

Žilinská univerzita v Žiline

Autoreferát
DIZERTAČNEJ PRÁCE

Žilina, apríl, 2017

Ing. Róbert ŽALMAN

Žilinská univerzita v Žiline
Fakulta riadenia a informatiky

Ing. Róbert ŽALMAN

Autoreferát dizertačnej práce

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

Názov dizertačnej práce

na získanie akademického titulu „**philosophiae doctor**“ (PhD.)
v študijnom programe doktorandského štúdia

aplikovaná informatika

v študijnom odbore

9.2.9 aplikovaná informatika

Žilina, apríl, 2017

Dizertačná práca bola vypracovaná v dennej forme doktorandského štúdia na Katedre technickej kybernetiky, Fakulte riadenia a informatiky Žilinskej univerzity v Žiline

Predkladateľ	Ing. Róbert ŽALMAN Žilinská univerzita v Žiline Fakulta riadenia a informatiky Katedra technickej kybernetiky
Školiteľ	doc. Ing. Ján Kapitulík, PhD. Žilinská univerzita v Žiline Fakulta riadenia a informatiky Katedra technickej kybernetiky
Oponenti	prof. Ing. Juraj Spalek, PhD., Žilinská univerzita v Žiline Elektrotechnická fakulta Katedra riadiacich a informačných systémov Ing. Martin Hyben, PhD., Vedúci výskumník v GoodAI, Praha

Autoreferát bol rozoslaný dňa:

Obhajoba dizertačnej práce sa koná dňa o hod.
pred komisiou pre obhajobu dizertačnej práce schválenou odborovou komisiou
v študijnom odbore **9.2.9 aplikovaná informatika**, v študijnom programe **aplikovaná informatika**, vymenovanou dekanom Fakulty riadenia a informatiky
Žilinskej univerzity
v Žiline dňa

prof. Ing. Karol Matiaško, PhD.
predseda odborovej komisie

študijného programu **aplikovaná informatika**
v študijnom odbore **9.2.9 aplikovaná informatika**
Fakulta riadenia a informatiky
Žilinská univerzita
Univerzitná 8215/1
010 26 Žilina

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 niekoľkonásobnú 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

Úvod	8
1 Ciele práce	9
1.1 Analýza vlastností akustického signálu	9
1.2 Návrh metód a algoritmov efektívneho spracovania dát senzorovým uzlom	9
1.3 Návrh nových metód a algoritmov identifikácie dopravných tokov a klasifikácie zdrojov akustických signálov	9
1.4 Experimentálne overenie teoretických záverov	9
Teoretická časť	10
2 Aplikácie vo WSN sieťach	10
2.1 Požiadavky na senzorový uzol	11
2.2 Monitorovanie dopravných systémov	12
3 Spektrálna analýza akustických signálov	13
3.1 Základne vlastnosti akustického signálu	14
3.2 Fourierová transformácia	15
3.2.1 Druhy Fourierových transformácií	15
3.3 Frekvenčné filtre	15
3.3.1 Rozdelenie frekvenčných filtrov	15
3.3.2 Banka frekvenčných filtrov	16
4 Metóda hlavných komponentov	17
4.1 Ciele metódy PCA	17
5 Neurónové siete	18
5.1 Základné pojmy	18
5.1.1 Neurón	20
5.2 Učenie siete	21
5.2.1 Algoritmus Back-Propagation	21
Experimentálna časť	22
6 Návrh metódy na klasifikáciu	22

7	Rôzne metódy klasifikácie akustického signálu	23
7.1	Klasifikácia s využitím hlavných komponentov	24
7.1.1	Vstupná databáza	24
7.1.2	Frekvenčné filtre	26
7.1.3	Normalizácia	27
7.1.4	Časové okno	27
7.1.5	Metóda hlavných komponentov – PCA	29
7.1.6	Neurónová sieť	29
7.1.7	Úspešnosť klasifikácia	30
8	Prínos práce	31
	Záver	31
	Publikácie	33
	Zoznam použitej literatúry	36

Úvod

Bezdrôtovým senzorovým sieťam (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 cieľom práce zamerať sa hlavne na klasifikáciu rôznych akustických signálov. Ďalším cieľom 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 časť. V teoretickej časti sa prvá kapitola venuje cieľom práce, ktoré sú tu bližšie opísané.

Druhá kapitola sa venuje aplikáciám vo WSN sieťach, 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 ďalšie možnosti riešenia spektrálnej analýzy akustického signálu.

