# ŽILINSKÁ UNIVERZITA V ŽILINE FAKULTA RIADENIA A INFORMATIKY

# Analýza akustických signálov s aplikačným využitím v bezdrôtovej senzorovej sieti inteligentnej dopravy

# DIZERTAČNÁ PRÁCA 28360020173009

Študijný program:	Aplikovaná informatika
Študijný odbor:	9.2.9 aplikovaná informatika
Školiace pracovisko:	Katedra technickej kybernetiky
Školiteľ:	doc. Ing. Ján Kapitulík, PhD.

Žilina 2017

Ing. Róbert ŽALMAN

### **Pod'akovanie**

Touto cestou by som chcel poď akovať vedúcemu práce doc. Ing. Jánovi Kapitulíkovi, PhD. za padegaogické usmernenie a odborné vedenie v priebehu konzultácii.

Ďalej by som chcel poď akovať všetkým členom Katedry technickej kybernetiky, Fakulty riadenia a informatiky na Žilinskej univerzite v Žiline, za pomoc a konzultácie pri problémoch súvisiacich s realizáciou mojej dizertačnej práce.

Osobitné poďakovanie patrí celej mojej rodine a priateľke Júlii Kostrovej za podporu a trpezlivosť počas celých ôsmich rokov môjho vysokoškolského štúdia.

## Abstrakt

ŽALMAN, Róbert: *Analýza akustických signálov s aplikačným využitím v bezdrôtovej senzorovej sieti inteligentnej dopravy.* [Dizertačná práca] Žilinská Univerzita v Žiline. Fakulta riadenia a informatiky. Katedra technickej kybernetiky. - Školiteľ: doc. Ing. Ján Kapitulík, PhD. - Žilina: FRI ŽU, 2017, 97 s.

Kľúčové slová: WSN, akustika, spektrálna analýza, neurónové siete.

V práci sa zameriavame na analýzu akustického signálu a jeho charakteristické vlastnosti, ktoré využívame na ďalšie spracovanie tohto signálu. Jeho následné spracovanie je zabezpečené pomocou frekvenčnej analýzy, ktorou sme schopný nájsť nosné frekvencie vybraného signálu. V práci využívame kompresné metódy na niekoľ konásobnú redukciu dát potrebných na klasifikáciu akustických signálov. Taktiež využívame neurónové siete, ktoré slúžia hlavne na klasifikáciu týchto signálov. Okrem toho bola v práci navrhnutá metóda na klasifikáciu akustických signálov, ktoré sa bežne nachádzajú v doprave. Výsledkom práce je návrh metódy, ktorá je schopná klasifikovať signály charakteristické pre rôzne prostredia, prípadne rôzne akustické zdroje. V práci sa nachádza opis viacerých experimentov, ktoré boli uskutočnené za spomínanými účelmi. Pre každý experiment je vytvorené vyhodnotenie a úspešnosť klasifikácie na vybraných akustických signáloch.

## Abstract

ŽALMAN, Róbert: Analysis of acoustic signals with application usage in wireless sensor network for intelligent transport. [PhD thesis] - University of Žilina in Žilina. Faculty of Management Science and Informatics. Department of Technical Cybernetics. - Supervisor: doc. Ing. Ján Kapitulík, PhD. - Žilina: FRI ZU, 2017, 97 p.

Key words: WSN, acoustics, spectral analysis, neural network.

In the PhD thesis, we focus on the analysis of the acoustic signal and its characteristic properties, which we use for further processing of the acoustic signal. Its further processing is ensured that we are able to find the carrier frequencies of the selected signal with frequency analysis. We use compression methods to reduce the data needed to classify acoustic signals. We also use neural networks that serve mainly to classify these signals. In addition, a method has been proposed to classify acoustic signals that are commonly found in transport. The result of the PhD thesis is the design of a method that is able to classify signals characteristic for different environments or different acoustic sources. In the PhD thesis, there is a description of several experiments that have been carried out for the mentioned purposes. For each experiment is created evaluation and classification success rate on selected acoustic signals.

# Obsah

Zo	Zoznam obrázkov		11
Zo	oznam	ı tabuliek	14
Zo	oznam	ı použitých symbolov	15
Ú٧	vod		16
Те	oretic	ká čast práce	18
1	Ciel	e práce	18
	1.1	Analýza vlastností akustického signálu	18
	1.2	Návrh metód a algoritmov efektívneho spracovania dát senzorovým uzlom	18
	1.3	Návrh nových metód a algoritmov identifikácie dopravných tokov a klasi-	
		fikácie zdrojov akustických signálov	18
	1.4	Experimentálne overenie teoretických záverov	18
2	Apl	ikácie vo WSN sieť ach	19
	2.1	Požiadavky na senzorový uzol	20
	2.2	Monitorovanie dopravných systémov	21
3	Spel	strálna analýza akustických signálov	23
	3.1	Základne vlastnosti akustického signálu	23
	3.2	Fourierová transformácia	24
		3.2.1 Druhy Fourierových transformácií	24
	3.3	Frekvenčné filtre	28
		3.3.1 Rozdelenie frekvenčných filtrov	28
		3.3.2 Banka frekvenčných filtrov	29
		3.3.3 Návrh frekvenčného filtra	29
	3.4	Ďalšie matematické metódy pre analýzu vlastnosti akustického signálu	31
		3.4.1 Diskrétna kosínusová transformácia	31
		3.4.2 Waveletová transformácia	33

4	Met	óda hlavných komponentov	35
	4.1	Mnohorozmerné dáta	35
		4.1.1 Typy štatistických analýz	36
	4.2	Ciele metódy PCA	37
	4.3	Podstata PCA	38
	4.4	Hlavné komponenty	40
		4.4.1 Počet hlavných komponentov	44
5	Neu	rónové siete	47
	5.1	História neurónových sieti	47
	5.2	Základné pojmy	47
		5.2.1 Neurón	48
		5.2.2 Prenosová funkcia neurónu	49
	5.3	Štruktúra a funkcionalita neurónových sietí	52
	5.4	Učenie siete	53
		5.4.1 Algoritmus Back-Propagation	54
	5.5	Rozdelenie sietí	57
		5.5.1 Podľa počtu vrstiev	57
		5.5.2 Podľa štýlu učenia	58
		5.5.3 Podľa algoritmu učenia	58
Ex	perin	nentálna čast práce	59
6	Návi	rh metódy na klasifikáciu	59
7	Rôzi	ne metódy klasifikácie akustického signálu	60
	7.1	Klasifikácia s využitím rýchlej Fourierovej transformácie	60
	7.2	Klasifikácia s využitím frekvenčných filtrov	62
	7.3	Klasifikácia s využitím neurónovej siete	65
	7.4	Klasifikácia s využitím časového okna	67
	7.5	Klasifikácia s využitím hlavných komponentov	69
		7.5.1 Vstupná databáza	69
		7.5.2 Frekvenčné filtre	72

7.5.3	Normalizácia	73
7.5.4	Časové okno	73
7.5.5	Metóda hlavných komponentov – PCA	73
7.5.6	Neurónová sieť	75
7.5.7	Úspešnosť klasifikácia	75
8 Prínos práce 8		83
Záver		84
Zoznam použitej literatúry		85
Príloha		91

# Zoznam obrázkov

1	Grafy váhových funkcií.	26
2	Spektrogramy pri rôznych dĺžkach STFT.	27
3	Spektrogramy pri rôznych dĺžkach STFT.	27
4	Charakteristika rezonančného filtra s rezonančnou frekvenciou 5 kHz	30
5	Energia signálu je po vykonaní diskrétnej kosínusovej transformácie sústre-	
	dená v niekoľ kých počiatočných koeficientoch zodpovedajúcich najnižším	
	frekvenciám.	32
6	Daubechiho wavelet triedy $D - 4N$ , kde <i>i</i> je počet vzoriek a <i>w</i> amplitúda.	34
7	Schéma maticových výpočtov v PCA.	39
8	Elipsa konštantnej hustoty.	44
9	Schematické znázornenie biologického neurónu	48
10	Schematické znázornenie umelého neurónu.	49
11	Vybrané prenosové funkcie.	51
12	Vplyv zavedenia prahu na výstup prenosovej funkcie	52
13	Všeobecná štruktúra viacvrstvové neurónovéj siete.	53
14	Bloková schéma navrhnutej metódy na klasifikáciu.	59
15	Bloková schéma experimentu s použitím FFT	60
16	Dĺžka nahratého signálu sirény 3,3 minúty a jeho priebeh, energia a FFT	
	akustického signálu	61
17	Spektrálna výkonová hustota sirény a otestovanie FFT pre akustický signál	
	sirény.	62
18	Bloková schéma experimentu s použitím frekvenčných filtrov	63
19	Zobrazené sú rôzne frekvenčné filtre, ich priebeh signálu a spektrogram,	
	priebeh znázorňuje časový úsek sirény.	63
20	Frekvenčný filter nastavený na frekvenciu 200 Hz a jeho výstup zobrazený	
	pomocou FFT.	64
21	Frekvenčný filter nastavený na frekvenciu 800 Hz a jeho výstup zobrazený	
	pomocou FFT	64
22	Frekvenčný filter nastavený na frekvenciu 3800 Hz a jeho výstup zobrazený	
	pomocou FFT	64

23	Frekvenčný filter nastavený na frekvenciu 8000 Hz a jeho výstup zobrazený	
	pomocou FFT	64
24	Bloková schéma experimentu s FFT koeficientami a neurónovej siete	65
25	Bloková schéma experimentu s frekvenčnými filtrami neurónovej siete	66
26	Bloková schéma experimentu s použitím banky filtrov, časovým oknom a neuró	novej
	siete	67
27	Časové okno, záznam bieleho šumu, 4 sekundy.	68
28	Bloková schéma výsledného experimentu.	70
29	Vstupný stream dát dĺžky 60 sekúnd.	70
30	Spektrogram vstupného streamu dát dĺžky 60 sekúnd	71
31	Spektrogram auta, motorovej píly a sirény	72
32	Časové okno, dáta z píly 4 sekundy.	74
33	Časové okno, dáta sirény 4 sekundy.	74
34	Úspešnosť pre meniace sa parametre experimentu a fixné parametre: počet	
	filtrov 200, počet PCA koeficientov 100 a počet neurónov v skrytej vrstve 100.	76
35	Jednotlivá úspešnosť vstupných dát s 1 sekundovým oknom pre meniace	
	sa parametre experimentu a fixné parametre: počet filtrov 200, počet PCA	
	koeficientov 100 a počet neurónov v skrytej vrstve 100	77
36	Jednotlivá úspešnosť vstupných dát s 2 sekundovým oknom pre meniace	
	sa parametre experimentu a fixné parametre: počet filtrov 200, počet PCA	
	koeficientov 100 a počet neurónov v skrytej vrstve 100	77
37	Jednotlivá úspešnosť vstupných dát s 4 sekundovým oknom pre meniace	
	sa parametre experimentu a fixné parametre: počet filtrov 200, počet PCA	
	koeficientov 100 a počet neurónov v skrytej vrstve 100	78
38	Úspešnosť pre meniace sa parametre experimentu a fixné parametre: počet	
	filtrov 200, dlžka časového okna 2 sekundy a počet vzoriek v časovom okne	
	20	78
39	Jednotlivá úspešnosť vstupných dát pre 30 neurónov v skrytej vrstve pre	
	meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka	
	časového okna 2 sekundy a počet vzoriek v časovom okne 20	79

40	Jednotlivá úspešnosť vstupných dát pre 90 neurónov v skrytej vrstve pre	
	meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka	
	časového okna 2 sekundy a počet vzoriek v časovom okne 20	79
41	Jednotlivá úspešnosť vstupných dát pre 120 neurónov v skrytej vrstve pre	
	meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka	
	časového okna 2 sekundy a počet vzoriek v časovom okne 20	80
42	Úspešnosť pre meniace sa parametre experimentu a fixné parametre: počet	
	filtrov 200, dĺžka časového okna 4 sekundy a počet vzoriek v časovom okne	
	20	80
43	Jednotlivá úspešnosť vstupných dát pre 30 neurónov v skrytej vrstve pre	
	meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka	
	časového okna 4 sekundy a počet vzoriek v časovom okne 20	81
44	Jednotlivá úspešnosť vstupných dát pre 90 neurónov v skrytej vrstve pre	
	meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka	
	časového okna 4 sekundy a počet vzoriek v časovom okne 20	81
45	Jednotlivá úspešnosť vstupných dát pre 120 neurónov v skrytej vrstve pre	
	meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka	
	časového okna 4 sekundy a počet vzoriek v časovom okne 20	82

# Zoznam tabuliek

1	Úlohy riešené analýzou dát	37
2	Parametre experimentu s FFT koeficientami a neurónovou sieťou	66
3	Parametre experimentu s frekvenčnými filtrami a neurónovou sieťou	67
4	Parametre experimentu s frekvenčnými filtrami, časovým oknom a neurónovou	
	siet'ou	69
5	Parametre vstupných dát	70
6	Typy vstupných dát	71
7	Úspešnosť pri rôznom počte rezonančných filtrov	72
8	Výsledky experimentu klasifikácie	76
9	Tabul'ka zobrazujúca výsledky pokusu pre nastavenie 4 sekundového okna	
	s počtom vzoriek v časovom okne 20 a počtom filtrov 200	94
10	Tabuľka zobrazujúca výsledky pokusu pre nastavenie 2 sekundového okna	
	s počtom vzoriek v časovom okne 20 a počtom filtrov 200	95
11	Úspešnosť experimentu pri meniacich sa parametroch zobrazených v tabuľke,	
	počet neurónov a počet PCA koeficientov je nastavených na 100	96
12	Pokračovanie tabuľ ky 11 úspešnosť experimentu pri meniacich sa parametroch	
	zobrazených v tabuľke, počet neurónov a počet PCA koeficientov je nas-	
	tavených na 100	97

# Zoznam použitých symbolov

Var(.)	variancia, disperzia
Cov(.)	kovariancia
р	akustický tlak
Р	akustický výkon
λ	vlnová dĺžka
Vz	rýchlosť šírenia zvukových vĺn
S	sekunda, jednotka času
ms	milisekunda (* $10^{-3}$ )
Hz,Hertz	jednotka frekvencie
kHz	kilohertz (*10 <sup>3</sup> )
$F_{vz}$	vzorkovacia frekvencia
DFT	diskrétna Fourierová transformácia
DWT	diskrétna Waveletová transformácia
FFT	rýchla Fourierová transformácia
STFT	krátkodobá Fourierová transformácia
DCT	diskrétna kosínusová transformácia
NN	neurónová sieť
WSN	bezdrôtová senzorová sieť
IIR	filtre s nekonečnou impulznou odozvou
FIR	filtre s konečnou impulznou odozvou
PCA	metóda hlavných komponentov
JPEG	druh stratovej kompresie pre obraz
MPEG	druh stratovej kompresie pre obraz
AAC	druh stratovej kompresie pre audio
MP3	druh stratovej kompresie pre audio

# Úvod

Bezdrôtovým senzorovým sieť am (WSN) odborníci pripisujú veľkú budúcnosť. Ide o malé, lacné a nízko výkonové zariadenia, ktoré môžu spolu bezdrôtovo komunikovať za účelom zberu dát, resp. riadenia. Zatiaľ je to však technológia s veľkým potenciálom. Jej reálne nasadenie v praxi nie je bežné. Až v nedávnej minulosti vznikli štandardy, ktoré definujú tento druh sietí. Veľká väčšina dnešných senzorových sietí je postavená na štandarde IEEE 802.15.4, ktorý definuje rádiový prenos a prístup na médium. Donedávna však chýbala nadstavba, ktorá by tento štandard využila a doplnila za účelom reálneho nasadenia bezdrôtových senzorových sietí v priemyselnej praxi.

Ako príklad je možné uviesť snímanie akustických emisií v doprave, snímanie pohybu osôb v objekte alebo získavanie meteorologických dát, prípadne široké využitie WSN v inteligentných budovách. Komunikácia medzi jednotlivými uzlami je zabezpečená práve prostredníctvom tohto štandardu. Uzly v bezdrôtovej senzorovej sieti majú svoju priepustnosť, výpočtový výkon a iné vlastnosti, ktoré závisia od aplikácie a dostupného množstva energie.

Množina úloh využitia analýzy akustických signálov v cestnej doprave je široká. Práve preto je cieľ om práce zamerať sa hlavne na klasifikáciu rôznych akustických signálov. Ďalším cieľ om je vytvorenie nových metód alebo algoritmov na klasifikáciu týchto akustických signálov a v neposlednom rade je redukcia dát, ktoré sú potrebné na úspešnú klasifikáciu akustického signálu. Taktiež je potrebné overiť funkčnosť týchto metód alebo algoritmov experimentom.

Práca je rozdelená na dve základne časti, a to teoretickú a experimentálnu čast. V teoretickej časti sa prvá kapitola venuje cieľ om práce, ktoré sú tu bližšie opísané.

Druhá kapitola sa venuje aplikáciam vo WSN sieť ach, požiadavkám na senzorový uzol siete a možnostiam monitorovania WSN sietí v rôznych oblastiach ako aj monitorovaniu v dopravných systémoch.

Tretia kapitola je zameraná na spektrálnu analýzu akustického signálu. Pojednáva sa v nej o možnostiach Fourierovej transformácie, ako aj o možnostiach frekvenčných filtrov. Sú v nej opísané aj ď alšie možnosti riešenia spektrálnej analýzy akustického signálu.

Štvrtá kapitola je zameraná na metódu hlavných komponentov, ktorá slúži hlavne na redukciu spracovaných dát, podstatu tejto metódy a ako sa tvoria jednotlivé hlavné komponenty.

V piatej kapitole sme sa zamerali na neurónové siete, štruktúru neurónových sietí, rozdelenie sietí, ako prebieha učenie siete s vybratým algoritmom pre učenie sa siete. Piatou kapitolou končí teoretická časť práce a nasleduje experimentálna časť.

V experimentálnej časti práce je návrh metódy na klasifikáciu akustických signálov. Ďalej nasleduje kapitola opisujúca vykonané experimenty, ktoré nám umožnili potvrdiť navrhnutú metódu na klasifikáciu akustických signálov.

Posledná kapitola obsahuje prínos práce a nasleduje záver.

## Teoretická časť práce

## 1 Ciele práce

Ciele dizertačnej práce sú opísané v jednotlivých podkapitolách.

### 1.1 Analýza vlastností akustického signálu

Analýza bude zameraná na určenie charakteristických vlastností akustického signálu za účelom ich ďalšieho využitia pri návrhu metód a algoritmov efektívneho spracovania dát senzorovým uzlom.

