

Technická univerzita v Košiciach
Fakulta elektrotechniky a informatiky

QuoVadis Research @ FEI



ročník 2, číslo 1
Marec 2019

ISSN 2585-9587

QuoVadis Research @ FEI je vedecký časopis, ktorého obsahom sú prezentácie výsledkov vedeckého bádania v oblasti informatických a elektrotechnických vied na Fakulte elektrotechniky a informatiky Technickej univerzity v Košiciach (FEI TUKE). Časopis obsahuje plnotextové vedecké články, ktorých obsahom sú výsledky dizertačných prác doktorandov a ich školiteľov obhájených v aktuálnom období na Fakulte elektrotechniky a informatiky Technickej univerzity v Košiciach. Vedecké články prispievajú k rozšíreniu vedeckých poznatkov v odboroch informatiky a elektrotechniky. Ide o podporu a rozvoj takých odborov ako je výpočtová technika a informatika, počítačové siete, kyberbezpečnosť, mechatronika a automatizácia, kybernetika a umelá inteligencia, multimediálna telekomunikačná technika, aplikovaná informatika, počítačové modelovanie, vybrané oblasti matematiky, hospodárska informatika, elektronika, mikroelektronika a optoelektronika, spracovanie signálov, teoretická elektrotechnika, elektroenergetika a technika vysokých napätí, silnoprúdová elektrotechnika, meracie systémy v elektronike, riadenie elektrotechnickej výroby, materiály a technológie elektroniky, štruktúra a vlastnosti moderných materiálov. Prijaté rukopisy uvádzajú relevantnú medzinárodnú literatúru a popisujú nové objavy, aplikácie nových techník a metód, použitie existujúcej metodológie na nový problém, čím prispievajú k rozširovaniu základných vedeckých poznatkov v danej vednej disciplíne.

Redakčná rada

Šéfredaktor časopisu:

prof. Ing. Liberios Vokorokos, PhD.

Výkonný redaktor:

doc. Ing. Anton Baláž, PhD.

Členovia:

doc. Ing. Jaroslav Porubän, PhD.

odbor: informatika

prof. Ing. Liberios Vokorokos, PhD.

odbor: informatika, kyberbezpečnosť

prof. Ing. Peter Sinčák, CSc.

odbor: kybernetika, umelá inteligencia, inteligentné systémy, aplikovaná informatika

prof. Ing. Ján Paralič, PhD.

odbor: hospodárska informatika

prof. RNDr. Ján Plavka, CSc.

odbor: aplikovaná matematika, počítačové modelovanie

prof. Ing. Jozef Juhár, CSc.

odbor: multimediálne telekomunikácie, počítačové siete

prof. Ing. Michal Kolcun, PhD.

odbor: elektroenergetika a technika vysokých napätí

prof. Ing. Dobroslav Kováč, CSc.

odbor: teoretická elektrotechnika, automatizácia

prof. Ing. Daniela Perduková, PhD.

odbor: elektrotechnika, mechatronika, riadenie elektrotechnickej výroby

prof. Ing. Alena Pietriková, CSc.

odbor elektrotechnológie a materiály

prof. Ing. Ján Šaliga, CSc.

odbor: elektronika, spracovanie signálov, optoelektronika, meranie

prof. RNDr. Ján Ziman, CSc.

odbor: štruktúra a vlastnosti moderných materiálov

Adresa vydavateľa a redakcie: Redakcia časopisu QuoVadis Research @ FEI, Technická univerzita v Košiciach Fakulta elektrotechniky a informatiky, Letná 9, 042 00 Košice, Slovenská republika, email:quovadis@fei.tuke.sk