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

V piatej kapitole sme sa zamerali na neurónové siete, štruktúru neuró-

nových 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.

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 zreteľom 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. Cieľom experimentov bude potvrdenie, resp. vyvrátenie

nie teoretických záverov dizertačnej práce.

Teoretická časť

2 Aplikácie vo WSN sieťach

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 ďalších [2]. Všeobecne je možné konštatovať, že WSN sú použiteľné 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 ďalších.

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 aplikácií. Ak sú mobilné prvky súčasťou 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 monitorovanom 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 vysielačím výkonom, ako aj citlivosťou prijímača. Z uvedených dôvodov sa senzorový uzol zvyčajne navrhuje ako kompromisné riešenie medzi aplikačnými požiadavkami a možnosťami 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 prístupy sú uvedené v [12], [13], [14].

Ďalšie požiadavky sieťových 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 prispôbiť štýl jazdy, aby sa predišlo nehodám. Monitorovanie podmienok prostredia slúži na zhromaždenie informácií o znečistení ovzdušia: emisie CO₂, 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 odberateľom 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 možné 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 spoľahlivosť komunikácie.
- Nižší vplyv prekážok 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 vlastnosťami [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 mierne pretlak a v miestach zriedenia mierny podtlak. Tak vznikajú tlakové vlny, ktoré vyvolávajú sluchový vnem. Pri ich šírení je im kladený odpor a tak hlasitosť s narastajúcou vzdialenosťou 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_z – Rýchlosť šírenia zvukových vln: 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 transformácií a iných operácií.

3.2 Fourierová transformácia

Fourierová transformácia je integrálna transformácia prevádzajúca signál z časovej oblasti do frekvenčnej oblasti so 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 transformácia (STFT),
- a iné.

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 (číslícové):

- 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 čitateľa prenosu), teda tento filter je vždy stabilný. IIR filter má nuly, aj póly (korene menovateľa prenosu). Môže byť nestabilný, ak sú póly mimo jednotkovej kružnice. FIR filter je ľahko realizovateľný, 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 priepust,
- Plno-priepustný.

Každý navrhnutý filter má svoj rád. Rád filtra (rád modelu) určuje, s akou vernosťou (presnosťou) sú modelované vlastnosti filtra.

3.3.2 Banka frekvenčných filtrov

Pod pojmom banka frekvenčných filtrov rozumieme množinu frekvenčných filtrov, napríklad typu pásmová priepust, ktoré prepúšťajú 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 podľa 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.

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 štatistik 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 vzťahov 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 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 zobrazovanie 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].

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 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




Figure 1: Schematické znázornenie biologického neurónu.

prenosu, spracovaniu a uchovaniu informácií potrebných pre realizáciu životných funkcií organizmu. Štruktúra neurónu je schematicky znázornená na obrázku 1.

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 rozhrania, tzv. (chemické) synapsie. Miera synaptickej priepustnosti je nositeľom 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 priepustnosťou určujú intenzitu podráždenia ďalších neurónov. Takto podráždené neuróny pri dosiahnutí určitej hraničnej medze, tzv. prahu, samy generujú impulz a zaisťujú tak šíreniu príslušné informácie. Po každom priechode signálu sa synaptická priepustnosť mení, čo je predpokladom pre pamäťové schopnosti neurónov. Tiež sa prepojenie neurónov prerába počas života organizmu. V priebehu učenia sa vytvárajú nové pamäťové stopy resp. počas zabúdania sa synaptické spoje prerušujú [54].




Figure 2: Schematické znázornenie umelého neurónu.

5.1.1 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 2.

Umelý neurón (ďalej len neurón) má N všeobecne reálnych vstupov $x_1, \dots, x_n$, ktoré modelujú dendrity. Vstupy sú ohodnotené všeobecne reálnymi synaptickým váhami $w_1, \dots, w_n$, ktoré určujú ich priepustnosť. V zhode s neurofyzickou motiváciou môžu byť synaptické váhy záporné, čím sa vyjadruje ich inhibičný charakter.

Vážená suma vstupných hodnôt predstavuje vnútorný potenciál neurónu:

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

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

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

5.2 Učenie siete

Učiaci 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 (rozhodovacia) a adaptačnú (učiacu sa), ktoré k svojej činnosti potrebujú tréningovú množinu. Trénovacia množina je skupina vektorov obsahujúca informácie o danom probléme pre učenie. Ak učíme sieť s učiteľom, potom sú to dvojice vektorov vstup – výstup. Ak učíme sieť bez učiteľa, potom trénovacia množina obsahuje len vstupné vektory. Ak používame len fázu aktivačnú, 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 cieľom 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. Celý súčet 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].