# 1.2 Návrh metód a algoritmov efektívneho spracovania dát senzorovým uzlom

Navrhnuté metódy umožnia spracovanie dát, na báze charakteristických vlastností akustického signálu, bez straty (prípadne s povolenou stratou) informačného obsahu signálu so zreteľ om na jeho optimálne kódovanie.

# **1.3** Návrh nových metód a algoritmov identifikácie dopravných tokov a klasifikácie zdrojov akustických signálov

Metódy identifikácie parametrov dopravných tokov a klasifikácie zdrojov akustických signálov (triedenie dopravných prostriedkov) umožnia rozvoj aplikácií v oblasti zvýšenia bezpečnosti dopravných systémov, riadenia dopravných tokov, ako aj plánovania výstavby, resp. údržby dopravnej infraštruktúry.

### **1.4** Experimentálne overenie teoretických záverov

Experimentálne overenie bude zamerané na oblasť inteligentných dopravných systémov. Cieľ om experimentov bude potvrdenie, resp. vyvrátenie teoretických záverov dizertačnej práce.

## 2 Aplikácie vo WSN sieť ach

Úspešná realizácia bezdrôtových senzorových sietí (WSN) je podmienená vývojom technológií, ktoré umožňujú realizáciu spoľahlivých a ekonomicky zaujímavých aplikácií [1]. Vývoj je možný v týchto oblastiach:

- Moderné nízkovýkonové elektronické zariadenia.
- Prvky MEMS (Micro–Electro–Mechanical Systems).
- Elektrické zdroje energie s vysokou energetickou hustotou.
- Zariadenia slúžiace na zber energie z okolitého prostredia.
- Nové RF komunikačné štandardy.
- Nové princípy HMI (Human Machine Interface).

To znamená, riešiť rôzne problémy v oblastiach meracích zariadení, elektroniky, komunikačných zariadení, programovania a mnoho ď alších [2]. Všeobecne je možné konštatovať, že WSN sú použiteľ né všade tam, kde sú k dispozícii distribuované informačné zdroje. Perspektívne oblasti využitia WSN aplikácií by mohli byť klasifikované nasledovne:

- Monitorovanie a ochrana životného prostredia.
- Monitorovanie ekologických škôd, ako aj preventívna ochrana pred jej účinkami.
- Vojenské aplikácie.
- Lekárske aplikácie.
- Dopravné aplikácie.
- Priemyselné využitie.
- Obchodné aplikácie a mnoho ď alších.

Cestná doprava predstavuje veľmi zaujímavú oblasť, kde je WSN použiteľná rôznymi spôsobmi [3]. Je zrejmé, že monitorovanie a kontrola, prípadné riadenie premávky na pozemných komunikáciách vyžaduje zber informácie z mnohých senzorov, ktoré sú vhodne

rozdelené vo veľkých zónach. To je dôvod, prečo má výskum a vývoj svoje prirodzené zameranie na implementáciu bezdrôtového snímača do cestnej siete, ktorý by slúžil na monitorovanie a riadenie aplikácii. Ak sú mobilné prvky súčasť ou cestnej siete, WSN by mohla zvýšiť bezpečnosť cestnej premávky. V poslednej dobe sa väčšina aplikácií v oblasti WSN zameriava na:

- Monitorovanie cestnej dopravy [4], [5].
- Monitorovanie parkovacích pozemkov a ich riadenia [6], [7].
- Adaptívne riadenie semaforov [8], [9].

WSN sa skladá z mnohých senzorový uzlov, ktoré sú rozmiestnené v monitorovanóm území [26]. Tieto uzly sú umiestnené náhodne alebo na vopred definovanej pozícii. Každý uzol musí spĺňať často protichodné požiadavky, napr. vysokovýkonná centrálna procesorová jednotka s minimálnymi nákladmi na spotrebu energie, dlhá životnosť bez údržby napriek nízkej kapacite zdroja energie [23], [24], [25]. Spotreba komunikačného prvku úzko súvisí s vysielacím výkonom, ako aj citlivosť ou prijímača. Z uvedených dôvodov sa senzorový uzol zvyčajne navrhuje ako kompromisné riešenie medzi aplikačnými požiadavkami a možnosť ami existujúcich technológií.

## 2.1 Požiadavky na senzorový uzol

Každá senzorová sieť sa skladá z mnohých jednoduchých senzorov umiestnených v okolí. Každý uzol by mal byť schopný vykonávať nasledujúce základné funkcie:

- Zber dát.
- Spracovanie dát.
- Komunikácia.
- Automatické zistenie pozície v prípade, že WSN nie je štruktúrované, GPS nám umožňuje určiť tento lokalizačný problém. Ďalšie riešenie je založené na princípe vyhodnotenia intenzity RF signálu [10],[11].

Časová synchronizácia prvkov siete je vyžadovaná vo väčšine aplikácií. Problém môže vyriešiť GPS. Ďalšie pristupy sú uvedené v [12], [13], [14].

Ďalšie požiadavky sieť ových uzlov, ktoré sú potrebné zhodnotiť:

- Výpočtový výkon a kapacita pamäte v jednom uzle.
- Nízka spotreba energie, prípadne dlhá životnosť.
- Náklady na jeden uzol.
- Bezpečnosť.
- Odolnosť proti chybám.

Dôležité je poznamenať, že nie je možné vytvoriť univerzálnu bezdrôtovú sieť, ktorá by spĺňala všetky uvedené požiadavky. Taktiež každý uzol WSN musí zabezpečiť vykonávanie týchto troch základných funkcií: zber dát, spracovanie dát a prenos dát.

## 2.2 Monitorovanie dopravných systémov

Monitorovanie dopravných systémov slúži predovšetkým na:

- Detekciu vozidiel na nastavenie jazdných pruhov križovatiek.
- Počítanie vozidiel na určenie počtu vozidiel na križovatkách, čo je dôležitá informácia pre ovládanie semaforov.
- Klasifikácia vozidiel identifikácia typu vozidla pre rôzne aplikácie.
- Meranie intenzity dopravného toku informácie potrebné pre efektívnu údržbu povrchu vozovky, kontrola prevádzky.
- Meranie rýchlosti vozidiel podporuje bezpečnosť a efektívnosť jazdy.

Monitorovanie zásahových vozidiel umožňuje bezpečný prechod križovatkou. Vzhľadom na to, že pohotovostné vozidlá používajú sirény, sledovanie týchto vozidiel je spoľahlivo zaistené akustickými snímačmi [22]. Monitorovanie poveternostných podmienok umožňuje vodičovi prispôsobiť štýl jazdy, aby sa predišlo nehodám. Monitorovanie podmienok prostredia slúži na zhromaždenie informácií o znečistení ovzdušia: emisie CO<sub>2</sub>, koncentrácie prachu, akustický hluk súvisiaci s prevádzkou v tejto oblasti. Tieto informácie sú cenné pre:

- Vývoj aplikácií pre ochranu zdravia občanov.
- Plánovanie rekonštrukcie historických objektov atď.

Senzorový uzol musí byť schopný komunikovať s najbližšími uzlami siete, prípadne so základnou stanicou prostredníctvom bezdrôtovej komunikácie. Komunikačná jednotka je hlavným odberateľ om energie zo systému. Nízka rýchlosť prenosu dát je očakáva pri WSN aplikáciach, pretože vyššie frekvenčné kanály sú nesprávne definované. Výber nižšej komunikačnej frekvencie medzi senzorovými uzlami má pozitívny vplyv na komunikáciu:

- Užšia šírka pásma kanála tým je možne dosiahnuť zvyšujúci sa počet kanálov pre definovaný frekvenčný rozsah.
- Zvyšuje sa komunikačná vzdialenosť.
- Znižuje sa strata na komunikačnej ceste menšie straty energie, vyššia kvalita a spol'ahlivost' komunikácie.
- Nižší vplyv prekážkok na silu signálu.
- Lepšia odolnosť proti poveternostným podmienkam nižšia chybovosť systému.

Na základe vyššie uvedených údajov je možné konštatovať, že nižšie frekvenčné pásmo je atraktívne pre riešenie návrhov WSN.

## 3 Spektrálna analýza akustických signálov

Zvuk (akustický signál) môžeme všeobecne definovať, ako mechanické kmitanie [19], ktoré je charakterizované parametrami pohybu častíc pružného prostredia alebo u vlnového pohybu parametrami zvukového poľa. Časť akustického signálu sa prejavuje ako počuteľný zvuk – čo je akustické kmitanie pružného prostredia (v pásme frekvencií od 16 Hz do 20 kHz), schopné vyvolať zvukový vnem. Rozsah počuteľného zvuku je individuálny. Len málokto je schopný vnímať celé pásmo frekvencií (predovšetkým počuteľnosť vyšších frekvencií je veľmi premenlivé a závislé na veku). Zvuky mimo tohto pásma nepočujeme, napriek tomu sme ich schopní vnímať a môžu mať aj nepriaznivý vplyv na zdravie či psychiku. Zvuky pod hranicou počuteľnosti (0,7 – 16 Hz) označujeme ako infrazvuk, zvuky z intervalu 20 kHz až 50 kHz sú známe ako ultrazvuk.

Čisté harmonické priebehy sa však vyskytujú len u najjednoduchších zvukov. V bežnej akustike sa s nimi takmer nestretneme. Akustický signál väčšiny zdrojov je oproti základnej sínusoide viac či menej deformovaný [20], [21]. Napriek tomu možno v každom periodickom signáli určiť základnú frekvenciu a pomocou frekvenčnej analýzy určiť jej harmonické zložky. Súčet ďalších frekvencií spolu so základnou frekvenciou vytvárajú deformovanú krivku. Výsledkom frekvenčnej analýzy je frekvenčné spektrum, z ktorého možno spätným postupom, frekvenčnou syntézou, zložiť pôvodný signál.

### 3.1 Základne vlastnosti akustického signálu

Akustický signál je charakterizovaný nasledovnými vlastnosť ami [41]:

- λ Vlnová dĺžka: Vzdialenosť dvoch najbližších bodov, ktoré kmitajú s rovnakou fázou. Pre lepšiu názornosť si môžeme predstaviť vzdialenosť dvoch miest prostredia, ktoré majú v danom okamihu rovnakú úroveň – zhustenie, respektíve zriedenia častíc.
- *f* Frekvencia zvuku: Jednotkou je hertz (Hz). Môžeme si ju predstaviť ako počet zhustení (zriedení) častíc v danom bode prostredia za základnú jednotku času.
- p Akustický tlak: Vzduch, v ktorom sa zvuk šíri, má vzhľadom k základnému atmosférickému tlaku v miestach zhustenia častíc mierny pretlak a v miestach zriedenia mierny podtlak. Tak vznikajú tlakové vlny, ktoré vyvolávajú sluchový vnem. Pri ich

šírení je im kladení odpor a tak hlasitosť s narastajúcou vzdialenosť ou slabne. Jednotkou akustického tlaku v sústave SI je 1 pascal (Pa).

- *P* Akustický výkon: Pod týmto pojmom sa rozumie akustická energia, ktorá prejde ľubovoľnou plochou S za sekundu.
- v<sub>z</sub> Rýchlosť šírenia zvukových vĺn: Závisí na prostredí, v ktorom sa zvuk šíri. Pri danom prostredí závisí na fyzikálnom stave tohto prostredia. Rýchlosť šírenia zvuku nezávisí od jeho frekvencie. Rýchlosť vo vzduchu, kde sa zvuk šíri najčastejšie, je 340 m za sekundu, vo vode 1480 m za sekundu, v oceli 5000 m za sekundu.

Pomocou týchto základných vlastností akustického signálu sme schopný realizovať rôzne druhy transformácii a iných operácii.

## 3.2 Fourierová transformácia

Fourierová transformácia je integrálna transformácia prevádzajúca signál z časovej oblasti do frekvenčnej oblasti zo závislým vyjadrením pomocou harmonických signálov, tj. funkcií sin(x) a cos(x). Fourierová transformácia môže spracovať signál, ktorý môže byť buď spojitý alebo diskrétny v čase [18].

#### 3.2.1 Druhy Fourierových transformácií

Poznáme viacero druhov algoritmov na výpočet Fourierovej transformácie:

- diskrétna Fourierová transformácia (DFT),
- rýchla Fourierová transformácia (FFT),
- krátkodobá Fourierová transformacia (STFT),
- a iné.

Niektoré z nich si priblížime.

#### Diskrétna Fourierová transformácia

Diskrétna Fourierová transformácia (DFT) slúži na konštrukciu spektra digitalizovaných signálov, pozostávajúcich zo sekvencie diskrétnych vzoriek [15], [16]. Vzorec pre výpočet diskrétnej Fourierovej transformácia je daný vzťahom 3.1.

$$X_k = \sum_{n=0}^{N-1} X_n e^{-i\frac{2\pi kn}{N}},$$
(3.1)

kde k = 0, 1, 2, ..., (N - 1).

Algoritmus DFT [3], [38], [39] spracováva konečný počet *N* vzoriek signálu, teda z signálu vyrezáva segment  $T_0 = NT$ . Ostré odrezanie signálu môžeme vyjadriť v časovej oblasti jeho násobením obdĺžnikovým oknom, teda váhovou funkciou w(n):

w(n) = 1 pre  $0 \le n \le N - 1$ ,

w(n) = 0 pre 0 > n > N - 1.

Z toho vyplýva, že segment signálu  $x_w(n)$  určený N vzorkami bude:

$$x_w(n) = x(n).w(n).$$
 (3.2)

Takže môžeme povedať, že spektrum signálu je ovplyvnené spektrom váhovej funkcie. Spektrálnym obrazom súčinu signálov x(n) a w(n) je konvolúcia ich spektier X(k) a W(k).

#### Tvar váhovej funkcie:

Zmenou tvaru okna sa znižuje zhoršenie frekvenčného rozlíšenia. Voľba váhovej funkcie je kompromisom medzi potlačením presakovania (miešanie spektier) a zhoršením frekvenčného rozlíšenia.

Pre analýzu akustického signálu sú vhodné predovšetkým Hanningovo, Hammingovo, Blackmanovo a trojuholníkové váhové funkcie (obr. 1).

#### Rýchla Fourierová transformácia

Predchádzajúci algoritmus (DFT) pre výpočet diskrétnej Fourierovej transformácie je pomerne jednoduchý, čo má za následok kvadratickú časovú zložitosť  $O(n^2)$ . Z tohto dôvodu bola Fourierová transformácia v praktických aplikáciách málo používaná [32], [33]. Napokon v roku 1942 Danielson a Lanczos vypracovali verziu tohto algoritmu označovanú



Obrázok 1: Grafy váhových funkcií.

pod názvom rýchla Fourierová transformácia. Časová zložitosť tohto algoritmu je už logaritmická  $O(Nlog_2N)$ . Danielson a Lanczos ukázali, že diskrétna Fourierová transformácia dĺžky N môže byť počítaná ako suma dvoch Fourierových transformácii dĺžky N/2. Jedna môže byť počítaná s párnymi vzorkami (nachádzajúcimi sa na párnom mieste) a druhá nepárnymi vzorkami (nachádzajúcimi sa na nepárnom mieste) pôvodnej Fourierovej transformácie, čo je vyjadrené vzť ahom:

$$X(k) = \sum_{n=0}^{\frac{N}{2}-1} x(2n) W_{\frac{N}{2}}^{nk} + W_{N}^{k} \sum_{n=0}^{\frac{N}{2}-1} x(2n+1) W_{\frac{N}{2}}^{nk}, \qquad W_{N} = e^{-j\frac{2\pi}{N}},$$
(3.3)

kde k = 0, 1, 2, ..., N - 1. Zo vzťahu je vidieť, že výpočet diskrétnej Fourierovej transformácie (s periódou *N*) sa redukuje. Podstatou algoritmu je zníženie počtu potrebných komplexných násobení z počtu  $N^2$  na počet  $Nlog_2(N)$  z dôvodu realizácie analýzy v reálnom čase.

Výhoda tohto algoritmu je teda v jeho rekurzivite. Avšak obmedzením je počet bodov vstupujúcich do transformácie, ktorý musí byť  $N = 2^r, r > 0$ .

### Krátkodobá Fourierová transformácia

Krátkodobá Fourierová transformácia (STFT) [31] nám pomáha vyriešiť problém straty informácie o čase pri použití Fourierovej transformácie. Označme rovnomerne vzorkované signály f(t) a g(t) ako funkciu f[n] a g[m]. Následne diskrétna STFT, pomocou váhovej

funkcie g[m], môže byť popísaná vzťahom:

$$F_g f(n,k) = \sum_{m=0}^{M-1} f(n-m)g(m)e^{\frac{-2\pi mk}{N}},$$
(3.4)

kde *M* je dĺžka okienka g[m] a *N* je počet vzoriek v f[n]. Tento algoritmus môže byť interpretovaný ako mnoho Fourierových transformácii idúcich za sebou po malých segmentoch na celom signále. Toto zobrazenie sa nazýva spektrogram signálu f[n].

Spektrogramy na obrázku 2 a 3 boli vypočítané pri rôznych dĺžkach STFT. Okienko o veľkosti 25 ms nám umožňuje identifikovať presný čas, kedy sa signál zmenil, ale presná identifikácia frekvencie je náročná. Na druhej strane, okienko o veľkosti 1000 ms umožňuje presnejšie určenie frekvencie, ale čas medzi zmenou frekvencie nie je dobre identifikovateľný (rozmazaný) [30].



Obrázok 2: Spektrogramy pri rôznych dĺžkach STFT.



Obrázok 3: Spektrogramy pri rôznych dĺžkach STFT.

## 3.3 Frekvenčné filtre

Filter pre spracovanie signálu predstavuje model, ktorým popisujeme systém (skutočný alebo virtuálny), opisujúci vzťahy medzi jeho vstupom a výstupom (prenosová charakteristika).

## 3.3.1 Rozdelenie frekvenčných filtrov

Frekvenčné filtre môžeme rozdeliť podľa viacerých kritérií. Z hľadiska všeobecných charakteristík na:

- lineárny, nelineárny
- kauzálny, nekauzálny
- s pamäťou, bez pamäte

Z hľadiska realizácie na:

- analógové (spojité):
  - aktívne
  - pasívne
- digitálne (číslicové):
  - filtre s nekonečnou impulznou odozvou (IIR)
  - filtre s konečnou impulznou odozvou (FIR)

### **Porovnanie filtrov FIR a IIR:**

Prenosová funkcia FIR filtrov obsahuje iba nuly (korene čitateľ a prenosu), teda tento filter je vždy stabilný. IIR filter má nuly, aj póly (korene menovateľ a prenosu). Môže byť nestabilný, ak sú póly mimo jednotkovej kružnice. FIR filter je ľ ahko realizovateľ ný, ale jeho rád býva vyšší ako u IIR filtra. U FIR filtra sa dá dosiahnuť lineárna fáza, u IIR filtra býva špecifikovaná iba amplitúdová charakteristika, lineárna fáza môže byť iba aproximovaná.