Obsah

Riadiaci algoritmus viacfázového meniča pre alternatívne zdroje energie	
<i>Matej Bereš, Dobroslav Kováč</i>	4-15
Vytvorenie metodiky procesu multikriteriálnej optimalizácie výrobných liniek	
<i>Ján Čabala, Ján Jadlovský</i>	15-26
Nové metódy obrazovej steganografie	
<i>Vladimír Hajduk, Dušan Levický</i>	26-36
Ovplyvňovanie nelineárnych javov v pásme C s využitím EDFA ako medzilinkového zosilňovača	
<i>Tomáš Ivaniga, Ján Turán, Ľuboš Ovseník</i>	36-47
Automatické spracovanie akustických dát pre systémy automatického rozpoznania reči	
<i>Tomáš Kocút, Jozef Juhár</i>	47-58
Fuzzy riadenie DC-DC meniča	
<i>Martin Lešo, Jaroslava Žilková</i>	58-66
Analýza názorov v konverlačnom obsahu so zameraním na slovníkový prístup	
<i>Martin Mikula, Kristína Machová</i>	66-82
Podpora rozhodovania vo vybranom logistickom procese metódami analýzy dát	
<i>Miroslava Muchová, Ján Paralič</i>	82-91
Implementácia protokolu PROPHET v prostredí OPNET s prvkami bezpečnosti	
<i>Roman Palitefka, Lubomír Doboš</i>	91-97
Videodohľadový systém s využitím optického korelátora	
<i>František Rakoci, Ľuboš Ovseník</i>	97-115
Optický korelátor v systémoch spracovania obrazu a videa	
<i>Dávid Solus, Ľuboš Ovseník</i>	115-125
Searching for Malware Markers and Malware Behavioural Patterns	
<i>Jana Št'astná, Martin Tomášek</i>	125-131
PLC Based HIL Workplace for Verification of Complex Drives Control Methods	
<i>Peter Talian, Daniela Perduková</i>	131-140

Riadiaci algoritmus viacfázového meniča pre alternatívne zdroje energie

Ing. Matej Bereš

Katedra teoretickej a priemyselnej elektrotechniky
Technická Univerzita v Košiciach, FEI
Košice, Slovensko
matej.beres@tuke.sk

prof. Ing. Dobroslav Kováč, CSc.

Katedra teoretickej a priemyselnej elektrotechniky
Technická Univerzita v Košiciach, FEI
Košice, Slovensko
dobroslav.kovac@tuke.sk

Abstrakt— Článok je venovaný novým, efektívnejším spôsobom získavania elektrickej energie z obnoviteľných zdrojov energií. V článku je v krátkosti uvedený princíp činnosti jedného z obnoviteľných zdrojov energií. Pre účely získavania energie z vybraného obnoviteľného zdroja bol navrhnutý viacvetvový DC/DC menič, ktorý je schopný pre určité podmienky prispôbiť počet vetiev, aby bola dosiahnutá maximálna účinnosť. K tomu je navrhnutý vlastný MPPT (Maximum Power Point Tracking) algoritmus. Cieľom článku je poukázať na to, že s navrhovaným obvodom je možné pracovať s vysokou účinnosťou v širokom rozsahu vstupného výkonu. Dôvod je ten, že v priebehu dňa sa maximálne množstvo energie, ktoré je možné odoberať z alternatívneho zdroja mení v širokom rozsahu. V článku je ďalej uvedený jeden príklad realizácie tohto zariadenia spolu s nameranými výsledkami, ktoré potvrdzujú teoretické predpoklady. Zariadenie je možné riadiť pomocou dvoch rôznych užívateľských prostredí, ktoré poskytujú údaje o aktuálnom stave navrhovaného obvodového riešenia.

Abstract – The article is devoted to a new, more efficient way of obtaining electricity from renewable energy sources. The article briefly explain the principle of one of the renewable energy sources. For the purpose of obtaining energy from a selected renewable source, a multi-leg DC/DC converter has been designed which can adjust the number of legs for certain conditions in order to achieve maximum efficiency. For this, a custom MPPT (Maximum Power Point Tracking) algorithm is designed. The aim of the article is to point out that with the proposed circuit solution, it is possible to work with high efficiency in a wide range of input power. The reason is that during the day the maximum amount of energy that can be taken from an alternative source varies widely. The following is an example of the realization of this device, together with the measured results confirming the theoretical assumptions. The device can be controlled using two different user environments that provide data on the current status of the proposed circuit topology.