5.2.1 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 neuronových sietí. Samotný algoritmus obsahuje tri etapy: dopredné (feed-forward) šírenie vstupného signálu tréningového vzoru, spätné šírenie chyby a aktualizáciu váhových hodnôt na spojeniach.

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 neuronovej siete na vstupný podnet daný vybudením neurónov vstupnej vrstvy.

Počas adaptácie neuronovej 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 neuronovej siete, pre ktorú je vypočítaný faktor δ , ktorý zodpovedá časti chyby, ktorá sa šíri späť 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 δ a aktiváciách neurónov v danej vrstve [55].

Experimentálna časť

6 Návrh metódy na klasifikáciu

Návrh metódy na klasifikáciu akustických signálov v doprave je zobrazený na obrázku 3. S touto metódou sa nám podarilo dosiahnuť najväčšiu úspešnosť klasifikácie akustického signálu.

Navrhnutá metóda je zložená s nasledujúcich krokov. Využitie frekvenčnej analýzy, ktorá slúži na získanie nosných frekvencií z akustického signálu. V rámci experimentov sme vyskúšali rôzne frekvenčné analýzy a postupy, z ktorých sa najlepšie osvedčili frekvenčné filtre. Hlavne kvôli




Figure 3: Bloková schéma navrhutej metódy na klasifikáciu.

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 redukciiu 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 navrhutej 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 cieľov práce. Vykonané experimenty sú:

- Klasifikácia s využitím rýchlej Fourierovej transformácie.
- Klasifikácia s využitím frekvenčných filtrov.

- Klasifikácia s využitím neurónovej siete:
 - vstupom do neurónovej siete sú FFT koeficienty,
 - vstupom do neurónovej siete sú výsledky z frekvenčných filtrov.
- Klasifikácia s využitím časového okna.
- Klasifikácia s využitím hlavných komponentov.

Každý jeden experiment nás posunul bližšie k zadaným cieľom práce. So splnením cieľov práce úzko súvisí aj prínos práce. Najúspešnejší experiment, klasifikáciu s využitím hlavných komponentov, si priblížme v nasledujúcej podkapitole.

7.1 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.

Pridaním metódy hlavných komponentov na redukcii 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 4.




Figure 4: Bloková schéma výsledného experimentu.

7.1.1 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. Vytvorí sa dva náhodné vstupné streamy, a to pre testovanie a tréovanie.

V experimente bolo potrebné využívať takzvané raw dáta (dáta bez hlavičky), ktorých jednotlivé parametre sú zobrazené v tabuľke 1.

Table 1: Parametre vstupných dát

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

Vytvorenie vstupných údajov pozostáva z náhodného výberu časových úsekov z jednotlivých dát zobrazených v tabuľke 2.

Table 2: Typy vstupných dát

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 pily, cca 2 minúty.
PassingCars.raw	Nahraté dáta prechádzajúcich áut, cca 2 minúty.

Algoritmus pristupuje náhodne k jednotlivým súborom v súboroch, náhodne si zvolí pozíciu a vyberie časový úsek (napr. 1 sec.). Takto algoritmus prechádza jednotlivé súbory, pokiaľ nenazbiera dostatočný počet vzoriek (napr. 60 sec.). Týmto spôsobom sú vytvorené dva súbory. Súbor na tréovanie a súbor na testovanie. Vstupný stream dát je zobrazený na obrázku 5.




Figure 5: Vstupný stream dát dĺžky 60 sekúnd.

Spektrogram k danému priebehu signálu je zobrazený na obrázku 6.

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. 7). 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




Figure 6: Spektrogram vstupného streamu dát dĺžky 60 sekúnd.

v celom frekvenčnom spektre) a siréna obsahuje frekvencie v rozmedzí 600 – 1350 Hz s opakovaním 12 krát za minútú.




Figure 7: Spektrogram auta, motorovej píly a sirény.

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

7.1.2 Frekvenčné filtre

Rezonančné filtre sa zosúladujú s danou frekvenciou na ktorú sú nasladené. 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 3), ktoré by spracovali a rozdelili vstupné dáta do frekvenčnej oblasti.

Z experimentu je vidieť, že pri zvyšujúcom počte filtrov úspešnosť narastala do určitého množstva filtrov. Následne úspešnosť začala klesať.