Z hľadiska frekvenčnej priepustnosti filtra na:

- Dolno-priepustný,
- Horno-priepustný,
- Pásmová zádrž,
- Pásmová priepusť,
- Plno-priepustný.

Každý navrhnutý filter má svoj rád. Rád filtra (rád modelu) určuje, s akou vernosť ou (presnosť ou) sú modelované vlastnosti filtra.

#### 3.3.2 Banka frekvenčných filtrov

Pod pojmom banka frekvenčných filtrov rozumieme množinu frekvenčných filtrov, napríklad typu pásmová priepusť, ktoré prepúšť ajú definovaný frekvenčný rozsah. Špeciálnym prípadom pásmovej priepuste je rezonančný filter, ktorý sa často používa ako základný komponent banky filtrov. Ak sa sústredíme len na jeden filter, tak pri frekvencií, na ktorú je daný filter naladený, dôjde k jeho rozkmitaniu a teda aj zosilneniu tejto frekvencie s daným zosilnením. Počet frekvenčných filtrov sa môže meniť podľ a aplikácie. Niektoré akustické aplikácie potrebujú na celé frekvenčné spektrum 10 filtrov iné aj 100.

Veľkosti pásiem priepustností sa tiež môžu líšiť. Podľa aplikácie od jednoduchého lineárneho rozdelenia, logaritmického rozdelenia, melovej stupnice až po špeciálne teda jednoúčelové vytvorené stupnice.

#### 3.3.3 Návrh frekvenčného filtra

Rezonančné filtre druhého rádu, teda IIR filtre  $(y[n] = x[n] - a_1y[n-1] - a_2y[n-2])$ , môžu byť navrhnuté s jedným vrcholom, v jeho frekvenčnej charakteristike, podľa koeficientov nasledovne:

$$a_1 = -2rcos(2\pi f_c T_{v_z}),$$
  
 $a_2 = r^2,$  (3.5)

kde  $f_c$  je stred rezonančnej frekvencie,  $T_{vz} = 1/f_{vz}$ , čiže  $f_{vz}$  je vzorkovacia frekvencia a rz intervalu (0; 1, 0). Čím viac sa blíži r k hodnote 1, 0, tým užšia je šírka pásma.



Obrázok 4: Charakteristika rezonančného filtra s rezonančnou frekvenciou 5 kHz.

Ďalej môžeme navrhnúť rezonančný filter tak, že rezonančný vrchol má vždy zisk 1,0 tým, že špecifikujeme koeficienty čitateľ a ako  $(y[n] = b_0 x[n] + b_1 x[n-1] + b_2 x[n-2] - a_1 y$  $[n-1] - a_2 y[n-2])$ :

$$b_0 = \frac{(1-r^2)}{2},$$
  
 $b_1 = 0,$  (3.6)  
 $b_2 = -b_0.$ 

Magnitúda rezonančného digitálneho filtra je uvedená na obrázku 4. Koeficienty boli vypočítané podľa vyššie uvedených vzťahov.

Týmto spôsobom je možné vytvoriť jeden filter na nami vybranej frekvencii. Taktiež je možné zapojiť mnoho rezonančných filtrov paralelne, teda každý filter rezonuje na inej frekvencii a dáva vlastný výstup na nami zvolenej frekvencii.

# 3.4 Ďalšie matematické metódy pre analýzu vlastnosti akustického signálu

Medzi takéto metódy patria:

- Diskrétna kosínusová transformácia,
- Waveletová transformácia,
- Wingerová distribúcia,
- Gaborov rozvoj.

Prvé dve si priblížime podrobnejšie.

### 3.4.1 Diskrétna kosínusová transformácia

Diskrétna kosínusová transformácia (ď alej už len DCT) patrí spolu so známou Diskrétnou Fourierovou transformáciou do skupiny metód vykonávajúcich takzvané transformačne kódovanie nad diskrétnym (vzorkovaným) jednorozmerným či viacrozmerným signálom [40]. V prípade spracovania obrazu (dvojrozmerného signálu) toto kódovanie spočíva v nájdení korelácií medzi susednými pixelmi, čo je možné využiť pri následnom odstránení redundantných informácií za účelom dátovej kompresie.

DCT sústreď uje najviac energie pôvodného signálu v najnižších frekvenciách (obrázok 5). Uvedená skutočnosť v spojení s predpokladom, že informačný obsah je väčšinou obsiahnutý v nižších frekvenciách signálu, umožňuje dátovú kompresiu. V prípade obrazovej kompresie, napríklad použitím frekvenčnej domény (matica DCT koeficientov), vynulovaním zanedbateľ ných frekvencií a spätným zobrazením obrázka inverznou transformáciou, môžeme znížiť počet bitov potrebných pre zachovanie informačného obsahu pôvodného obrázku.

V reálnych aplikáciách je DCT súčasť ou stratového kompresného formátu JPEG, či MPEG jej modifikovaná verzia je zase používa v audio formátoch AAC, či MP3.



Obrázok 5: Energia signálu je po vykonaní diskrétnej kosínusovej transformácie sústredená v niekoľ kých počiatočných koeficientoch zodpovedajúcich najnižším frekvenciám.

#### Formálne vyjadrenie DCT:

Formálne je jednorozmerná diskrétna kosínusová transformácia lineárnym, invertovateľným zobrazením  $F : \mathbb{R}^n \to \mathbb{R}^n$ . Transformuje teda vektor reálnych čísel  $x_0, x_1, ..., x_{N-1}$  na vektor  $X_0, X_1, ..., X_{N-1}$  a to podľa vzorca:

$$X_{k} = c(k) \sum_{n=0}^{N-1} x_{n} cos\left[\frac{\pi}{N}\left(n+\frac{1}{2}\right)k\right] \quad \text{pre} \quad k = 0, ..., (N-1),$$
(3.7)

kde hodnoty konštánt c(k) sú:

$$c(k) = \frac{1}{\sqrt{N}} \quad \text{pre} \quad k = 0, \tag{3.8}$$

$$c(k) = \sqrt{\frac{2}{N}}$$
 pre  $1 \le k \le (N-1).$  (3.9)

Hodnota *N* značí maximálnu dĺžku signálu (tzv. rád transformácie), ktorú je transformácia schopná spracovať. Pokiaľ je vstupný signál dlhší, je rozdelený na úseky maximálnou dĺžkou *N*, ktoré sú transformované oddelene [40].

Dvojrozmernú diskrétnu transformáciu získame prevedením jednorozmernej DCT pozdĺž riadkov a stĺpcov vstupnej matice (resp. obrázku) veľkosti *NxN*. Vzorec pre jej výpočet je

teda:

$$X_{k_1,k_2} = c(k_1,k_2) \sum_{n=0}^{N-1} \sum_{m=0}^{N-1} x_{m,n} cos\left[\frac{\pi}{N}\left(m+\frac{1}{2}\right)k_1\right] cos\left[\frac{\pi}{N}\left(n+\frac{1}{2}\right)k_2\right],$$
(3.10)

pričom pre konštanty tentokrát platí:

$$c(k_1, k_2) = c(k_1) \cdot c(k_2), \tag{3.11}$$

kde c(k) je definované rovnako ako v prípade jednorozmernej DCT. Poznamenajme ešte, že rád dvojrozmernej DCT je všeobecne typu MxN, väčšinou sa však pre zjednodušenie výpočtov používa M = N.

#### 3.4.2 Waveletová transformácia

Z pohľadu digitálneho spracovania signálu sú wavelety široko využívané na spektrálnu analýzu signálu a na transformáciu dát. Koncept waveletov má korene v mnohých disciplínach ako napr. matematika, fyzika a strojárstvo. V rokoch 1980–1990 vznikla nová vlna waveletových objavov.

Wavelet [35], [36], [37] čo doslovne znamená malá vlnka, je oscilovanie funkcie s nulovým priemerom, ktorá je ohraničená v malom časovom úseku. Z waveletovej funkcie, známej ako matka waveletov, je odvodená rodina waveletov preložením (posunutím) a dilatáciou (natiahnutím alebo stlačením) oproti originálnej waveletovej funkcii.

Digitálny signál môže byť reprezentovaný ako súčet waveletov, ktoré sú v zásade totožné, s výnimkou preloženia a dilatácie. Preto môžu byť v signáli zastúpené úplne všetky waveletové koeficienty. Tieto koeficienty poskytujú dôležité informácie o frekvencii a čase a používajú sa na analýzu signálu. Signál môže byť samozrejme spracovaný v spektrálnej oblasti predtým, než je transformovaný späť do časovej oblasti.

Prístup waveletovej transformácie usiluje o dosiahnutie optimálnej rovnováhy medzi rozlíšením frekvencie a času.

#### Druhy waveletovej transformácie:

Waveletovú transformáciu možno rozdeliť do troch typov: spojitá waveletová transformácia, waveletová transformácia s diskrétnymi koeficientmi a diskrétna waveletová transformácia.

## Najznámejšie wavelety sú:

- Haarov wavelet,
- Morletov wavelet,
- Daubechiho wavelet,
- a mnoho d'alších.

Aby sme si vedeli predstaviť ako taky wavelet vyzerá, na obrázku 6 je zobrazený Daubechiho wavelet [34].



Obrázok 6: Daubechiho wavelet triedy D - 4N, kde *i* je počet vzoriek a *w* amplitúda.

## 4 Metóda hlavných komponentov

V nasledujúcej kapitole sa zoznámime s metódou hlavných komponentov (Principal Component Analysis, PCA). Túto metódu zaviedol už v roku 1901 anglický matematik, filozof a zakladateľ odboru matematickej štatistiky Karl Pearson ju definuje ako opisnú štatistickú metódu, ktorá slúžila najmä k redukcii mnohorozmerných dát. Na jeho prácu nadviazal v roku 1933 štatistík Harold Hotelling, a to tým spôsobom, že zovšeobecnil postup aplikácií komponentnej analýzy na náhodné vektory a navrhol použitie metódy hlavných komponentov pre rozbor kovariančnej štruktúry premenných. Preto môžeme túto metódu nájsť tiež pod názvom Hotellingova transformácia (Hotelling Transform). V súčasnej štatistickej literatúre je metóda hlavných komponentov doporučovaná najmä ako význačný nástroj prieskumnej analýzy dát pre overovanie predpokladov, ďalej ako samostatný nástroj na analýzu štruktúry vzť ahov v množine vzájomne závislých pozorovaní a v neposlednom rade ako užitočný pomocník niektorých metód mnohorozmernej štatistickej analýzy. Metóda hlavných komponentov pomáha ako jedno z možných prvých riešení, napríklad v diskriminačnej analýze, v prípade malého počtu pozorovaní a veľkého počtu premenných, ďalej umožňuje regresnej analýze odstrániť problémy s multikolinearitou a prebytočným počtom vzájomne závislých vysvetľujúcich premenných, pomáha tiež zhlukovej analýze pri klasifikácii objektov do homogénnych skupín na základe veľkého počtu premenných, ale aj faktorovej analýze a ďalším viacrozmerným [43], [45]. Hlavným zdrojom pre tvorbu tejto kapitoly boli články a knihy [42], [43], [44], [46], [47], [48].

### 4.1 Mnohorozmerné dáta

Je potrebné spomenúť dôležitý pojem, a tým je skúmaná náhodná veličina (premenná, štatistický znak). Jedná sa o vlastnosť, ktorú sledujeme na vybraných prvkoch a nadobúda rôzne hodnoty. Je dôležité uvedomiť si, že veličiny, ktoré zisť ujeme na sledovaných objektoch, sú rôzneho typu. Informácie k tejto podkapitole sú čerpané najmä z [46].

Veličiny môžeme rozlišovať podľa meracej stupnice, tzv. škály na:

 nominálne – veličiny merané na nominálnej škále. Táto škála je zložená z dvoch alebo viacerých vzájomne sa vylučujúcich kategórií, ktoré nemôžu byť zoradené, a teda
nominálne veličiny triedime na:

- 1. binárne (dvojhodnotové),
- 2. viachodnotové,
- ordinálne (poradové) rovnako ako u nominálnych veličín, sú hodnoty ordinálnych veličín zoskupené do nezlučiteľ ných kategórií, ale navyše možno tieto hodnoty vzájomne usporiadať,
- pomerové s absolútnou nulou začína skutočným nulovým bodom, čo umožňuje vypočítať rozdiely (intervaly) medzi hodnotami a tiež podiely týchto hodnôt. Zároveň, ale absolútna nula, vylučuje záporné hodnoty.
- intervalové s relatívnou nulou nemá jasne určenú nulovú pozíciu, umožňuje stanoviť vzdialenosť (rozdiel) medzi hodnotami definovanú jednotkou.

Ďalej veličiny môžeme rozlišovať podľa oboru ich hodnôt:

- spojité môžu nadobúdať nespočetne veľa hodnôt,
- diskrétne nadobúdajú len vyčísliteľ ný počet hodnôt, ktoré sa nazývajú varianty, kategórie alebo úrovne.

Tiež delíme veličiny na kvantitatívne a kvalitatívne:

- kvantitatívne (metrické) označujú veličiny diskrétne, spojité, pomerové a intervalové,
- kvalitatívne (kategoriálne) označujú iba diskrétne veličiny, a to nominálne a ordinálne veličiny.

#### 4.1.1 Typy štatistických analýz

Rozlišujeme rôzne typy analýz mnohorozmerných dát. Záleží na tom, či sledované objekty môžeme považovať za nezávislé, alebo dáta vznikli ako rad pozorovaní toho istého objektu v rôznych obdobiach. Informácie sú čerpané najmä z [46]. Teraz si zavedieme nasledujúce označenie:  $X_{iit} \rightarrow \text{data},$ 

 $i = 1, ..., n \rightarrow$  objekty (pozorovanie), pričom *n* je počet pozorovaní,

 $j = 1, ..., p \rightarrow$  premenné (vlastnosti), kde p je počet premenných, tj. dimenzia (rozmer) úlohy,

 $t = 1, ..., T \rightarrow čas, kde T je časový horizont.$ 

Nasledujúca tabuľka 1 znázorňuje rôzne typy úloh riešených analýzou dát.

Počet	Počet	Časový	Typ analýzy	
pozorovaní	premenných	horizont		
n	1	1	jednorozmerná štatistická analýza	
1	p	1	kazuistika	
1	1	Т	jednorozmerný časový rad	
n	1	Т	jednorozmerné longitudinálne sledovanie	
n	р	1	viacrozmerná štatistická analýza	
1	р	Т	viacrozmerný časový rad	
n	р	Т	mnohorozmerné longitudinálne sledovanie	

Tabul'ka 1: Úlohy riešené analýzou dát

Všimnime si, že mnohorozmerné longitudinálne sledovanie, ktorému sa v tejto práci budeme venovať, sa zaoberá situáciou, kedy na n objektoch sledujeme p vlastností v čase T.

## 4.2 Ciele metódy PCA

Základný cieľ metódy hlavných komponentov spočíva najmä v zjednodušení popisu skupiny vzájomne lineárne závislých, teda korelovaných znakov. Metóda sa snaží znížiť dimenziu úlohy, čiže redukovať počet znakov s povolenou stratou informácie, čo je výhodné predovšetkým pre zobrazenie mnohorozmerných dát. Jednotlivé merané veličiny pomerne často vykazujú silnú koreláciu. Pre zjednodušenie analýzy a jednoduchšie hodnotenie výsledkov je vhodné skúmať, či je možné celú skupinu premenných (teda študovanej vlastnosti pozorovaných objektov) nahradiť jedinou veličinou alebo menším počtom veličín, ktoré budú obsahovať o dátach takmer rovnakú informáciu, ako obsahovali pôvodné veličiny. Tento problém možno opísať ako metódu lineárnej transformácie pôvodných znakov na nové, vzájomne nekorelované premenné, ktoré majú vhodnejšie vlastnosti a je ich výrazne menej.

Metóda hlavných komponentov sa teda snaží nájsť tieto skryté (umelé, latentné, nemerateľné) veličiny, nazvané ako hlavné komponenty. Nové vytvorené premenné sú lineárnou kombináciou pôvodných premenných a požaduje sa od nich, aby čo najlepšie reprezentovali pôvodné premenné, inak povedané, aby čo najlepšie vysvetľovali variabilitu pôvodných premenných.

Základnou charakteristikou každého hlavného komponentu je jeho miera variability, čiže rozptyl. Hlavné komponenty sú zoradené podľa dôležitosti, tj. podľa klesajúceho rozptylu, od najväčšieho k najmenšiemu. Prvý hlavný komponent obsahuje najviac informácií o variabilite pôvodných dát, druhý hlavný komponent zase najväčšiu časť rozptylu pôvodných dát neobsadeného v prvom komponente. Najmenej informácií je obsiahnutých v poslednom komponente. Ak má nejaký pôvodný znak malý, či dokonca žiadny rozptyl, potom nie je schopný prispievať k rozlíšeniu medzi objektmi. Metóda hlavných komponentov umožňuje namiesto vyšetrovania veľkého počtu pôvodných znakov s komplexnými vnútornými väzbami analyzovať iba malý počet nekorelovaných hlavných komponentov.

V praxi býva metóda hlavných komponentov využívaná napríklad pre efektívne rozpoznávanie obrázkov ľudskej tváre. V tomto prípade metóda hlavných komponentov redukuje pôvodný priestor obrázkov a poskytuje veľmi rozumnú extrakcia rysov. Praktickou úlohou je identifikácia osôb podľa zvoleného biometrického rysu, ako je napríklad očná dúhovka či rysy tváre [50], [51].

### 4.3 Podstata PCA

U metódy hlavných komponentov je vstupom zdrojová matica dát **X** typu *n x p*. Táto matica obsahuje hodnoty *n* objektov (pozorovanie, meranie) pre *p* pôvodných premenných (vlastností, skúmaných znakov, meraných veličín). Dôležitá je skutočnosť, že pre každý objekt zo skupiny *n* objektov je známy skúmaný znak. Výstupom je aproximácia zdrojovej matice dát **X**, obsahujúca hodnoty *n* meraní pre  $p^*$  hlavných komponentov. Informácie k tejto podkapitole sú čerpané najmä z [43], [44], [49].