Kľúčové slová— *alternatívne zdroje energie, DC/DC menič, DC/DC viacvetvový menič, fotovoltaické panely, MPPT algoritmus, MPP*

I. ÚVOD

So stúpajúcim počtom elektrických spotrebičov a elektrických aut, stúpa dopyt po elektrickej energii. V súčasnej dobe je prevažujúca časť elektrickej energie vyrábaná pomocou fosílnych palív. Výroba energie za pomoci fosílnych palív je po prvé škodlivá pre životné prostredie a po


druhé, tieto zdroje nie je možné obnoviť. Z toho dôvodu je potrebné, aby sa zmenil spôsob výroby elektrickej energie. Jedným z možných spôsobov je použitie takzvaných obnoviteľných zdrojov energií. Výroba energie pomocou týchto zdrojov nie je škodlivá pre životné prostredie (ak sa neuvažujú nečistoty pri ich výrobe), pretože produkcia je z obnoviteľných zdrojov, ako napríklad slnko, voda, vzduch. Dokonca niektoré krajiny vo svete sú úplne závislé na obnoviteľných zdrojov energií. Pomerne najrozšírenejšie, získavanie elektrickej energie zo slnka, je možné s použitím Fotovoltických (FV) panelov. FV panely prešli za posledné roky veľkými zmenami, ktoré prispievajú ku generovaniu energie s vyššou účinnosťou. Keďže počas roka, a ani počas jedného dňa, nie je intenzita slnečného žiarenia rovnaká, je potrebné upravovať zaťaženie FV panelov tak, aby bolo možné vždy, za každých poveternostných podmienok, odoberať maximálny výkon. Najviac, ak sú FV panely zapojené do série, môže nastať situácia, kedy viaceré panely budú kompletne zatienené. V tomto prípade nastane veľká zmena napätia. Rovnako ako pri zmene slnečného žiarenia, aj v tomto prípade, je potrebné upravovať zaťaženie FV panela. Na reguláciu zaťaženia sa najčastejšie používajú DC/DC meniče, ktoré sú riadené pomocou niektorej z metód MPPT. Keďže je pravdepodobné, že výkon sa môže v priebehu dňa výrazne meniť, tak pri terajších topológiách DC/DC meničov nastáva situácia, kedy síce FV panel pracuje v režime MPP, ale samotné meniče pracujú so zníženou účinnosťou. Je to z dôvodu, že existujúce DC/DC meniče pracujú s vysokou účinnosťou iba v určitom rozsahu vstupného výkonu. Preto sa po určitom čase prešlo na viacvetvové meniče, ktoré dokážu pracovať s vyššou účinnosťou, pri vyšších výkonoch. Dokonca, niektorí výrobcovia, aj v súčasnosti už používajú viacvetvové meniče pre účely získavania maximálneho výkonu z alternatívnych zdrojov energií. Problém však je, že takýto menič sa špecifikuje pre určitý výkon. Tieto meniče pracujú s vyššími stratami v prípade, ak je do nich dodávaný nižší výkon. Táto situácia môže nastať skoro ráno, podvečer, čiastočným zatienením a príchodom mračen. V takomto stave FV panely nedokážu produkovať dostatočné množstvo energie, aby meniče pracovali s vysokou účinnosťou. Kvôli tomu sa pristúpilo k návrhu vlastného obvodového riešenia, ktoré odstraňuje tento nedostatok.[1]

Predtým, než bude popísaný navrhovaný menič a spôsob riadenia, je vhodné uviesť základné vlastnosti FV panelov.

II. FOTOVOLTICKÝ PANEL

FV panel je tvorený z viacerých FV článkov. FV článok je v podstate polovodič s P-N prechodom, ktorý je vyrobený z dvoch rôznych vrstiev kremíka. Tieto vrstvy sú dotované nečistotami. Pri dopadaní fotónu zo slnečného žiarenia na FV článok môžu nastať rôzne situácie. Niektoré fotóny sú odrazené z kovových pásov a povrchu FV článku. Fotóny, ktoré nie sú odrazené preniknú do substrátu. Niektoré z nich, zvyčajne tie, ktoré majú menej energie, prejdú cez FV článok bez vykonania nejakého efektu. Fotóny, s energetickou úrovňou prevyšujúcou zakázané pásmo kremíka, môžu vytvoriť dvojicu elektrón-diera. Tieto dvojice sú generované na oboch stranách vrstiev PN. Minoritné náboje (elektróny vo vrstve typu P, diery vo vrstve typu N) sú rozptýlené v prechode PN a prechádzajú v opačných smeroch (elektróny k vrstve typu N, diery k vrstve typu P) pôsobením elektrického poľa vytváraného prúdom vo FV článku, ktorý je zachytávaný pomocou kovových kontaktov na oboch stranách. Takto je svetlom generovaný prúd, ktorý závisí na množstve žiarenia. Ak sú vyššie hodnoty slnečného žiarenia, potom sa do FV článku dostane viac fotónov s dostatočnou energiou k tomu, aby bolo možné vytvoriť viac dvojíc elektrón-diera, čo v končnom dôsledku zvýši schopnosť FV panela generovať vyšší prúd. [2]