Table 3: Úspešnosť pri rôznom počte rezonančných filtrov.

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%

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

$$B_w = \frac{F_{vz}}{C_f}, \quad (2)$$

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.

7.1.3 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.

7.1.4 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 ($20 * 0,2 = 4$

Intenzita




Figure 8: Časové okno, dáta z píly 4 sekundy.

Intenzita




Figure 9: Časové okno, dáta sirény 4 sekundy.

sekundy). Na obrázkoch 8, 9 je vidieť na x -osi šírka okna, na y -osi počet filtrov a na z -osi ako jednotlivé filtre rezonovali zo vstupným signálom $(-1; +1)$.

7.1.5 Metóda hlavných komponentov – PCA

PCA – analýza hlavných komponentov nám slúži hlavne na redukcii 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.

Algoritmus PCA bol testovaný osobitne na dátach čísel, ktoré boli rozložené a spätne zložené s chybou 20%. Táto chyba sa môže zdať veľká. Naším cieľom však nie je spätne zložiť pôvodný signál, ale vytvoriť jeho hlavné komponenty, ktoré budeme ďalej 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 môžeme zapísať ako:

$$\Delta w_{ij} = \eta V_i (\xi_j - \sum_{k=1}^N V_k w_{kj}), \quad (3)$$

kde η je rýchlosť učenia, V je i -tý neurón, N -rozmerný vstupný vzor ξ vytvorený z distribúcie $P(\xi)$, w_{kj} sú váhy synapsí od neurónu k ku neurónu j .

7.1.6 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 veľkosťou 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 úspešnosťou 98%. Samozrejme, je to možné len s nastavenými parametrami na určité hodnoty. Neurónová sieť obsahuje aj parameter, tzv. trashold, ktorým regulu-

jeme 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.

7.1.7 Úspešnosť klasifikácia

Z uvedených experimentov môžeme tvrdiť, že pri parametroch uvedených v tabuľke 4 je klasifikácia úspešná.

Table 4: Výsledky experimentu klasifikácie.

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%

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

8 Prínos práce

Dizertačná práca sa zaoberá analýzou akustického signálu s využitím charakteristických vlastností akustického signálu v oblasti inteligentných dopravných systémov. Prínos práce 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 navrhutej metódy. Schopnosť navrhutej 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 transformáciou 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.

Publikácie

Vlastné publikácie:

1. 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.
2. The measurement of CO₂ by using Yrobot platform = Meranie CO₂ s využitím platformy Yrobot / Peter Šarašin, Veronika Olešnaníková and Róbert Žalman. In: Otvorený softvér vo vzdelávaní, výskume a v IT riešeníach: 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.
3. Monitoring of CO₂ amount in closed objects via WSN / Róbert Žalman, Veronika Olešnaníková, Peter Ševčík, Peter Šarašin. 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.
4. 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.l.]: 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 Šarašin, 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.
7. Analysis of acoustic signals in transport systems using WSN / Róbert Žalman, Veronika Olešnaníková, Peter Šarašin, 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.
 8. Methods of input shapers realization / Peter Šarašin, 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.
 9. Case-study of localization via WSN using distributed compressed sensing / Veronika Olešnaníková, Michal Kochláš, 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.
 10. 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 Šarašin, 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 Šarašin, Róbert Žalman. In: Information and digital technologies 2016: proceedings of the international conference: 5–7 July 2016

Rzeszow, Poland. – [S.l.]: IEEE, 2016. – ISBN 978-1-4673-8860-3.
– USB klíč, s. 203–206.

Zoznam použitej literatúry

- [1] Hodoň M., Miček J., Karpíš O., Ševčík P.: *Bezdrôtové siete senzorov a aktuátorov - od teórie k aplikáciám*, ITAT, Donovaly, Slovakia, 2013. - ISBN 978-1490952086.
- [2] Chovanec M., Púchyová J., Húdík 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 Congres 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 Proccesign 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, číslo 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*, SCIECONF, Žilina: University of Zilina, 2013. - ISBN 978-80-554-0726-5.
- [25] Karpíš 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] Thiya: *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., Michihiro, 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; Sciabassi, 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 Všeticka: *Encyklopedie fyziky*, Encyklopédia podlieha licencií 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](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_1/fritsch_1.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/efface.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: MATFYZPRESS, 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: Vydavatelstvo ČVUT, 2004, 156 s. ISBN 80-01-02549-7.