Na obrázku 7 je schématicky znázornená situácia, kde sa zdrojová matice dát **X** rozkladá na tzv. maticu komponentných skóre typu  $n \ x \ k$  a maticu komponentných záť aží typu  $k \ x$  $p^*$ . Pri zmene súradníc z objektov v pôvodných znakoch na objekty v hlavných komponen-



Obrázok 7: Schéma maticových výpočtov v PCA.

toch dochádza k rozdielu, teda k strate informácie projekciou do menšieho počtu rozmerov. Tento rozdiel nazývame mierou tesností zavádzania modelu PCA alebo tiež chybou modelu PCA. Jednou z najdôležitejších súčastí metódy hlavných komponentov je jej interpretácia, tj. vysvetlenie použitých hlavných komponentov, ich pomenovanie a vysvetlenie vzťahu pôvodných veličín k hlavným komponentom. Aproximácia zdrojovej matice dát  $\mathbf{X}$  má rad výhod v interpretácii dát. Jedná sa nielen o zmenu súradnicového systému, ale tiež predovšetkým o nájdenie tzv. šumu (ostatných zostávajúcich hlavných komponentov) a jeho vypustenie.

Prvky novovzniknutých matíc nazývame komponentné skóre a komponentné záť aže, ktorých význam si vysvetlíme neskôr. Vzhľ adom k tomu, že sa k rekonštrukcii všeobecne používa len  $k \ge p^*$  hlavných komponentov, prejaví sa strata informácie vznikom chybovej matice, čiže matice rezíduí **E** rozmeru  $n \ge p^*$ . Platí teda vzť ah:

$$\mathbf{X} = \mathbf{Y} \mathbf{\Omega}^T + \mathbf{E},\tag{4.1}$$

teda štruktúra dát + šum. Matica rezíduí **E** nie je objasnená modelom hlavných komponentov. Súvisí s tzv. tesnosť ou zavádzania modelu a ukazuje, ako dobre sú objekty preložené modelom hlavných komponentov.

Doteraz sme pre počet hlavných komponentov používali označenie  $j = 1, ..., p^*$ , ďalej budeme pre zjednodušenie používať označenie j = 1, ..., p, rovnako ako u pôvodných premenných.

#### 4.4 Hlavné komponenty

Z algebraického hľ adiska sú hlavné komponenty tvorené lineárnou kombináciou p náhodných veličín  $X_1, X_2, ..., X_p$ . Z geometrického hľ adiska tieto lineárne kombinácie sú osi nového súradnicového systému, ktorého dimenzia je zmenšená. Nové osi predstavujú smernice s maximálnou variabilitou a poskytujú jednoduchší a šetrný popis kovariančnej štruktúry. Metóda hlavných komponentov teda vytvorí nový systém súradníc rotáciou pôvodného systému a prevedie do neho pôvodné premenné  $X_1, X_2, ..., X_p$ . Rotáciu vykoná tým spôsobom, aby obrazy prípadov v novej súradnicovej sústave vyhovovali určitému kritériu [42], [43], [46], [47].

Majme náhodný vektor  $\mathbf{x} = (\mathbf{X}_1, \mathbf{X}_2, ..., \mathbf{X}_p)^T$ , ktorého prvky sú náhodné veličiny obsahu-

júce viacrozmerné normálne rozdelenie, nech  $\Sigma$  je kovariančná matica o hodnosti p, tj. rank ( $\Sigma$ ) = p.

Označme postupne klesajúce charakteristické čísla matice  $\Sigma$  ako  $\lambda_1 \ge \lambda_2 \ge ... \ge \lambda_p \ge 0$ a ich zodpovedajúce charakteristické vektory  $\omega_1, \omega_2, ..., \omega_p$ .

Uvažujme o lineárnej kombinácii:

T

$$Y_{1} = \boldsymbol{\omega}_{1}^{T} \mathbf{x} = \boldsymbol{\omega}_{11}X_{1} + \boldsymbol{\omega}_{12}X_{2} + \dots + \boldsymbol{\omega}_{1p}X_{p}$$

$$Y_{2} = \boldsymbol{\omega}_{2}^{T} \mathbf{x} = \boldsymbol{\omega}_{21}X_{1} + \boldsymbol{\omega}_{22}X_{2} + \dots + \boldsymbol{\omega}_{2p}X_{p}$$

$$\vdots$$

$$Y_{p} = \boldsymbol{\omega}_{p}^{T} \mathbf{x} = \boldsymbol{\omega}_{p1}X_{1} + \boldsymbol{\omega}_{p2}X_{2} + \dots + \boldsymbol{\omega}_{pp}X_{p}$$

$$(4.2)$$

Platí:

$$Var(Y_j) = \boldsymbol{\omega}_j^T \boldsymbol{\Sigma} \boldsymbol{\omega}_j = \boldsymbol{\lambda}_j \qquad j = 1, ..., p$$
(4.3)

$$Cov(Y_j, Y_k) = \boldsymbol{\omega}_j^T \boldsymbol{\Sigma} \boldsymbol{\omega}_k = 0 \qquad j, k = 1, ..., p$$
(4.4)

Uvedené nekorelované lineárne kombinácie  $Y_1, Y_2, ..., Y_p$  predstavujú hlavné komponenty, ktoré sú zoradené podľa dôležitosti, tzn. podľa klesajúceho rozptylu od najväčšieho k najmenšiemu.

**Prvý hlavný komponent** je lineárna kombinácia  $Y_1$ , kde je vektor  $\omega_1$  určený maximalizáciou rozptylu komponentov  $Y_1$ , tj.  $Var(\omega_1^T \mathbf{x})$ , cez všetky vektory  $\omega_1$  tak, aby bola splnená normalizačná podmienka  $\omega_1^T \omega_1 = 1$ . V prípade, že  $\omega_1$  je charakteristický vektor zodpovedajúci  $\lambda_1$ , pre splnenie normalizačnej podmienky je maximálna hodnota rozptylu  $Y_1$  rovná najväčšiemu charakteristickému číslu  $\lambda_1$  kovariančnej matice  $\Sigma$ . Prvý hlavný komponent, s najväčším rozptylom, teda obsahuje najviac informácií o variabilite pôvodných premenných.

**Druhý hlavný komponent** je lineárna kombinácia  $Y_2$ , ktorá maximalizuje rozptyl *Var*  $(\omega_2^T \mathbf{x})$  spĺňajúci podmienku  $\omega_2^T \omega_2 = 1$  a navyše musí byť splnená požiadavka nekorelovaní veličín  $Y_1, Y_2$  tj.  $Cov(Y_1, Y_2) = 0$ , čo zaisť uje kolmosť oboch hlavných komponentov. Druhý hlavný komponent opisuje najväčšiu časť rozptylu, ktorý neobsahuje prvý komponent.

**J-tý hlavný komponent** je analogicky lineárna kombinácia  $Y_j$ , ktorá maximalizuje rozptyl  $Var(\omega_j^T \mathbf{x})$  a spĺňa obmedzujúce podmienky  $\omega_j^T \omega_j = 1$  a  $Cov(Y_j, Y_k) = 0$  pre k < j. Najmenej informácií je teda sústredených v poslednom komponente.

Kovariančnú maticu  $\Sigma$  môžeme napísať pomocou spektrálneho rozkladu ako:

$$\Sigma = \mathbf{P} \Lambda \mathbf{P}^T = \Sigma_{j=1}^p \lambda_j \omega_j \omega_j^T, \quad \mathbf{P}^T \mathbf{P} = \mathbf{P} \mathbf{P}^T = \mathbf{I}_{(pxp)}, \tag{4.5}$$

kde

$$\Lambda_{(pxp)} = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_p \end{bmatrix}$$
(4.6)

je diagonálna matica rádu *p*, ktorá má na hlavnej diagonále všetky zostupne usporiadané charakteristické čísla matice  $\Sigma$  a  $\mathbf{P}_{(pxp)} = (\omega_1, ..., \omega_p)$  je ortogonálna matica, ktorej prvky sú ortogonálne vlastné vektory  $\Sigma$ , tj. *k*-tý stĺpec matice **P** je vlastný vektor  $\omega_k$  matice  $\Sigma$ , ktorý prislúcha vlastnému číslu  $\lambda_k$  a pre ktorý platia normalizačné podmienky  $\omega_k^T \lambda_k = 1$ .

Zo vzť ahu:

$$st(\mathbf{A}) = \sum_{i=1}^{p} a_{ii},\tag{4.7}$$

kde **A** je štvorcová matica typu pxp, stopa matice **A** (označíme  $st(\mathbf{A})$ ) vyjadruje súčet prvkov na hlavnej diagonále, plynie že:

$$st(\Sigma) = st(\mathbf{P}\Lambda\mathbf{P}^T) = st(\Lambda\mathbf{P}^T\mathbf{P}) = st(\Lambda) = \lambda_1 + \dots + \lambda_p.$$
(4.8)

Pomocou troch vzťahov ([42], s. 432), ktoré platia pre kovariančnú maticu  $\Sigma$ , si vieme overiť platnosť tvrdení 4.3 a 4.4. Tieto vyjadrujú, že hlavné komponenty sú nekorelované veličiny s variáciami rovnými vlastným číslam.

Z geometrického hľadiska predstavujú hlavné komponenty osi nového súradnicového systému. Vychádzame z modelu, v ktorom majú náhodné veličiny  $X_1, X_2, ..., X_p$  viacrozmerné normálne rozdelenie, tj. predpokladáme, že náhodný vektor  $x = (X_1, X_2, ..., X_p^T)$  má *p*-rozmerné normálne rozdelenie  $N_p(\mu, \Sigma)$ . Oblasť, v ktorej je hustota náhodného vektora konštantná má tvar elipsoidy, tj. množiny všetkých vektorov *x* takých, pre ktoré platí rovnosť:

$$(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) = c^2, \tag{4.9}$$

kde  $\Sigma^{-1}$  je inverzná matica ku kovariančnej matici  $\Sigma$ . Tieto elipsoidy sú centrované v  $\mu$ s osami  $\pm c\sqrt{\lambda_i\omega_i}$ , kde  $\lambda_i$  sú vlastné čísla matice  $\Sigma$  a  $\omega_i$  sú im prislúchajúce vlastné vektory. Bod ležiaci na *i*-tej osi elipsoidy bude mať súradnice úmerné vlastnému vektoru  $\omega_i = (\omega_{i_1}, \omega_{i_2}, ..., \omega_{i_p})^T$  v súradnicovom systéme, ktorý má počiatok v  $\mu$  a osi rovnobežné s pôvodnými osami  $X_1, X_2, ..., X_p$ . Ak položíme  $\mu = 0$ , posunie sa systém súradníc do začiatku v nule, môžeme povedať že:

$$c^2 = \mathbf{x}^T \Sigma^{-1} \mathbf{x}. \tag{4.10}$$

Ak platí pre maticu  $\Sigma$  vzť ah 4.5, tak pre inverzné maticu  $\Sigma^{-1}$  platí:

$$\Sigma^{-1} = \mathbf{P}\Lambda^{-1}\mathbf{P}^T = \sum_{j=1}^p \frac{1}{\lambda_j} \omega_j \omega_j^T.$$
(4.11)

Môžeme teda povedať, že:

$$c^{2} = \mathbf{x}^{T} \Sigma^{-1} \mathbf{x} = \frac{1}{\lambda_{1}} (\boldsymbol{\omega}_{1}^{T} \boldsymbol{x})^{2} + \frac{1}{\lambda_{2}} (\boldsymbol{\omega}_{2}^{T} \boldsymbol{x})^{2} + \dots + \frac{1}{\lambda_{p}} (\boldsymbol{\omega}_{p}^{T} \boldsymbol{x})^{2}, \qquad (4.12)$$

kde  $\boldsymbol{\omega}_1^T \mathbf{x}, ..., \boldsymbol{\omega}_p^T \mathbf{x}$  sú hlavné komponenty. S využitím 4.2 platí že:

$$c^{2} = \frac{1}{\lambda_{1}} (Y_{1})^{2} + \dots + \frac{1}{\lambda_{p}} (Y_{p})^{2}.$$
(4.13)

Táto rovnica definuje elipsoidy v súradnicovom systéme s osami  $Y_1, Y_2, ..., Y_p$  ležiacimi v smere príslušných vektorov  $\omega_1, ..., \omega_p$ . Ak je  $\lambda_1$  najväčšie vlastné číslo kovariančnej matice  $\Sigma$ , hlavná os leží v smere vektora  $\omega_1$ . Zostávajúce osi menšieho merítka sa nachádzajú v smere vlastných vektorov $\omega_2, ..., \omega_p$ . Hlavné komponenty  $Y_1, Y_2, ..., Y_p$  teda tvora osi elipsoidy konštantnej hustoty, tj. osi nového súradnicového systému.

Elipsa konštantnej hustoty pre dvojrozmerný náhodný vektor  $x = (X_1, X_2)^T$ , ktorá má počiatok v  $\mu = 0$ , je znázornená na obrázku 8. Môžeme vidieť, že hlavné komponenty  $Y_1$  a  $Y_2$  sme získali rotáciou pôvodného súradnicového systému. Korelačný koeficient  $\rho$  je tu rovný 0,75 a udáva mieru sploštenia elipsoidy (napr.  $\rho = 0$  zodpovedá kružnici, naopak  $\rho = 1$  priamke).



Obrázok 8: Elipsa konštantnej hustoty.

#### 4.4.1 Počet hlavných komponentov

Cieľ om metódy hlavných komponentov je zmestiť čo najviac informácií do niekoľ kých málo nových premenných. Všeobecne možno dosiahnuť stav, v ktorom úplný systém všetkých *p* hlavných komponentov  $Y_1, Y_2, ..., Y_p$  dokonale (bez zvyšku) vysvetlí celkový rozptyl pôvodných premenných. Keď že hľ adáme nižší rozmer dát, je vhodné, keď celkovo bude hlavných komponentov výrazne menej ako *p*. Prvé, o čo sa teda budeme vo výsledkoch zaujímať je, nakoľ ko je takáto kompresia možná a koľ ko budeme potrebovať výsledných komponentov. Hlavným zdrojom informácií o tejto problematike sú publikácie [42], [43], [47], [49].

Pre hodnotenie a usporiadanie objektov by bolo zrejme najvýhodnejšie mať iba jeden hlavný komponent, čo sa dá veľmi zriedkavo očakávať. Z hľadiska grafického zobrazenia dát by bolo vhodné mať najviac tri hlavné komponenty, ale samozrejme záleží na počte pôvodných veličín. Pre *p* komponentov platí:

$$\sigma_1^2 + \sigma_2^2 + \dots + \sigma_p^2 = \sum_{i=1}^p Var(X_i) = \lambda_1 + \dots + \lambda_p = \sum_{i=1}^p Var(Y_i), \quad (4.14)$$

to znamená, že celkový rozptyl základného súboru či pôvodných náhodných veličín  $X_1, X_2, ..., X_p$  zodpovedá celkovému rozptylu hlavných komponentov. Zo vzť ahu 4.7 plynie:

$$st(\Sigma) = \sum_{i=1}^{p} Var(X_i) = st(\Lambda) = \sum_{i=1}^{p} Var(Y_i).$$
(4.15)

**Mierou významu** (tiež označovanú ako podiel variability) *k*-teho hlavného komponentu vzhľadom k celkovému rozptylu vysvetľovaných veličín  $X_1, X_2, ..., X_p$  je podiel:

$$\frac{\lambda_k}{\lambda_1 + \lambda_2 + \dots + \lambda_p} = \frac{\lambda_k}{st(\Sigma)} = \frac{\lambda_k}{st(\Lambda)} \qquad k = 1, 2, \dots, p.$$
(4.16)

Ak súčet prvých (najvyšších) podielov variability je dostatočne blízky jednej, tj. vyjadrené v percentách 100% (zvyčajne však stačí 80% až 90%), potom môžeme bez veľkej straty informácie nahradiť pôvodných p premenných týmito prvými k hlavnými komponentmi. Vzťahy medzi pôvodnými veličinami a hlavnými komponentmi vyjadrujú nasledujúce korelačné koeficienty [42]. Povedzme, že hlavné komponenty:

$$Y_{1} = \boldsymbol{\omega}_{1}^{T} \mathbf{x}$$

$$Y_{2} = \boldsymbol{\omega}_{2}^{T} \mathbf{x}$$

$$\vdots$$

$$Y_{p} = \boldsymbol{\omega}_{p}^{T} \mathbf{x}$$
(4.17)

s kovariančnou maticou  $\Sigma$ , potom

$$\rho_{Y_i,X_k} = \frac{Cov(Y_i,X_k)}{\sqrt{Var(Y_i)}\sqrt{Var(X_k)}} = \frac{\lambda_i\omega_{ik}}{\sqrt{\lambda_i}\sqrt{\sigma_{kk}}} = \frac{\omega_{ik}\sqrt{\lambda_i}}{\sqrt{\sigma_{kk}}} \qquad i,k = 1,2,...,p$$
(4.18)

sú korelačné koeficienty medzi komponentmi  $Y_i$  a veličinami  $X_k$ , kde  $Cov(Y_i, X_k)$  je kovariancia medzi *i*-tým hlavným komponentom a *k*-tou pôvodnou veličinou.

Keď že niektoré publikácie pojmy komponentné skóre Y a komponentné záť aže (váhy)  $\Omega^T$  neuvádzajú je potrebne tieto pojmy spomenúť a vysvetliť ich význam.

**Komponentné skóre** predstavuje súradnice objektov v novom priestore definovanom hlavnými komponentmi. Jedná sa teda o hodnoty hlavných komponentov pre každý objekt, ktoré sa ďalej používajú ako vstupné dáta aj v ďalších analýzach (napríklad v analýze zhlukovej, diskriminačnej alebo mnohorozmernej regresii).

Ak označíme ako  $x_i$  vektor hodnôt *i*-tého objektu i = 1, ..., n, potom projekcie *i*-tého objektu na *j*-tom hlavnom komponente je komponentné skóre:

$$Y_{ij} = \boldsymbol{\omega}_j^T (x_i - \bar{x})$$
  $i = 1, ..., n$   $j = 1, ..., p.$  (4.19)

Každý objekt má svoj súbor komponentných skóre, pričom počet komponentných skóre v tomto súbore zodpovedá počtu hlavných komponentov. Riadky matice skóre tvoria skóre pre jeden objekt a stĺpce sú tvorené vektormi skóre, ktoré sú ortogonálne a obsahujú skóre všetkých objektov pre jeden hlavný komponent. Skóre objektov na hlavných komponentoch sa používa na vykreslenie dát do tzv. rozptylových diagramov komponentných skóre.

Matica komponentných váh  $\Omega^T$  je transformačnou maticou, ktorá prevádza pôvodné znaky zdrojovej matice *X* na hlavné komponenty. Vzťah medzi pôvodnými premennými a hlavnými komponentmi vyjadrujú **komponentné váhy** (**záťaže**).