Ako bolo spomenuté vyššie, tak FV panel je zostavený z viacerých FV článkov. Jeden FV článok môže byť reprezentovaný náhradným elektrickým obvodom tvoreným jednou diódou, jedným prúdovým zdrojom a dvomi rezistormi, ako je to možné vidieť na obrázku (Obr. 1).




Obr. 1 Ekvivalentná schéma FV článku

Rovnicu pre výstupný prúd FV článku je možné zostaviť pomocou prvého Kirchoffovho zákona pre ktorý platí:

$$I = I_L - I_d - I_{sh} \quad (1)$$

kde I_L reprezentuje prúd generovaný svetelným žiarením, I_D je saturačný prúd tvorený rekombináciou elektrón s dierou a I_{sh} reprezentuje tzv. unikajúci prúd v dôsledku nečistôt.


FV panely sú charakteristické svojimi parametrami. Medzi tieto parametre patrí napätie naprázdno, prúd nakrátko a bod maximálneho výkonu. Bod maximálneho výkonu je generovaný FV panelom v pracovnom bode, kedy súčin napätia a prúdu na volt-ampérovej charakteristike je maximálny. Tento bod je jedinečný. To znamená, že FV panel má iba jeden bod v celej charakteristike (v danom čase), kedy je výkon najvyšší, ako je to možné vidieť na obrázku (Obr. 2).




Obr. 2 Volt-ampérová charakteristika FV článku a jeho bod maximálneho výkonu

Medzi faktory, ktoré značne ovplyvňujú charakteristiku FV panela, patrí veľkosť intenzity slnečného žiarenia a teplota. Vplyvy slnečného žiarenia na tvar volt-ampérovej charakteristiky je možné vidieť na obrázku (Obr. 3).

Vplyv teploty na tvar volt-ampérovej charakteristiky je možné vidieť na obrázku (Obr. 4).



Obr. 3 Volt-ampérová a napätovo-výkonová charakteristika FV panela pri konštantnej teplote a štyroch stupňoch intenzity slnečného žiarenia



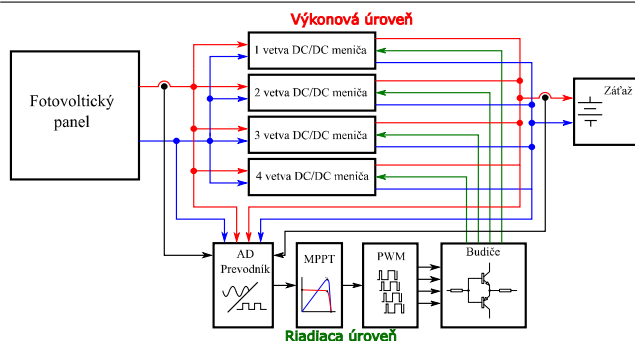
Obr. 4 Volt-ampérová a napätovo-výkonová charakteristika FV panela pri konštantnom slnečnom žiarení a štyroch zmenách teploty

Keďže nastáva zmena bodu, kedy FV panel produkuje maximálny výkon je potrebné upravovať zaťaženie panela. Reálne sa zmena zaťaženia FV panela vykonáva posúvaním pracovného bodu (striedy, tiež nazývaný aj ako činiteľ plnenia) DC/DC meniča.

Ako už bolo spomenuté, tak na zlepšenie účinnosti bolo navrhnuté vlastné obvodoové riešenie, ktoré mení počet vetiev podľa nameranej účinnosti. Navrhované obvodoové riešenie je uvedené v nasledujúcej kapitole.


