostupné z: https://e2e.ti.com/blogs_/b/behind_the_wheel/archive/2017/10/25/why-are-automotive-radar-systems-moving-from-24ghz-to-77ghz
34. WIKIPEDIA, DBSCAN [online]. [cit.2018-08-15]. Dostupné z: <https://en.wikipedia.org/wiki/DBSCAN>
35. STHDA, Statistical tools for high-throughput data analysis [online]. [cit.2018-08-20]. Dostupné z: <http://www.sthda.com/english/wiki/print.php?id=246>