Komponentný váhy sú prvky vektora komponentných váh (stĺpce matice komponentných váh), ktoré slúžia pre lepšie porovnanie vlastných vektorov kovariančnej matice  $\Sigma$ . Kým prvky vnútri každého vlastného vektora sú vzájomne porovnateľné, nie sú porovnateľné prvky z rôznych vlastných vektorov. Čím viac prvkov má vlastný vektor, tým sú jeho jednotlivé prvky bližšie nule. Z tohto dôvodu je pre lepšie porovnanie vhodné používať vektory komponentných váh, ktoré získame vynásobením prvkov každého vlastného vektora odmocninou príslušného vlastného čísla, tj.

$$\omega_j \sqrt{\lambda_j} \qquad j = 1, \dots, p. \tag{4.20}$$

Prvky vektora komponentných váh sú stále vlastné vektory zodpovedajúce kovariančnej matici. Rozdiel je však v tom, že sú porovnateľ né, pretože čím sú väčšie, tým väčší význam má aj zodpovedajúci hlavný komponent.

## 5 Neurónové siete

Okolo umelých neurónových sietí je sústredený veľký záujem nielen odbornej verejnosti. Simulácie týchto sietí dosahujú prekvapivo veľmi slušné výsledky. Ako už bolo povedané, umelé neurónové siete (ďalej len neurónové siete) sú zjednodušené matematické modely nervových systémov živých organizmov. Dokazujú teda schopnosť ľudského myslenia, a to učiť sa [52].

#### 5.1 História neurónových sieti

História vzniku a stále pokračujúceho vývoja neurónových sietí spadá do prvej polovice 20. storočia, kedy bola publikovaná prvá práca o neurónoch a ich modeloch američanom W. S. McCulloch. V 40. rokoch tohto storočia potom so svojím študentom W. Pitts vypracoval model neurónu, ktorý je prakticky používaný dodnes. Na základe týchto výsledkov v roku 1958 F.Rosenblatt vytvoril prvú funkčnú perceptronovú sieť. Táto sieť mala ale určitú nevýhodu, a to že nevedela klasifikovať lineárne neseparabilné problémy. Vď aka tomuto faktu záujem o neurónové siete na dlhú dobu opadol. Až v polovici 80. rokov došlo vď aka skalným priaznivcom problematiky neurónových sietí k ich pomyselnej renesancii, a to keď sa objavil prvý model viacvrstvových neurónových sietí, ktorý problém lineárnej neseparability odstránil. Vznikali aj ď alšie typy sietí, ako je Hopfieldova, Kohonenova a ď alšie [53].

## 5.2 Základné pojmy

Základným stavebným funkčným prvkom nervovej sústavy je nervová bunka, tzv. neurón. Len mozgová kôra človeka je tvorená asi 13 až 15 miliardami neurónov, z ktorých každý môže byť spojený s 5000 inými neurónmi. Neuróny sú samostatné špecializované bunky určené k prenosu, spracovaniu a uchovaniu informácií potrebných pre realizáciu životných funkcií organizmu. Štruktúra neurónu je schematicky znázornená na obrázku 9.

Neurón je prispôsobený na prenos signálov tak, že okrem vlastného tela, tzv. somatu, má aj vstupné a výstupné prenosové kanály: dendrity a axon. Z axónu zvyčajne odbočuje rad vetiev, tzv. terminálov, zakončených blanou, ktorá sa prevažne stýka s výbežkami dendritov iných neurónov. K prenosu informácie potom slúžia unikátne medzi neurónové rozhra-



Obrázok 9: Schematické znázornenie biologického neurónu.

nia, tzv. (chemické) synapsie. Miera synaptickej priepustnosti je nositeľ om všetkých význačných informácií počas celého života organizmu. Šírenie informácie je umožnené tým, že soma i axon sú obalené membránou, ktorá má schopnosť za istých okolností generovať elektrické impulzy. Tieto impulzy sú z axónu prenášané na dendrity iných neurónov synaptickými bránami, ktoré svojou priepustnosť ou určujú intenzitu podráždenia ď alších neurónov. Takto podráždené neuróny pri dosiahnutí určitej hraničné medze, tzv. prahu, samy generujú impulz a zaisť ujú tak šíreniu príslušné informácie. Po každom priechode signálu sa synaptická priepustnosť mení, čo je predpokladom pre pamäť ové schopnosti neurónov. Tiež sa prepojenie neurónov prerába počas života organizmu. V priebehu učenia sa vytvárajú nové pamäť ové stopy resp. počas zabúdania sa synaptické spoje prerušujú [54].

#### 5.2.1 Neurón

Základom matematického modelu neurónovej siete je umelý (formálny) neurón, ktorý získame preformulovaním zjednodušenej funkcie neurofyzického neurónu do matematickej reči. Jeho štruktúra je schematicky znázornená na obrázku 10.

Umelý neurón (ď alej len neurón) má N všeobecne reálnych vstupov  $x_1, ..., x_n$ , ktoré modelujú dendrity. Vstupy sú ohodnotené všeobecne reálnymi synaptickým váhami  $w_1, ..., w_n$ , ktoré určujú ich priepustnosť. V zhode s neurofyzickou motiváciou môžu byť synaptické



Obrázok 10: Schematické znázornenie umelého neurónu.

váhy záporné, čím sa vyjadruje ich inhibičný charakter.

Vážená suma vstupných hodnôt predstavuje vnútorný potenciál neurónu:

$$u = \sum_{i=1}^{n} w_i x_i.$$
 (5.1)

Hodnota vnútorného potenciálu *u* po dosiahnutí tzv. prahovej hodnoty  $\Theta$  indukuje výstup (stav) neurónu *y*, ktorý modeluje elektrický impulz axónu. Nelineárny nárast výstupnej hodnoty y = S(u) pri dosiahnutí prahovej hodnoty potenciálu  $\Theta$  je daný, tzv. aktivačnou (prenosovou) funkciou *S*.

Formálnou úpravou možno docieliť toho, že funkcia *S* bude mať nulový prah a vlastný prah neurónu budeme chápať ako váhu, tzv. bias ď alšieho formálneho vstupu s konštantnou jednotkovou hodnotou [54].

#### 5.2.2 Prenosová funkcia neurónu

Výstup z neurónu môžeme teda napísať ako:

$$y = S\left(\sum_{i=1}^{n} w_i x_i + \Theta\right).$$
(5.2)

Prenosová funkcia neurónu je funkcia, ktorá transformuje vstupný signál na výstupný signál v intervaloch o až 1 a -1 až +1. Táto funkcia môže byť skoková alebo spojitá a musí byť monotónna, tzn. že priradenie odoziev výstupu na vstup je jednoznačné. Prenosová

funkcia je teda veľmi dôležitým prvkom pri práci s neurónom. Pre správny chod neurónu a neurónových sietí je dôležité, akú prenosovú funkciu zvolíme. Prenosová funkcia udáva, aká bude odozva na výstupe na vstupný podnet. Sú rôzne druhy funkcií u ktorých všeobecne platí, že ich hodnota má byť v intervale -1 až +1 a že majú byť spojité alebo nespojité prvého rádu (binárna funkcia: 0 - 1). Voľba funkcie závisí od problému, ktorý chceme riešiť. Napríklad, ak chceme klasifikovať, či je výrobok dobrý alebo zlý, potom nám stačí binárná funkcia. Ak by sme použili funkciu spojitú, potom musíme rozhodnúť, aká jej hodnota (0,7;0,8;...) znamená dobrý a aká zlý [53].

Najpoužívanejšie typy prenosových funkcií sú:

- skoková,
- lineárna,
- logistická.

Skoková prenosová funkcia naberá iba dve diskrétne hodnoty, a to podľa toho, či je unipolárna alebo bipolárna. Unipolárna binárna skoková funkcia nadobúda hodnoty o a 1, zatiaľ čo bipolárna -1 a +1. Podobné je to aj s logistickými prenosovými funkciami. Výstupy týchto typov funkcií však nadobúdajú spojité hodnoty. Logistická sigmoida má obor hodnôt z intervalu (0;1), hyperbolický tangens má potom interval (-1;+1). Lineárna prenosová funkcia vykazuje taktiež spojitý výstup. Jej transformácia je zrejmá, že tú istú hodnotu na vstupe dáva aj na výstupe. Grafickú reprezentáciu vymenovaných prenosových funkcií znázorňuje obrázok 11.

Na výstup prenosovej funkcie neurónu má veľký vplyv jeho prah  $\Theta$ . Ten do istej miery ovplyvňuje citlivosť neurónu na vstupné podnety. Ak je prah nulový, výstup prenosovej funkcie naberá štandardné hodnoty. Ak sa ale prah nastaví na konkrétnu hodnotu, prejaví sa to na výstupe neurónu ako posunutie. Tento jav je zrejmý na nasledujúcom obrázku 12. Definovaním prahu na inú ako nulovú hodnotu, môžeme výrazne ovplyvniť správanie sa neurónu a teda aj celej siete.



Obrázok 11: Vybrané prenosové funkcie.



Obrázok 12: Vplyv zavedenia prahu na výstup prenosovej funkcie.

## 5.3 Štruktúra a funkcionalita neurónových sietí

Pre väčšiu výpočtovú silu sa neuróny usporiadavajú do sietí neurónov. Neuróny sa združujú do štruktúr a tým vlastne vytvoria špecificky previazanú sieť. Táto sieť sa väčšinou skladá z oblastí s podobnou funkcionalitou, tzv. vrstiev. Neurónová sieť je zložená z jednotlivých neurónov, ktoré sú vzájomne prepojené a to tak, že výstup jedného neurónu je vstupom do všeobecne ľubovoľ ného počtu neurónov v ďalšej vrstve. Počet neurónov v jednotlivých vrstvách a princíp ich prepojenia určuje topológiu siete [27], [28], [29]. Pre topológiu sietí platí obvykle pravidlo, že každý neurón býva spojený s každým neurónom vo vyššej vrstve. Existujú však aj výnimky, akou je napríklad Hopfieldova sieť (obrázok 13), v ktorej je spojený každý neurón sa všetkými ostatnými. Každý spoj je navyše ohodnotený váhami, ktoré môžu nadobúdať rôzne hodnoty a vyjadrujú, aký význam tento spoj má pre daný neurón. To však neznamená, že spoj s malou váhou môžeme zanedbať, pretože nevieme, aký vplyv má tento vstup na celkovú činnosť siete [53].

U viacvrstvových sieť ach platí, že prvá vrstva je vždy vetviaca, čo znamená, že neuróny vo vstupnej vrstve len distribuujú vstupné hodnoty do ďalšej vrstvy [53]. Vrstvy bezprostredne po vstupnej vrstve sú nazývané skryté vrstvy, ktorých býva vo viacvrstvovej sieti hneď niekoľ ko. Za výstupnú vrstvu býva označovaná posledná vrstva siete, ktorá na svojom výstupe predkladá výstup celej siete.

Problém vhodného počtu vrstiev u viacvrstvových sietí bol "vyriešený" až v druhej polo-



Obrázok 13: Všeobecná štruktúra viacvrstvové neurónovéj siete.

vici dvadsiateho storočia. Vlastná funkcia neurónovej siete je v podstate v transformačnej funkcii, ktorá priraďuje istému vstupnému obrazu výstupný obraz. Dôkaz matematického charakteru o takejto funkcii nebol dlho k dispozícii. Kolmogorovov teorém o riešení trinásteho Hilbertového problému aplikovaného na neurónové siete viedol k poznatku, že k aproximácii ľubovoľ nej funkcie neurónovou sieť ou stačí, aby mala minimálne tri vrstvy s odpovedajúcim počtom neurónov v každej vrstve. Bohužiaľ, dôkaz z ktorého plynie vyššie spomínaný počet vrstiev, nám nič nehovorí o počte neurónov v týchto vrstvách, ktorých počet by bol z hľadiska riešenie daného problému optimálny [53].

## 5.4 Učenie siete

Učiaca sa schopnosť neurónových sietí spočíva práve v možnosti meniť všetky váhy v sieti podľa vhodných algoritmov na rozdiel od biologických sietí, kde schopnosť sa učiť je založená na možnosti tvorby nových spojov medzi neurónmi. Fyzicky sú teda obe schopnosti učiť sa založené na rozdielnych princípoch, avšak z hľadiska logiky nie.

Algoritmus sa zvyčajne delí na dve fázy a to na fázu aktivačnú (rozhodovaciu) a adaptačnú (učiacu sa), ktoré k svojej činnosti potrebujú trénovaciu množinu. Trénovacia množina je skupina vektorov obsahujúca informácie o danom probléme pre učenie. Ak učíme sieť s učiteľ om, potom sú to dvojice vektorov vstup – výstup. Ak učíme sieť bez učiteľ a, potom trénovacia množina obsahuje len vstupné vektory. Ak používame len fázy aktivačné, potom hovoríme o rozhodovaní. Táto fáza sa používa samostatne iba vtedy, keď je sieť naučená. Cyklické striedanie oboch fáz je vlastne učenie.

Aktivačná fáza je proces, pri ktorom sa predložený vektor informácií na vstup siete prepočíta cez všetky spoje, vrátane ich ohodnotenia váhami až na výstup, kde sa objaví odozva siete na tento vektor vo forme výstupného vektora. Pri učení sa tento vektor porovná s vektorom originálnym (požadovaným, výstupným) a rozdiel medzi oboma vektormi (lokálna odchýlka – chyba) sa uloží do pamäťovej premennej.

Adaptačná fáza je proces, pri ktorom je minimalizovaná lokálna chyba siete tak, že sa prepočítavajú váhy jednotlivých spojov smerom z výstupu na vstup s cieľ om čo najväčšej podobnosti výstupnej odozvy s originálnym vektorom. Po tej sa opäť opakuje aktivačná fáza. Ďalší získaný rozdiel (lokálna odchýlka) sa pripočíta k predchádzajúcemu, atď. Ak sa týmto postupom prejde cez celú trénovaciu množinu, je hotová jedna epocha. Celej sume odchýlok za jednu epochu sa hovorí globálna odchýlka – chyba. Ak je globálna odchýlka menšia ako nami požadovaná chyba, potom sa proces učenia skončí. Z vyššie popísaného je vidieť, že proces učenia sa nie je nič iné, než prelievanie informácií zo vstupu na výstup a naopak.

To, či sa sieť naučí správnym odozvám na dané podnety, závisí na viacerých okolnostiach. Na množstve vektorov a ich veľkosti, topológii siete, odlišnosti charakteristických vlastností jednotlivých tried, príprave trénovacej množiny a iných [53].

#### 5.4.1 Algoritmus Back-Propagation

Špecifickým a v poslednej dobe často používaným algoritmom, čo sa týka učenia neurónových sietí, je tzv. Back-Propagation algoritmus – spätné šírenie (propagácia) chyby. Iteratívny gradientný algoritmus učenia, ktorý minimalizuje hodnotu chybovej funkcie.

#### **Princíp Back-Propagation:**

Adaptačný algoritmus spätného šírenia chyby je používaný v približne 80% všetkých aplikácií neurónových sietí. Samotný algoritmus obsahuje tri etapy: dopredné (feed-forward) šírenie vstupného signálu trénovacieho vzoru, spätné šírenie chyby a aktualizáciu váhových hodnôt na spojeniach.

54

#### 5 NEURÓNOVÉ SIETE

Počas dopredného šírenia signálu dostane každý neurón vo vstupnej vrstve vstupný signál a sprostredkuje jeho prenos k všetkým neurónom vnútornej vrstvy. Každý neurón vo vnútornej vrstve vypočíta svoju aktiváciu a pošle tento signál všetkým neurónom vo výstupnej vrstve. Jednotlivé neuróny vo výstupnej vrstve vypočítajú svoju aktiváciu, ktorá zodpovedá jeho skutočnému výstupu po predložení vstupného vzoru. V podstate týmto spôsobom získame odozvu neurónovej siete na vstupný podnet daný vybudením neurónov vstupnej vrstvy.

Počas adaptácie neurónovej siete metódou Back-Propagation sú porovnávané vypočítané aktivácie s definovanými výstupnými hodnotami pre každý neurón vo výstupnej vrstve a pre každý tréningový vzor. Na základe tohto porovnania je definovaná chyba neurónovej siete, pre ktorú je vypočítaný faktor  $\delta$ , ktorý zodpovedá časti chyby, ktorá sa šíri spätne z daného neurónu ku všetkým neurónom predchádzajúcej vrstvy a majú s týmto neurónom definované spojenia.

Úprava váhových hodnôt na spojenie medzi konkrétnymi neurónmi a vyššou vrstvou potom závisí na zodpovedajúcom faktore  $\delta$  a aktiváciách neurónov v danej vrstve [55].

#### **Odvodenie algoritmu Back-Propagation:**

K úspešnému naučeniu neurónovej siete (v prípade učenia s učiteľ om) je potrebná tzv. trénovacia množina. Každý vzor trénovacej množiny opisuje akým spôsobom sú vybudené neuróny vstupnej a výstupnej vrstvy. Formálne môžeme za trénovaciu množinu *T* považovať množinu prvkov (vzorov), ktoré sú definované usporiadanými dvojicami nasledujúcim spôsobom [55]:

$$T = \{x[k], d[k]\}_{k=1}^{N},$$
(5.3)

kde N je počet prvkov (dvojíc), x[k] je k-tý vstupný vzor a d[k] je k-tý výstupný vzor. Odchýlka medzi výstupnou odozvou a požadovaným originálom je daná vzťahom:

$$E(k) = \frac{1}{2} \sum_{j=1}^{m} \left[ y_k(k) - d_j(k) \right]^2,$$
(5.4)

kde  $y_j(k)$  je odozva na vstupný *k*-tý vektor a  $d_j(k)$  je požadovaný výstupný vzor. Chyba E(k) je chyba za jeden jediný vektor (*k*-tý) cez všetky jeho prvky (j = 1 až m) a na jej výpočet možno pozerať ako na prvý krok spätného chodu. Globálna chyba (chyba za celú trénovaciu

množinu, teda za jednu epochu) je potom daná vzťahom:

$$E_T = \sum_{k=1}^{N} E(k),$$
 (5.5)

kde *N* je počet dvojíc vektorov v trénovacej množine a býva tiež označovaná ako energetická funkcia. Jediný parameter (ak vynecháme prah neurónu a strmosť jeho prenosovej funkcie), ktorý možno meniť, je váha každého spoja.

K tomu, aby sme dobre rozumeli nasledujúcim odvodením, si musíme určiť všeobecnejší popis jednotlivých premenných. Pamätajme si, že  $w_{ij}^L$  je váha, ktorá je v *L*-tej vrstve, počítajúc od výstupnej vrstvy nadol smerom k vstupnej. Táto váha spája *i*-ty neurón v tejto vrstve s *j*-tým neurónom vo vrstve L + 1. Výstup z tohto *i*-tého neurónu bude  $y_i^L$  a suma vstupov:

$$\boldsymbol{\psi}_{i}^{L} = \sum_{m} \boldsymbol{y}_{m}^{L+1} \boldsymbol{w}_{m}^{L} - \boldsymbol{\Theta}_{i}^{L}, \qquad (5.6)$$

kde  $\Theta_i^L$  je prah neurónu *i* vo vrstve *L*. Pre výstupnú vrstvu teda platí L = 0, pre najbližšie nižšie L = 1, atď. Vyššie uvedená rovnica (5.6) platí pre vrstvu L = 0.