III. NAVRHOVANÉ OBVODOVÉ RIEŠENIE

Navrhované obvodoové riešenie pozostáva z viacvetvového meniča, generátora fázovo posunutých signálov a snímačov vstupného a výstupného napätia a prúdu. V nasledujúcom obrázku (Obr. 5) je znázornená bloková schéma navrhovaného obvodoového riešenia.




Obr. 5 Bloková schéma navrhovaného obvodového riešenia

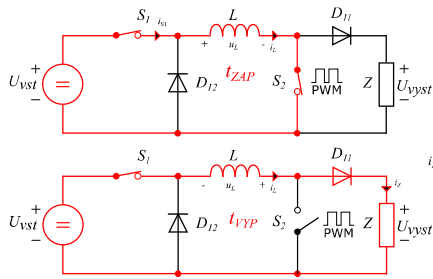
Pre širšiu oblasť využitia, bol pre každú vetvu meniča použitý zvyšovaco-znižovací menič. Konkrétne sa jedná o kaskádovité zapojenie znižovacieho a zvyšovacieho meniča. Spomínaná topológia je znázornená na obrázku (Obr. 6). [3]



Obr. 6 Navrhovaná topológia DC/DC meniča




Obr. 7 Principiálne znázornenie prvého spôsobu riadenia



Obr. 8 Principiálne znázornenie druhého spôsobu riadenia

Navrhovaná topológia napätového DC/DC meniča poskytuje viacero výhod. Jednou z nich je to, že výstupné napätie voči vstupnému nie je invertované. Pomocou tejto topológie je možné menič riadiť 3 spôsobmi. Prvý spôsob je ten, kedy spína iba spínač S_1 . V tomto prípade menič pracuje iba v znižovacom režime. Druhý spôsob riadenia je taký, kedy spína iba spínač S_2 pričom spínač S_1 musí byť neustále zopnutý.



Obr. 9 Principiálne znázornenie tretieho spôsobu riadenia

V tomto prípade menič pracuje iba vo zvyšovacom režime. Nakoniec posledný režim je taký, ktorý využíva spínanie oboch spínačov naraz. Nasledujúce obrázky (Obr. 7), (Obr. 8) a (Obr. 9) znázorňujú princíp jednotlivých režimov.


Pri každom spôsobe riadenia menič pracuje v dvoch pracovných intervaloch (Intervalu pri ktorom sa v cievke hromadí energia vo forme magnetického poľa a intervalu, kedy sa energia z indukčnosti odovzdáva do záťaže). Pre tretí spôsob riadenia platí, že pre znižovací režim je strieda $z \in (0, 0,5)$ a pre zvyšovací režim je strieda $z \in (0,5, 1)$. Nevýhodou však je užšia oblasť riadenia pre jednotlivé režimy. V prípade prvého a druhého spôsobu riadenia je možné pre zvyšovací a znižovací režim používať celý rozsah striedy. Z toho dôvodu bol prvý a druhý spôsob riadenia použitý pre riadenie tejto topológie meniča. Samozrejme s viacvetvovou verzou.

A. Návrh hardvérovej časti viacvetvového DC/DC meniča

Pri jednovetvových meničoch je potrebné venovať väčšiu pozornosť typom použitých súčiastok, pretože napríklad, spínacie súčiastky pracujúce v oblasti s vyššou frekvenciou majú vyššiu hodnotu sériového odporu kanála. To vedie k veľkým stratám a nutnosti použitia lepšieho chladenia. Na druhej strane spínacie súčiastky s malým odporom kanála majú vyššie spínacie straty z dôvodu dlhších zapínaných a vypínaných časov. Z toho dôvodu ich nie je vhodné použiť pre oblasť vyšších frekvencií. Obe nevýhody sú podstatne vykompenzované použitím viacvetvových meničov, ktorých jednotlivé tranzistory vo vetvách spínajú s fázovým posunom. Prvý fakt je, že ak spínajú s fázovým posunom, výsledná frekvencia je n - násobne vyššia, čo vedie k n - násobne nižšiemu prúdovému zvlneniu. Z toho dôvodu je možné pri uvažovaní viacerých vetiev použiť spínacie súčiastky, ktoré majú nízky odpor, ale vyššie spínacie straty. Na druhej strane je možné použiť rýchle spínacie súčiastky s vyšším odporom, pretože prúd sa rozdeľuje medzi jednotlivé vetvy meniča, a tým sa celkové straty oproti jednovetvovému znižujú kvadraticky, ako to už bolo spomenuté. Keďže spínacie súčiastky s nižším odporom sú podstatne drahšie než spínacie súčiastky s kratšou dobou zapnutia a vypnutia, ale vyšším odporom, bude navrhované riešenie obsahovať spínacie súčiastky pre oblasť vyšších frekvencií s vyšším odporom kanála.