Uvažujme iba s jedeným neurónom. Ten, ako vieme, sa skladá z ohodnotených vstupov ich sumy a prenosovej funkcie. Hodnota prahu sa rovná o. Vlastná závislosť zmeny chyby na váhe je daná vzť ahom:

$$\frac{\partial E(k)}{\partial w_{ii}^0},\tag{5.7}$$

čo nám určuje lokálny gradient energetickej funkcie. Neurón sa dá rozložiť na tri časti: na vstupy ohodnotené váhami, prenosovú funkciu, rozdielom medzi výstupom a požadovanou odozvou. Premenná  $\psi$  tu zastupuje sumu všetkých vstupov,  $w_{ij}$  je príslušná váha daného spoja a  $y_i$  je výstupná hodnota prenosovej funkcie neurónu vo výstupnej vrstve:

$$\frac{\partial E(k)}{\partial w_{ij}^0} = \frac{\partial E}{\partial y_i^0} \frac{\partial y_i^0}{\partial \psi_i^0} \frac{\partial \psi_i^0}{\partial w_{ij}^0}.$$
(5.8)

Zložením týchto medzivýsledkov tak dostaneme rovnicu 5.9, kde  $\delta$  je chyba výstupného neurónu. Táto chyba, ktorá závisí aj na prenosovej funkcii neurónu, je počítaná pre každý neurón výstupnej vrstvy.

$$\frac{\partial E(k)}{\partial w_{ij}^0} = \frac{\partial E(k)}{\partial \psi_i} y_j^1 = \delta_i^0 y_j^1$$
(5.9)

Po tom, čo sme spočítali gradient chybovej funkcie, môžeme pristúpiť k výpočtu prírastku váhy tohto spoja podľa rovnice 5.10. Parameter *t* znamená všeobecne opravu váh v epoche t(0; max. epoch).

$$\Delta w_{ij}^0(t) = \eta \,\delta_i^0(t) y_i^1(t) + \mu \Delta w_{ij}^0(t-1), \tag{5.10}$$

kde  $\mu$  je momentum (zotrvačnosť) a  $\eta$  parameter učenia. Aktualizácia váh sa potom vykoná podľa nasledujúceho vzťahu [55]:

$$\Delta w_{ii}^0(t+1) = w_{ii}^0(t) + \Delta w_{ii}^0(t).$$
(5.11)

Výpočet nových váh pre ďalšie nižšie vrstvy je podobný. Musíme si ale uvedomiť, že vo vyššej vrstve môže byť viac neurónov, a preto sa bude výstup skrytého neurónu vetviť. Z tohto dôvodu je hodnota  $\delta_i^L$  daná súčtom príspevkov  $w_{ki}^{L+1}\delta_k^{L+1}$  od všetkých neurónov vyššej vrstvy siete [52].

#### 5.5 Rozdelenie sietí

Neurónové siete je možné členiť podľa mnohých rôznych kategórií. Pre pochopenie problematiky si postačí predstaviť základné aspekty, ako je počet vrstiev, štýl učenia a algoritmus učenia.

#### 5.5.1 Podľa počtu vrstiev

Podľa počtu vrstiev delíme neurónové siete na:

- siete s jednou vrstvou,
- siete s viacerými vrstvami.

Delenie podľa počtu vrstiev znamená, že rozlišujeme z koľkých vrstiev sa daná sieť skladá. Existujú siete s jednou vrstvou, s dvoma, troma a viacerými vrstvami. Siete s jednou či dvoma vrstvami bývajú väčšinou špeciálne, ako napríklad Hopfieldova či Kohonenova sieť, ktoré majú svoj špeciálny učiaci sa algoritmus a topológiu, zatiaľ čo pre siete s tromi a viac vrstvami sa zvyčajne používa klasická viacvrstvová sieť s algoritmom Back–Propagation [53].

## 5.5.2 Podľa štýlu učenia

Podľa štýlu učenia rozoznávame siete s učením:

- deterministickým,
- stochastickým.

Štýl učenia v podstate znamená, ako sa pristupuje k zisteniu váh siete. V prípade, že sa jedná o zistenie výpočtom, potom hovoríme o deterministickom štýle učenia. Ak sú však váhy získavané pomocou generátora náhodných čísel, potom hovoríme o stochastickom štýle učenia. Tento spôsob získania váh siete sa zvyčajne používa len pri štarte siete [53].

#### 5.5.3 Podľa algoritmu učenia

Podľa typu algoritmu rozlišujeme neurónové siete s učením:

- s učiteľ om,
- bez učiteľa.

Učenie neurónovej siete s učiteľ om znamená, že sa sieť snaží prispôsobiť svoju odozvu na vstupné informácie tak, aby sa jej momentálny výstup čo najviac podobal požadovanému originálu.

Učenie bez učiteľ a je proces, v ktorom sieť vychádza z informácií, ktoré sú obsiahnuté vo vstupných vektoroch [53].

# Experimentálna časť práce

# 6 Návrh metódy na klasifikáciu

Návrh metódy na klasifikáciu akustických signálov v doprave je zobrazený na obrázku 14. S touto metódou sa nám podarilo dosiahnuť najväčšiu úspešnosť klasifikácie akustického signálu.



Obrázok 14: Bloková schéma navrhnutej metódy na klasifikáciu.

Navrhnutá metóda je zložená s nasledujúcich krokov. Využitie frekvenčnej analýzy, ktorá slúži na získanie nosných frekvencii z akustického signálu. V rámci experimentov sme vyskúšali rôzne frekvenčné analýzy a postupy, z ktorých sa najlepšie osvedčili frekvenčné filtre. Hlavne kvôli ich rýchlej odozve a nižšej výpočtovej náročnosti. Vytvorením časového okna sme schopný uchovať časové zmeny signálu. Uchovanie týchto zmien je dôležité, lebo priebehy akustických signálov nie sú jednorázové udalosti, teda je potrebné uchovávať ich závislosť v časovom slede (napríklad zvuk sirény). Tiež je potrebné dáta s ktorými pracujeme redukovať a zachovať ich nosnú informáciu. Na túto redukciu bola použitá metóda hlavných komponentov. Redukcia dát je potrebná na rýchlejšie spracovanie a vyhodnotenie dát, ktoré prebieha v neurónovej sieti. Taktiež táto redukcia spôsobuje, že nie je potrebné, aby neurónová sieť bola robustná. Neurónová sieť je dopredného typu a využíva algoritmus

Back–Propagation. Avšak je možné využiť aj iné typy neurónových sietí a algoritmov. Pre jednotlivé bloky navrhnutej metódy boli vytvorené experimenty, ktoré slúžili na overenie jednotlivých krokov.

## 7 Rôzne metódy klasifikácie akustického signálu

V experimentálnej časti práce boli vyskúšané rôzne druhy experimentov, ktoré slúžili na dosiahnutie cieľ ov práce. Podstatné experimenty sú jednotlivo opísané a každý jeden experiment nás posunul bližšie k zadaným cieľ om práce. So splnením cieľ ov práce úzko súvisí aj prínos práce.

## 7.1 Klasifikácia s využitím rýchlej Fourierovej transformácie



Obrázok 15: Bloková schéma experimentu s použitím FFT.

V tomto experimente sme využili prostredie Matlab, v ktorom sme realizovali FFT na vybraných signáloch. Zamerali sme sa hlavne na analýzu jednotlivých signálov a nájdenie nosných frekvencií pre tieto signály. Na začiatok sme overili akustický signál sirény, ktorá ako vieme ma frekvenčný rozsah od 600 Hz do 1350 Hz. Týmto spôsobom sme sa mohli zamerať na parametre ako sú počet bodov FFT, aká ma byť vzorkovacia frekvencia pre signál, energia signálu a iné. Ďalším krokom v pokuse bolo tieto zistenia vyskúšať na iných signáloch ako je akustický signál stojaceho auta, motorovej píly, vetra a iné. Tento experiment zahŕňal aj to, či sme schopný nastaviť niektoré parametre (počet bodov FFT, vzorkovacia frekvencia, energia signálu a iné) tak, aby Matlab po spracovaní akustického signálu bol schopný vyhodnotiť tento signál a podľa nastavenia parametrov určil, či sa jedná o sirénu alebo iný akustický signál.

Tento experiment nám pomáha určiť, kde sa v akustickom signále nachádzajú nosné frekvencie a otestovanie týchto nosných frekvencií pre vybraný signál s parametrami: vzorkovacia frekvencia nastavená na 16kHz, počet FFT koeficientov je 80 z ktorých je potrebných len prvých 40 kvôli zrkadleniu sa signálu vo frekvenčnom spektre.

Aby sme boli schopný si tento experiment lepšie predstaviť, uvedieme ho na príklade s využitím sirény. Na obrázku 16 je zobrazený signál sirény dĺžky 3,3 minúty s jeho priebehom normovaným na intervale (-1;+1), taktiež je tu zobrazená energia signálu. Táto energia je zobrazená po blokoch o veľkosti 100 ms do ktorých bol signál rozdelený. V tomto prípade využívame energiu signálu, takým spôsobom, že ak bola energia pod prahovou hodnotu (napr. v signály sa nenachádza nosná frekvencia ale len šum) sa táto čast signálu nevyhodnotí. Posledná je zobrazená na tomto obrázku FFT celého signálu.



Obrázok 16: Dĺžka nahratého signálu sirény 3,3 minúty a jeho priebeh, energia a FFT akustického signálu.

Týmto spôsobom sme schopný určiť nosnú frekvenciu signálu, ale je potrebné tento signál ešte vyhodnotiť. Vyhodnotenie signálu sme spravili tak, aby program v Matlabe určil, kde v nahrávke sa nachádza vybraný signál. Pre FFT môžme vidieť, že nosný signál sa nachádza približne pri frekvencii 1kHz. To vieme aj z definície sirény (600 – 1350Hz).

Následne program v Matlabe určil, kedy sa tam tento signál nachádza. Tým sme overili nosnú frekvenciu signálu. Overenie bolo spustené tak, že sa pustil akustický signál a program v Matlabe nahrával pomocou mikrofónu a následne vyhodnotil, kde sa tento signál nachádza v nahrávke. Takéto vyhodnotenie je zobrazené na obrázku 17 spolu so znázorneným frekvenčným spektrom.



Obrázok 17: Spektrálna výkonová hustota sirény a otestovanie FFT pre akustický signál sirény.

## 7.2 Klasifikácia s využitím frekvenčných filtrov

Experiment vychádzal z predpokladu, že výpočet frekvenčných koeficientov pomocou FFT bude nahradený výpočtom týchto koeficientov pomocou frekvenčných filtrov. Hlavne preto, že výpočet frekvenčných koeficientov pomocou filtrov je možné realizovať rýchlejšie ako výpočet koeficientov pomocou FFT. Taktiež kvôli možnej implementácii do senzorového nodu bolo potrebné celý experiment realizovať mimo programu Matlab. Ako programovací jazyk bol zvolený jazyk C++. V prvotnom pokuse sme sa zamerali na vytvorenie podobných



Obrázok 18: Bloková schéma experimentu s použitím frekvenčných filtrov.

koeficientov ako sme to dokázali pomocou programu v Matlabe. Na obrázku 19 sú zobrazené niektoré filtre spolu s ich priebehom signálu a spektrogramom.



Obrázok 19: Zobrazené sú rôzne frekvenčné filtre, ich priebeh signálu a spektrogram, priebeh znázorňuje časový úsek sirény.

Z obrázku 19 vyplýva, že pre filter ktorý je naladený na vyššie frekvencie sa energia znižuje. Rozdelenie frekvenčného pásma bolo zvolené podobne ako pri FFT. Na pokrytie frekvenčného pásma 8 kHz sme použili 40 frekvenčných filtrov a frekvencia vzorkovania ostala nastavená na 16 kHz. Takže každý filter pokrýval pásmo 200 Hz.

Na obrázkoch 20 až 23 je zobrazený výstup z filtrov a ich následná reprezentácia pomocou FFT vo frekvenčnom spektre.

Ako bolo spomenuté na začiatku, tento experiment mal nahradiť FFT koeficienty za filtre. Čo sa nám aj podarilo. Keď sme si nastavili parameter pre intenzitu v danom frekvenčnom filtri, tak program odpovedal, že sa tam daná, resp. nosná frekvencia nachádza. Z pred-



Obrázok 20: Frekvenčný filter nastavený na frekvenciu 200 Hz a jeho výstup zobrazený pomocou FFT.



Obrázok 21: Frekvenčný filter nastavený na frekvenciu 800 Hz a jeho výstup zobrazený pomocou FFT.



Obrázok 22: Frekvenčný filter nastavený na frekvenciu 3800 Hz a jeho výstup zobrazený pomocou FFT.



Obrázok 23: Frekvenčný filter nastavený na frekvenciu 8000 Hz a jeho výstup zobrazený pomocou FFT.

chádzajúceho príkladu so sanitkou, ak berieme frekvenčný filter nastavený na 800 Hz a hodnota na výstupe filtra prekročila určitú hodnotu, program hlásil, že sa v signále práve nachádza akustický prejav sanitky. Avšak nastavenie parametrov prebiehalo tak, že užívateľ musel odhadnúť hodnoty týchto parametrov. Teda, ak bolo potrebné zmeniť frekvenciu aj hodnotu pri ktorej program hlásil, že našiel zhodu, stále to bolo na užívateľ ovi, ako to platilo pre parametre experimentu s FFT koeficientami.

## 7.3 Klasifikácia s využitím neurónovej siete

V tomto experimente sme sa zamerali na pridanie neurónovej siete, ktorá by bola schopná identifikovať jednotlivé akustické signály. Rozhodli sme sa vytvoriť dva scenáre pre experimenty. Prvý experiment pre ktorý vstupom do neurónovej siete sú FFT koeficienty (obr. 24). Druhý experiment pre ktorý vstupom budú výsledky z frekvenčných filtrov (obr. 25).



Obrázok 24: Bloková schéma experimentu s FFT koeficientami a neurónovej siete.

Ako je zobrazené na blokovej schéme experimentu pre FFT koeficienty (obr. 24) spolu s neurónovou sieť ou, úspešnosť experimentov záležala od viacerých parametrov zobrazených v tabuľ ke 2. V tabuľ ke sú hodnoty parametrov experimentu, ktorý mal najväčšiu úspešnosť, a to 95%. Tomu zodpovedá aj výsledok v blokovej schéme. Je nutné podotknúť, že tieto parametre sa každým pokusom naučiť neurónovú sieť klasifikovať akustické signály rôzne menili.

K experimentu je treba ešte dodať, že vstupné dáta sa menia každých 100 ms, a teda samotné vyhodnocovanie výsledkov prebiehalo každých 100 ms. V tomto experimente sa nám podarilo úspešne klasifikovať vstupný akusticky signál pomocou FFT koeficientov na 95%.

Ako je zobrazené na blokovej schéme experimentu pre frekvenčné filtre (obr. 25) spolu s neurónovou sieť ou, úspešnosť experimentov záležala od viacerých parametrov zobrazených v tabuľ ke 3. V tabuľ ke sú hodnoty parametrov experimentu, ktorý mal najväčšiu úspešnosť

Frekvencia vzorkovania	16 000 Hz
Počet vstupov	3
Počet FFT koeficientov	80
Počet vstupov do NN	40
Počet skrytých vrstiev NN	1
Počet neurónov v skrytej vrstve NN	64

Tabul'ka 2: Parametre experimentu s FFT koeficientami a neurónovou sieť ou.



Obrázok 25: Bloková schéma experimentu s frekvenčnými filtrami neurónovej siete.

a to 96%, čomu zodpovedá aj výsledok v blokovej schéme. Opäť je nutné podotknúť, že tieto parametre sa každým pokusom naučiť neurónovú sieť klasifikovať akustické signály rôzne menili.

V tom prípade tiež vyhodnocovanie prebiehalo každých 100 ms. Tak isto sa menili aj vstupne dáta. V tomto experimente sa nám podarilo úspešne klasifikovať vstupný akusticky signál pomocou frekvenčných filtrov na 96%.

Výsledky experimentov boli pomerne úspešné, ale nastali problémy v reálnych podmienkach. Hlavne preto, že vyhodnotenie signálu prebiehalo každých 100 ms a bolo problematické určiť, či ide o skutočný akusticky signál, ktorý sme hľadali alebo len o akustickú anomáliu, ktorá trvalá len 100 ms a potom skončila. Z tohoto dôvodu sme potrebovali za-

Frekvencia vzorkovania	16 000 Hz
Počet vstupov	3
Počet frekvenčných filtrov	80
Počet vstupov do NN	40
Počet skrytých vrstiev NN	1
Počet neurónov v skrytej vrstve NN	64

Tabul'ka 3: Parametre experimentu s frekvenčnými filtrami a neurónovou sieťou.

chovávať časovú postupnosť dát. Potrebovali sme vytvoriť ďalší experiment. Ďalším zistením pri tomto experimente bolo, že odozva frekvenčných filtrov je rýchlejšia ako výpočet FFT koeficientov. Z týchto dôvodov sme ďalej pracovali už len s frekvenčnými filtrami a vytvorili nový experiment s časovým oknom.

## 7.4 Klasifikácia s využitím časového okna

Ako sme spomenuli, je potrebné zachovávať časovú postupnosť dát a vyhodnocovať tieto dáta ako väčší celok. Bloková schéma experimentu je zobrazená na obrázku 26.



Obrázok 26: Bloková schéma experimentu s použitím banky filtrov, časovým oknom a neurónovej siete.

Z blokovej schémy experimentu je vidieť, že boli zmenené niektoré parametre. Jedná sa hlavne o zmenu vzorkovacej frekvencie signálu z 16000 Hz na 44100 Hz, a to z toho

dôvodu, aby sme mohli pokryť väčšie frekvenčné pásmo. Príkladom, prečo sme zväčšili toto frekvenčne pásmo, môže byť napríklad frekvenčná charakteristika bieleho šumu, ktorá je zobrazená na obrázku 27. Ďalšou zmenou bolo, že sme zvýšili počet filtrov z pôvodných 80 na 200, a to z dôvodu zachovania ich pásma filtrovania na približne 200 Hz. V tomto experimente sa veľkosť pásma filtrácie frekvenčných filtroch nemenila. Parametre, ktoré boli variabilné sú: robustnosť neurónovej siete (počet neurónov, počet skrytých vrstiev, atď.) a veľkosť časového okna. Všetky parametre najúspešnejšieho experimentu sú zobrazené v tabuľke 4.



Obrázok 27: Časové okno, záznam bieleho šumu, 4 sekundy.

Parametre, ktoré sme menili, boli veľkosť okna v rozmedzí 100 ms až 4 sekundy, robustnosť neurónovej siete – počet neurónov od desiatok do tisícov a počet skrytých vrstiev v rádoch jednotiek. Za predpokladu, že veľkosť časového okna nastavíme na 100 ms je možné povedať, že sa jedná o predošlý experiment s frekvenčnými filtrami. Zhodovali sa tu aj výsledky, približne 95%. Úlohou tohoto experimentu bolo vytvoriť čo najväčšie časové okno, ktoré by zachytávalo časovú postupnosť dát. Pri veľkosti časového okna 4 sekundy úspešnosť experimentu rapidne klesala. Neurónová sieť nebola schopná identifikovať jednotlivé akustické signály. Veľkosť neurónovej siete začala rapidnym spôsobom narastať a na rýchle vyhodnotenie nie je vhodné mať robustnú sieť. Preto sme sa zamerali na redukciu Tabul'ka 4: Parametre experimentu s frekvenčnými filtrami, časovým oknom a neurónovou sieť ou.

Frekvencia vzorkovania	44 100 Hz
Počet vstupov	3
Počet frekvenčných filtrov	200
Veľkosť časového okna	4 sekundy
Počet vstupov do NN	2000
Počet skrytých vrstiev NN	1
Počet neurónov v skrytej vrstve NN	240
Úspešnosť	48%

vstupných dát do neurónovej siete.

S ohľadom na tieto skutočnosti sme boli nútený zásadným spôsobom redukovať vstup do neurónovej siete a teda sme vytvorili experiment s metódou hlavných komponentov, ktorá by mala byť schopná tento vstup redukovať.

## 7.5 Klasifikácia s využitím hlavných komponentov

Experiment bol úspešný v úspešnej identifikácii viacerých signálov (nie len 3 ale už 9 vstupných akustických signálov), ale aj v redukcii nosnej informácie v dátach. Bližšie ho priblížime v jednotlivých bodoch.

Ako bolo spomenuté na konci predchádzajúceho experimentu, pridaním metódy hlavných komponentov na redukciu veľkosti vstupnej matice do neurónovej siete, sa nám podarilo uchovať nosnú informáciu signálu a aj niekoľkonásobne redukovať dáta potrebné na úspešnú identifikáciu. Bloková schéma tohto experimentu je zobrazená na obrázku 28.

#### 7.5.1 Vstupná databáza

Vstupná databáza sa vytvára náhodným prístupom k dátam, z ktorých sa naplní jedno časové okno. Náhodným prístupom sa vyplní ďalšie okno. Týmto spôsobom sa to opakuje, kým sa nevytvorí vstupný stream dát. Vytvoria sa dva náhodné vstupné streamy, a to pre testovanie a trénovanie.

V experimente bolo potrebné využívať takzvané raw dáta (dáta bez hlavičky), ktorých



Obrázok 28: Bloková schéma výsledného experimentu.

jednotlivé parametre sú zobrazené v tabuľ ke 5.

Počet kanálov	Jeden kanál (Mono)
Frekvencia vzorkovania	44100 Hz
Kódovanie	32 bit float
Poradie bitov	Little-endian

Tabul'ka 5: Parametre vstupných dát

Vytvorenie vstupných údajov pozostáva z náhodného výberu časových úsekov z jednotlivých dát zobrazených v tabuľ ke 6.

Algoritmus pristupuje náhodne k jednotlivým súborom v súboroch, náhodne si zvolí pozíciu a vyberie časový úsek (napr. 1 sec.). Takto algoritmus prechádza jednotlivé súbory, pokial' nenazbiera dostatočný počet vzoriek (napr. 60 sec.). Týmto spôsobom sú vytvorené dva súbory. Súbor na trénovanie a súbor na testovanie. Vstupný stream dát je zobrazený na obrázku 29.



Obrázok 29: Vstupný stream dát dĺžky 60 sekúnd.

rain.raw	Nahraté dáta dažďa, cca 2 minúty.
water.raw	Nahraté dáta tečúcej vody, cca 2 minúty.
wind.raw	Nahraté dáta vetra, cca 2 minúty.
leaf.raw	Nahraté dáta lístia, cca 2 minúty.
white_noise.raw	Nahraté dáta bieleho šumu, cca 2 minúty.
car.raw	Nahraté dáta auta, cca 2 minúty.
siren.raw	Nahraté dáta sirény, cca 2 minúty.
saw.raw	Nahraté dáta motorovej píly, cca 2 minúty.
PassingCars.raw	Nahraté dáta prechádzajúcich áut, cca 2 minúty.

Tabul'ka 6: Typy vstupných dát

Spektrogram k danému priebehu signálu je zobrazený na obrázku 30.



Obrázok 30: Spektrogram vstupného streamu dát dĺžky 60 sekúnd.

Počet vstupných raw dát sa v experimente menil až do štádia, ktorý je opísaný vyššie. Na začiatku experimentu sa porovnávali len tri druhy dát: siréna, píla, auto (obr. 31). Bolo to z dôvodu, že frekvenčná reprezentácia jednotlivých dát je diametrálne rozličná: auto je v zastúpení nízkych frekvencií, píla obsahuje aj vyššie harmonické zložky (prejavuje sa takmer v celom frekvenčnom spektre) a siréna obsahuje frekvencie v rozmedzí 600 – 1350 Hz s opakovaním 12 krát za minutú.

Ďalším postupom bolo pridávanie jednotlivých rozličných dát. Poslednou pridanou množinou dát bol vygenerovaný biely šum, ktorý slúži hlavne na zvýšenie nepresnosti celého vyhodnocovacieho systému.


Obrázok 31: Spektrogram auta, motorovej píly a sirény.

### 7.5.2 Frekvenčné filtre

Rezonančné filtre sa zosúlaď ujú s danou frekvenciou na ktorú sú nastavené. Sú schopné prepustiť, alebo potlačiť vybrané frekvencie. Tieto filtre sú typicky popísané ich rezonančnou frekvenciou a faktorom kvality *K*, ktorý opisuje ich ostrosť.

V našom prípade sme testovali rôzny počet rezonančných filtrov (tabuľka 7), ktoré by spracovali a rozdelili vstupné dáta do frekvenčnej oblasti.

Počet filtrov	Úspešnosť (výstup z neurónovej siete)
100	89%
160	93%
180	94%
200	98%
210	55%
220	30%
240	12%
300	11%
400	11%

Tabul'ka 7: Úspešnosť pri rôznom počte rezonančných filtrov.

Z experimentu je vidieť, že pri zvyšujúcom počte filtrov úspešnosť narastala do určitého

množstva filtrov. Následne úspešnosť začala klesať.

Šírku pásma pre jeden filter sme určili pomocou vzorkovacej frekvencie a počtu požadovaných filtrov:

$$B_w = \frac{F_{\nu_z}}{C_f},\tag{7.1}$$

kde  $B_w$  je šírka pásma pre jeden filter,  $F_{vz}$  je vzorkovacia frekvencia a  $C_f$  je počet filtrov. Z tabuľky vidieť, že najlepšie výsledky sme dosahovali pri počte filtrov 200, kde  $F_{vz} = 44100$  Hz a  $C_f = 200$ , šírka pásma pre jednotlivé filtre bola 220,5 Hz.

#### 7.5.3 Normalizácia

Výstupné dáta z filtrov je potrebné normalizovať do intervalu (-1;+1) s využitím rovnice priamky. Táto normalizácia sa vykonávala hlavne pre neurónové siete, ktoré takto rozdelené dáta ľahko spracovávajú.

### 7.5.4 Časové okno

Výstupy z filtrov sa pravidelne ukladajú, aby sme vytvorili časové okno, ktoré sa ďalej spracováva. Veľkosť časového okna je variabilná a môže sa meniť od niekoľkých ms do niekoľkých sekúnd. Napríklad od 200 ms do 4 sekúnd. V experimente sme zistili, že najlepšie výsledky získavame pri veľkosti okna 4 sekundy a dáta sa menia každých 200 ms.

### Formát časového okna

Výsledok z filtrov je uložený do vektora každých 200 ms. Týmto spôsobom sa vektory ukladajú až do požadovaného počtu 20 (20 \* 0, 2 = 4 sekundy). Na obrázkoch 32, 33 je vidieť na *x*-osi šírka okna, na *y*-osi počet filtrov a na *z*-osi ako jednotlivé filtre rezonovali zo vstupným signálom (-1;+1).

#### 7.5.5 Metóda hlavných komponentov – PCA

PCA – analýza hlavných komponentov nám slúži hlavne na redukciu dvojrozmerného priestoru s veľkým počtom prvkov na jednorozmerný priestor s pomerne malým počtom prvkov. Matica o veľkosti 2000 prvkov (časové okno 20 \* 100) sa zredukuje na vektor o veľkosti 95 prvkov.



Obrázok 32: Časové okno, dáta z píly 4 sekundy.



Obrázok 33: Časové okno, dáta sirény 4 sekundy.

Algoritmus PCA bol testovaný osobitne na dátach čísel, ktoré boli rozložené a spätne zložené s chybou 20%. Táto chyba sa môže zdať veľká. Naším cieľ om však nie je spätne zložiť pôvodný signál, ale vytvoriť jeho hlavné komponenty, ktoré budeme ď alej spracovávať. Môžeme si to predstaviť ako frekvenčné spektrum normované na intervale (-1;+1) vstupujúce do PCA. Výstupom je vektor hlavných komponentov a ich váhou pre každý komponent.

Na učenie PCA algoritmu sme využili tzv. Oja pravidlo, ktoré môžme zapísať ako:

$$\Delta w_{ij} = \eta V_i (\xi_j - \sum_{k=1}^N V_k w_{kj}),$$
(7.2)

kde  $\eta$  je rýchlosť učenia, *V* je *i*-tý neurón, *N*-rozmerný vstupný vzor  $\xi$  vytvorený z distribúcie *P*( $\xi$ ), *w*<sub>kj</sub> sú váhy synapsií od neurónu *k* ku neurónu *j*.

### 7.5.6 Neurónová sieť

Pomocou neurónovej siete sme schopný klasifikovať vstupné dáta. S ohľadom na to, že náš prístup redukuje vstupné dáta z veľkosti 44100\*4 na vektor o veľkosti 95 prvkov, nami navrhnutá neurónová sieť nemusí byť robustná, aby správne klasifikovala akustický signál. Navrhnutá neurónová sieť obsahuje jednu skrytú vrstvu. Topológia siete je nasledovná: vstupná vrstva – 95 neurónov (výstup z PCA), jedna skrytá vrstva s veľkosť ou 95 neurónov a výstupná vrstva s 9 neurónmi, ktorá prislúcha jednotlivým setom dát. Prenosová funkcia skrytej vrstvy bola zvolená funkcia hyperbolický tangens a pre výstupnú vrstvu bola zvolená lineárna funkcia. Takto navrhnutá neurónová sieť je schopná identifikovať dáta s úspešnosť ou 98%. Samozrejme, je to možné len s nastavenými parametrami na určité hodnoty. Neurónová sieť obsahuje aj parameter, tzv. trashold, ktorým regulujeme možnosť neurónovej siete rozpoznať neznámy signál. Ak sa jednotlivé pravdepodobnosti výstupov nachádzajú pod danú hodnotu, znamená to, že neurónová sieť tento signál nepozná a vyhodnotí ho ako neznámi signál.

### 7.5.7 Úspešnosť klasifikácia

Z uvedených experimentov môžeme tvrdiť, že pri parametroch uvedených v tabuľke 8 je klasifikácia úspešná.

Môžeme povedať, že úspešnosť 98% je pre naše požiadavky dostačujúca.

Počet filtrov	200
Dĺžka časového okna	4 sekundy
Počet vzoriek v časovom okne	20
Počet PCA komponentov	95
Počet skrytých vrstiev NN	1
Počet neurónov v skrytej vrstve	95
Počet klasifikovaných výstupov	9
Výsledná úspešnosť	98%

Tabul'ka 8: Výsledky experimentu klasifikácie.

Na obrázkoch 34 až 45 je zobrazená úspešnosť s meniacimi sa parametrami a úspešnosť pre jednotlivé vstupné signály.



Obrázok 34: Úspešnosť pre meniace sa parametre experimentu a fixné parametre: počet filtrov 200, počet PCA koeficientov 100 a počet neurónov v skrytej vrstve 100.



Obrázok 35: Jednotlivá úspešnosť vstupných dát s 1 sekundovým oknom pre meniace sa parametre experimentu a fixné parametre: počet filtrov 200, počet PCA koeficientov 100 a počet neurónov v skrytej vrstve 100.



Obrázok 36: Jednotlivá úspešnosť vstupných dát s 2 sekundovým oknom pre meniace sa parametre experimentu a fixné parametre: počet filtrov 200, počet PCA koeficientov 100 a počet neurónov v skrytej vrstve 100.



Obrázok 37: Jednotlivá úspešnosť vstupných dát s 4 sekundovým oknom pre meniace sa parametre experimentu a fixné parametre: počet filtrov 200, počet PCA koeficientov 100 a počet neurónov v skrytej vrstve 100.



Obrázok 38: Úspešnosť pre meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka časového okna 2 sekundy a počet vzoriek v časovom okne 20.



Obrázok 39: Jednotlivá úspešnosť vstupných dát pre 30 neurónov v skrytej vrstve pre meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka časového okna 2 sekundy a počet vzoriek v časovom okne 20.



Obrázok 40: Jednotlivá úspešnosť vstupných dát pre 90 neurónov v skrytej vrstve pre meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka časového okna 2 sekundy a počet vzoriek v časovom okne 20.



Obrázok 41: Jednotlivá úspešnosť vstupných dát pre 120 neurónov v skrytej vrstve pre meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka časového okna 2 sekundy a počet vzoriek v časovom okne 20.



Obrázok 42: Úspešnosť pre meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka časového okna 4 sekundy a počet vzoriek v časovom okne 20.



Obrázok 43: Jednotlivá úspešnosť vstupných dát pre 30 neurónov v skrytej vrstve pre meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka časového okna 4 sekundy a počet vzoriek v časovom okne 20.



Obrázok 44: Jednotlivá úspešnosť vstupných dát pre 90 neurónov v skrytej vrstve pre meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka časového okna 4 sekundy a počet vzoriek v časovom okne 20.



Obrázok 45: Jednotlivá úspešnosť vstupných dát pre 120 neurónov v skrytej vrstve pre meniace sa parametre experimentu a fixné parametre: počet filtrov 200, dĺžka časového okna 4 sekundy a počet vzoriek v časovom okne 20.

## 8 Prínos práce

Dizertačná práca sa zaoberá analýzou akustického signálu s využitím charakteristických vlastností akustického signálu v oblasti inteligentných dopravných systémov. Prínos prace spočíva hlavne:

- V analýze akustického signálu rôznymi metódami, ktoré poskytujú vhodné dáta pre spracovanie signálu.
- V kombináciách metód redukcií dát, tak aby nezanikla charakteristická informácia riešenia vybranej množiny klasifikačných úloh.
- V návrhu metódy spracovania akustického signálu. Táto metóda je vhodná na klasifikáciu zdrojov akustického signálu pri sledovaní emitovaného zvuku v cestnej prevádzke.

### Záver

V rámci práce boli testované rôzne postupy na analýzu a zistenie charakteristických vlastností rôznych akustických signálov. Uskutočnili sme experimenty, ktoré slúžili na postupnú realizáciu navrhnutej metódy. Schopnosť navrhnutej metódy je úspešne klasifikovať rozličné druhy akustického signálu. Kladnou stránkou tejto metódy je rozšírenie o ďalšie akustické signály, ktoré je schopná rozpoznávať.

Experiment s rýchlou Fourierovou transformáciu nám pomohol určiť nosné frekvencie akustického signálu. Boli sme schopný, predstaviť si, ako sú tieto signály zobrazené vo frekvenčnom spektre. Ďalším experimentom sme zistili, že rýchlosť výpočtu Fourierovej transformácie nie je dostatočný. Z toho dôvodu sme využili na transformáciu z časovej oblasti do frekvenčnej oblasti banku frekvenčných filtrov. S bankou frekvenčných filtrov dosahoval experiment rovnaké výsledky, ale rýchlejšie. Ďalej sme overili schopnosť neurónovej siete klasifikovať rôzne akustické signály vo frekvenčnej oblasti. Chýbala časová následnosť vzoriek. Pridaním časového okna do experimentu sa tento problém vyriešil. Neurónová sieť nebola schopná klasifikovať akustické signály na požadovanej úrovni. Navrhnutý experiment, ktorý zahŕňa aj redukciu dát s využitím hlavných komponentov zvýšil klasifikáciu na dostatočnú úroveň.

Prínosom práce je návrh metódy spracovania akustického signálu. Metóda je vhodná na klasifikáciu zdrojov akustického signálu pri sledovaní emitovaného zvuku v cestnej premávke. Výsledky môžu byť ďalej použité pri klasifikácii dopravného toku, riadenia križovatiek, monitorovanie vozidiel atď. Navrhnutá metóda sa sústreďuje na redukciu dát potrebných na rozpoznávanie akustického signálu pri nezníženej úspešnosti klasifikácie. Taktiež bola uskutočnená aj analýza akustického signálu a možnosti využitia jej vlastností pri klasifikácii. Čím boli ciele dizertačnej práce splnené. Či sa navrhnutá metóda klasifikácie osvedčí aj v praxi, ukáže až čas.

### Zoznam použitej literatúry

- Hodoň M., Miček J., Karpiš O., Ševčík P.: *Bezdrôtové siete senzorov a aktuátorov od teórie k aplikáciám*, ITAT, Donovaly, Slovakia, 2013. ISBN 978-1490952086.
- [2] Chovanec M., Púchyová J., Húdik M., Kochláň M.: Universal synchronization algorithm for wireless sensor networks - FUSA algorithm, FedCSIS, 2014, Warsaw, Poland: IEEE. - ISSN 2300-5963
- [3] Astapov, S.; Preden, J.S.; Suurjaak, E.: A method of real-time mobile vehicle identification by means of acoustic noise analysis implemented on an embedded device, Electronics Conference (BEC), 2012 13th Biennial Baltic, vol., no., pp.283,286, 3-5 Oct. 2012.
- [4] I.C. Perez, A-B. Garcia, J-F. Martinez, P. L. Bustos : *Wireless Sensor Network-based system for measuring and monitoring road traffic*, CollCTeR Iberoamerica, 2008.
- [5] M. Shuai, K. Xie, X. Ma, G. Song: An On-Road Wireless Sensor Network Approach for Urban Traffic State Monitoring, Proceedings of 11-th IEEE Congress on ITS, pp. 1195-1200, 2008.
- [6] V. W. S. Tang, Y. Zheng, J. Cao: An Intelligent Park Management System based on Wireless Sensor Networks, Proceedings of 1 st International Symposium on Pervasive Computing and Applications, 2006.
- [7] V.K.Boda, A. Nisipuri, I. Howitt: Considerations for a Wireless Sensor Network for Locating Parking Spaces, 2007
- [8] Y. Wen, J. L. Pan, J. F. Le: Survey on Application of Wireless Sensor Networks for Traffic Monitoring, Proceedings of International Conference on Transportation Engineering, 2007.
- [9] M. Thubaishat, Y Shang, H. Shi: Adaptive Traffic Light Control with Wireless Sensor Networks, IEEE 2007.
- [10] Ch. Savarese, J. M. Rabaey, J. Beutel: Locationing in Distributed Ad-hoc Wireless Sensor Networks, 2001.

- [11] G. Mao, B. Fidan, B. D. O. Anderson: Wireless sensor network localization techniques, p.p. 2529-2553, Computer Networks 51, 2007.
- [12] J. Elson, D. Estrin: *Time Synchronization for Wireless Sensor Networks*, Proceedings of 15th International Parallel and Distributed Proceesign Symposium, IEEE 2001.
- [13] P. Sommer, R. Wattenhofer: Gradient Clock Synchronization n Wireless Sensor Networks, Proc. IPSN09, USA 2009.
- [14] B. Sundararaman, U. Buy, A. D. Kshemkalyani: *Clock Synchronization for Wireless Sensor Networks: A Survey*, pp.281-323, Ad Hoc Networks 3, Elsevier 2005.
- [15] Miček J., Jurečka M.: Moderné prostriedky implementácie metód číslicového spracovania signálov I. Žilina : Žilinská univerzita, 2013. - ISBN 978-80-554-0714-2
- [16] Ševčík P., Kapitulík J.: Moderné prostriedky implementácie metód číslicového spracovania signálov II. Žilina : Žilinská univerzita, 2013. - ISBN 978-80-554-0676-3.
- [17] Hodoň M.: Estimation of localization parameters in positioning of dynamic objects, EURO - ŽEL, Žilina, Slovak Republic. - Brno: Tribun EU, 2011. - ISBN 978-80-263-0003-8.
- [18] Zimmermann J.: Spektrálna skladba segmentov rečového signálu, Jazyk a kultúra, čislo
   2/2010, Prešov, ISSN 1338-1148.
- [19] Everest A.F. and Pohlmann C. K.: *Master Handbook of Acoustics Fifth Edition*, ISBN 978-0-07-160333-1.
- [20] Proakis J.G., Manolakis D.G.: *Digital signal processing: principles, algorithms and applications*, Prentice Hall, 2007, ISBN 0-13-187374-1.
- [21] Steven W. Smith: *Digital Signal Processing: A Practical Guide for Engineers and Scientists*, 2002, ISBN 0-7506-7444-X.
- [22] Miček J., Kapitulík J.: Wireless sensors networks in road transportation applications, MEMSTECH 2011, Lviv - Polyana, Ukraine, 2011. - ISBN 978-966-2191-19-6.

- [23] Púchyová J., Kochláň M., Hodoň M.: Development of special smartphone-based Body Area Network - energy requirements, FedCSIS, 2013, Kraków, Poland: IEEE. - ISBN 978-1-4-673-4471-5.
- [24] Ševčík P., Kovář O.: Power unit based on supercapacitors and solar cell module, SCI-ECONF, Žilina: University of Zilina, 2013. - ISBN 978-80-554-0726-5.
- [25] Karpiš O.: Solar-cell based powering of a node for traffic monitoring, IOSR journal of engineering, 2013. - ISSN 2278-8719.
- [26] Miček J., Kapitulík J.: WSN sensor node for protected area monitoring, FedCSIS, 2012: IEEE. ISBN 978-83-60810-51-4.
- [27] R.J. Mitchell, J.M. Bishop and W. Low.: Using a genetic algorithm to find the rules of a neural network, In: R.F. Albrecht, C.R. Reeves and N.C. Steele, editors. bArtificial Neural Nets and Genetic Algorithms, pp. 664-669, Springer Verlag, Wien, 1993.
- [28] Thiyam: Evaluation of neural network based real time maximum power tracking controller for PV system, IEEE Trans. Energy Conv., 1995, 10. (2): 543-548.
- [29] Beck, S. and Ghosh, J.: Noise sensitivity of static neural network classifiers, Proceedings of SPIE Science of Artificial Neural Networks, Vol. 1709, April 1992.
- [30] Kovacs P., Samiee K.: Gabbouj, M., On application of rational Discrete Short Time Fourier Transform in epileptic seizure classification, Acoustics, Speech and Signal Processing (ICASSP), 2014 IEEE International Conference on , vol., no., pp.5839,5843, 4-9 May 2014.
- [31] Tomazic S., Znidar S.: A fast recursive STFT algorithm, Electrotechnical Conference, 1996. MELECON '96., 8th Mediterranean , vol.2, no., pp.1025,1028 vol.2, 13-16 May 1996.
- [32] Perko M., Fajfar I., Tuma T., Puhan, J.: *Fast Fourier transform computation using a digital CNN simulator*, Cellular Neural Networks and Their Applications Proceedings, 1998 Fifth IEEE International Workshop on , vol., no., pp.230,235, 14-17 Apr 1998.

- [33] Song-Nien Tang; Fu-Chiang Jan; Hui-Wen Cheng; Ching-Kai Lin; Guo-Zua Wu: Multimode Memory-Based FFT Processor for Wireless Display FD-OCT Medical Systems, Circuits and Systems I: Regular Papers, IEEE Transactions on , vol.61, no.12, pp.3394,3406, Dec. 2014.
- [34] Daubechies, I.: *The wavelet transform, time-frequency localization and signal analysis*, Information Theory, IEEE Transactions on , vol.36, no.5, pp.961,1005, Sep 1990.
- [35] Takata G.; Tahara J., Michihir, M., Tsuyoshi A., Amako K., Omori H., Yasui K.: *The time-frequency analysis of the harmonics with wavelet transform for the power electronics systems*, Power Conversion Conference, 2002. PCC-Osaka 2002. Proceedings of the , vol.2, no., pp.733,737 vol.2, 2002.
- [36] Fu-Chiang Tsui; Li, C.-C.; Mingui Sun; Sclabassi, R.J.: A comparative study of two biorthogonal wavelet transforms in time series prediction, Systems, Man, and Cybernetics, 1997. Computational Cybernetics and Simulation., 1997 IEEE International Conference on , vol.2, no., pp.1791,1796 vol.2, 12-15 Oct 1997.
- [37] Hui Li: Complex Morlet wavelet amplitude and phase map based bearing fault diagnosis, Intelligent Control and Automation (WCICA), 2010 8th World Congress on , vol., no., pp.6923,6926, 7-9 July 2010.
- [38] M. Frigo and S.G. Johnson, FFTW: an adaptive software architecture for the FFT. IEEE International Conference on Acoustics, Speech and Signal Processing, vol.3, pp.1381-1384, 1998.
- [39] H. W. Johnson and C. S. Burrus: *The design of optimal DFT algorithms using dynamic programming*, IEEE Transactions on Acoustics, Speech and Signal Processing, vol. 31, pp. 378-387, Apr. 1983.
- [40] Pavel Tišnovský: Programujeme JPEG: diskrétní kosinová transformace (DCT), http://www.root.cz/clanky/ programujeme-jpeg-diskretni-kosinova-transformace-dct/, elektronický text.

- [41] Jaroslav Reichl, Martin Všetička: Encyklopedie fyziky, Encyklopédia podlieha licencii CC, http://fyzika.jreichl.com/, elektronický text.
- [42] Johnson R. A., Wichern D. W.: Applied multivariate statistical analysis. Sixth edition, Pearson education, New Jersey, 2007.
- [43] Hebák P. a kol.: Vícerozměrné statistické metody [3]. 2. doplň. vyd. Praha: Nakladatelství Informatorium, 2007.
- [44] Meloun M., Militký J., Hill M.: Počítačová analýza vícerozměrných dat v příkladech. Academia, Praha, 2005.
- [45] Meloun M., Militký J.: Analýza vícerozměrných dat, http://centrum.tul.cz/ centrum/centrum/1Projektovani/1.2\_publikace/[1.2.37].pdf, elektronický text.
- [46] Tvrdík J.: Analýza vícerozměrných dat, Ostravská univerzita, Přírodovědecká fakulta, 2003, http://prf.osu.cz/doktorske\_studium/dokumenty/Multivariable\_ Data\_Analysis.pdf, elektronický text.
- [47] Sebera M.: Vícerozměrné statistické metody. Masarykova univerzita v Brně, Fakulta sportovních studií, 2006, http://is.muni.cz/el/1451/ja-ro2010/ bk948/sebera-vicerozmerna.pdf, elektronický text.
- [48] Meloun M., Militký J.: Metoda hlavních komponent a exploratorní analýza vícerozměrných dat, http://meloun.upce.cz/docs/publi-cation/127a.pdf, elektronický text.
- [49] Meloun M., Militký J.: Metoda hlavních komponent v laboratorní praxi, http: //meloun.upce.cz/docs/publication/127b.pdf, elektronický text.
- [50] Fritsch L.: Metoda PCA a její implementace v jazyce C++. ČVUT v Praze, Fakulta elektrotechnická, http://dsp.vscht.cz/konference\_matlab/ MA-TLAB07/prispevky/fritsch\_l/fritsch\_l.pdf, elektronický text.
- [51] Krátký M., Skopal T., Snášel V.: Efektivní vyhledávání v kolekcích obrázků tváří. VŠB – Technická univerzita Ostrava, Katedra informatiky, http://www.cs.vsb.cz/ kratky/courses/2003-04/dis/reference/effface.pdf, elektronický text.

- [52] Jirsík, V., Hráček P.: Neuronové sítě, expertní systémy a rozpoznávání řeči, Brno: VUT Brno, 106 s., elektronický text.
- [53] Zelinka I.: Umělá inteligence I, Zlín: VUT Brno, 1998, 126 s., elektronický text.
- [54] Šíma J., Neruda R.: Teoretické otázky neuronových sítí, 1. vyd. Praha: MATFYZ-PRESS, 1996, 390 s., http://www2.cs.cas.cz/~sima/kniha.pdf, elektronický text.
- [55] Volná E.: Neuronové sítě 1, 2. vyd. Ostrava: Ostravská univerzita v Ostravě, 2008, 86 s., http://albert.osu.cz/oukip/volna/materialy/NEURONOVE\_SITE\_ 1/XNES1.pdf, elektronický text.
- [56] Šnorek M.: *Neuronové sítě a neuropočítače*, Praha: Vydavateľ stvo ČVUT, 2004, 156
   s. ISBN 80-01-02549-7.

# Príloha

### Prílohy na optickom médiu:

- zdrojové kódy,
- dizertačná práca v pdf.

### Vlastné publikácie:

- Analysis and synthesis of acoustic signal in transport systems / Róbert Žalman, Jana Milanová. In: CSIT 2014 = Computer science and information technologies: proceedings of the IX international scientific and technical conference: 18–22 November 2014, Lviv, Ukraine. – Lviv: Printing Center of Publishing House of Lviv Polytechnic National University, 2014. – ISBN 978–617–607–669–8. – S. 166–167.
- The measurement of CO2 by using Yrobot platform = Meranie CO2 s využitím platformy Yrobot / Peter Šarafín, Veronika Olešnaníková and Róbert Žalman. In: Otvorený softvér vo vzdelávaní, výskume a v IT riešeniach: zborník príspevkov medzinárodnej konferencie OSSConf 2015: 1.–3. júla 2015 Žilina, Slovensko. Žilina: Žilinská univerzita, 2015. ISBN 978–80–970457–7–7. S. 89–94.
- Monitoring of CO2 amount in closed objects via WSN / Róbert Žalman, Veronika Olešnaníková, Peter Ševčík, Peter Šarafín. In: FedCSIS: proceedings of the 2015 Federated conference on Computer science and information systems: September 13–16, 2015, Łódź, Poland. – Warsaw; Los Alamitos: Polskie Towarzystwo Informatyczne; IEEE, 2015 – (Annals of computer science and information systems, Vol. 5. – ISSN 2300–5963). – ISBN 978–83–60810–65–1. – S. 1257–1260.
- Distributed sensor network for vehicles with prior right detection / Róbert Žalman, Ján Kapitulík, Michal Kochláň. In: ISCC 2015: 20th IEEE Symposium on Computers and Communications: 6–9 July 2015 Larnaca, Cyprus. – [S.I.]: IEEE, 2015. – ISBN 978–1–4673–7194–0. – USB kľúč, s. 999–1003.
- 5. Analysis of acoustic signals in the field of transport / Róbert Žalman. In: MIST 2015
   = Mathematics in Science and Technologies: proceedings of the MIST conference

2015: Fačkovské sedlo, Kľak, Slovakia. – [S.l.]: CreateSpace Independent Publishing Platform, 2015. – ISBN 978–1514866382. – [6] s.

- 6. Power consumption analysis and possibilities of energy saving in WSN applications / Veronika Olešnaníková, Peter Šarafín, Róbert Žalman, Ondrej Karpiš. In: TRANSCOM 2015: 11–th European conference of young researchers and scientists: Žilina, June 22– 24, 2015, Slovak Republic. Section 3: Information and communication technologies. – Žilina: University of Žilina, 2015. – ISBN 978–80–554–1045–6. – CD–ROM, s. 45–49.
- Analysis of acoustic signals in transport systems using WSN / Róbert Žalman, Veronika Olešnaníková, Peter Šarafín, Ján Kapitulík. In: TRANSCOM 2015: 11–th European conference of young researchers and scientists: Žilina, June 22–24, 2015, Slovak Republic. Section 3: Information and communication technologies. – Žilina: University of Žilina, 2015. – ISBN 978–80–554–1045–6. – CD–ROM, s. 105–109.
- Methods of input shapers realization / Peter Šarafín, Veronika Olešnaníková, Róbert Žalman, Peter Ševčík. In: TRANSCOM 2015: 11–th European conference of young researchers and scientists: Žilina, June 22–24, 2015, Slovak Republic. Section 3: Information and communication technologies. – Žilina: University of Žilina, 2015. – ISBN 978–80–554–1045–6. – CD–ROM, s. 84–88.
- Case–study of localization via WSN using distributed compressed sensing / Veronika Olešnaníková, Michal Kochláň, Róbert Žalman. In: FedCSIS: proceedings of the 2016 Federated conference on Computer science and information systems: September 11–14, 2016, Gdańsk, Poland. – Warsaw; Los Alamitos: Polskie Towarzystwo Informatyczne; IEEE, 2016 – (Annals of computer science and information systems, Vol. 8. – ISSN 2300–5963). – ISBN 978–83–60910–92–7. – S. 1093–1096.
- System analytics approach using wireless sensor network technologies and big data visualization for continuous assessment of air quality in a workplace environment / Judith Molka–Danielsen, Veronika Olešnaníková, Peter Šarafín, Róbert Žalman, Per Engelseth. In: NOKOBIT 2016 = Norsk konferanse for organisasjoners bruk av informasjonsteknologi. ISSN 1894–7719. Vol. 24, no. 1 (2016), online, [10] s.

11. Water level monitoring based on the acoustic signal using the neural network / Veronika Olešnaníková, Ondrej Karpiš, Michal Chovanec, Peter Šarafín, Róbert Žalman. In: Information and digital technologies 2016: proceedings of the international conference:
5–7 July 2016 Rzeszow, Poland. – [S.1.]: IEEE, 2016. – ISBN 978–1–4673–8860–3. – USB kľúč, s. 203–206.

Tabuľky s výsledkami pre niektoré experimenty:

Počet	Počet PCA	Úspešnosť
neurónov	koeficientov	[%]
30	40	71,8
30	50	92
30	60	71,8
30	70	78,4
30	80	95
30	90	66,4
30	100	75
90	40	93,6
90	50	90
90	60	86
90	70	89,4
90	80	96,6
90	90	98,2
90	100	96,8
120	40	92,4
120	50	86,8
120	60	86,6
120	70	95,2
120	80	94,6
120	90	97,2
120	100	96

Tabuľ ka 9: Tabuľ ka zobrazujúca výsledky pokusu pre nastavenie 4 sekundového okna s počtom vzoriek v časovom okne 20 a počtom filtrov 200.

Počet	Počet PCA	Úspešnosť
neurónov	koeficentov	[%]
30	40	78,6
30	50	80,8
30	60	95,2
30	70	94,4
30	80	88,6
30	90	91,6
30	100	79,2
90	40	93,6
90	50	97
90	60	96,6
90	70	97,4
90	80	94
90	90	97,2
90	100	97,8
120	40	93,4
120	50	97,6
120	60	96,4
120	70	97
120	80	96,2
120	90	97,6
120	100	97,8

Tabuľka 10: Tabuľka zobrazujúca výsledky pokusu pre nastavenie 2 sekundového okna s počtom vzoriek v časovom okne 20 a počtom filtrov 200.

Veľkosť časového okna	Počet vzoriek v časovom okne	Počet filtrov	Úspešnosť [%]
44100	1	200	63,77
44100	2	200	85,58
44100	4	200	91,16
44100	6	200	94,5978
44100	8	200	94,96
44100	10	200	95,7
44100	12	200	96,3986
44100	14	200	82,493
44100	16	200	95,36
44100	18	200	90,6306
44100	20	200	97,4
88200	2	200	87,14
88200	4	200	90,12
88200	6	200	92,8571
88200	8	200	93,12
88200	10	200	96,4
88200	12	200	93,6375
88200	14	200	82,7731
88200	16	200	94,4
88200	18	200	89,1892
88200	20	200	97

Tabuľ ka 11: Úspešnosť experimentu pri meniacich sa parametroch zobrazených v tabuľ ke, počet neurónov a počet PCA koeficientov je nastavených na 100.

Tabuľ ka 12: Pokračovanie tabuľ ky 11 úspešnosť experimentu pri meniacich sa parametroch zobrazených v tabuľ ke, počet neurónov a počet PCA koeficientov je nastavených na 100.

Veľ kosť časového okna	Počet vzoriek v časovom okne	Počet filtrov	Úspešnosť [%]
176400	2	200	87,14
176400	4	200	93
176400	6	200	94,7179
176400	8	200	96,24
176400	10	200	95,9
176400	12	200	96,6387
176400	14	200	89,3557
176400	16	200	96,96
176400	18	200	96,9369
176400	20	200	95,2