Z hľadiska overenia platnosti vyššie uvedených tvrdení, bol navrhnutý štvorvetvový menič. Reálny model štvorvetvového meniča je znázornený na obrázku (Obr. 10).

Reálne boli jednotlivé vetvy zhotovené separátne kvôli širšej možnosti využitia.




Obr. 10 Zhotovený štvorvetvový DC/DC menič

B. Budiče pre hradlá výkonových tranzistorov

Návrhy jednotlivých vetiev meniča neobsahujú budiče pre tranzistory. Z hľadiska univerzálnosti využitia boli jednotlivé budiče na tranzistory navrhnuté na oddelené plošné spoje. Zhotovené budiče pre tranzistory sú znázornené na obrázku (Obr. 11). Kvôli ochrane riadiaceho obvodu boli budiče navrhnuté s galvanickým oddelením signálov.

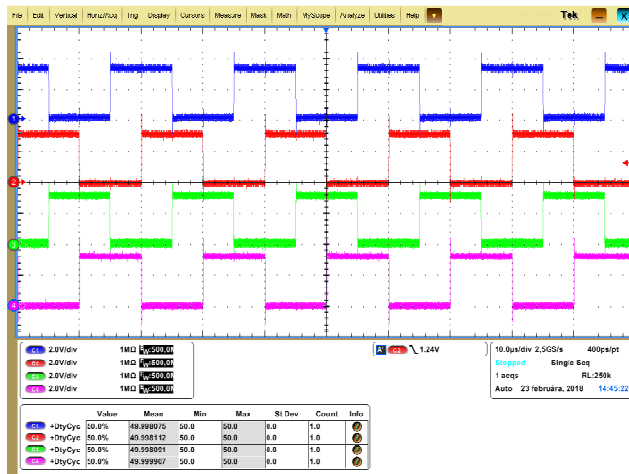
Po zhotovení navrhovaného meniča a budičov pre výkonové tranzistory sa prešlo k návrhu generátora riadiacich signálov. Podmienkou pri navrhovaní bolo vytvorenie generátora signálov s fázovým posunom T/n , kde n predstavuje počet vetiev.



Obr. 11 Ilustrácia zhotovených budičov pre výkonové MOSFET tranzistory

C. Generovanie fázovo posunutých riadiacich signálov

Pre účely generovania fázovo posunutých signálov bola použitá vývojová doska NUCLEO- F746ZG. Na generovanie štyroch fázovo posunutých signálov, boli použité 4 časovače. Každý z časovačov obsluhuje dva kanály. Prvý kanál všetkých časovačov je určený pre znižovací režim a druhý pre zvyšovací. Pre overenie správnosti fungovania generovania fázovo posunutých riadiacich signálov, boli namerané časovo závislé priebehy, ktoré sú znázornené na obrázku (Obr. 12).




Obr. 12 Namerané časové priebehy riadiacich signálov pre štyri vetvy meniča generované mikrokontrolérom, so šírkou impulzu 50%

Výhodou je flexibilita generovania signálov s možnosťou zmeny tried a počtu týchto signálov s požadovaným časovým oneskorením bez mechanického zasahovania. Vďaka tomu je možné tento spôsob generovania signálov jednoducho zakomponovať do riadiaceho algoritmu navrhovaného obvodového riešenia.


Na získavanie spätnej väzby z FV panela, ako aj aktuálnej účinnosti, je potrebné poznať hodnoty napätia a prúdu na vstupe, ako aj na výstupe meniča. K určovaniu hodnoty účinnosti je potrebné poznať vstupný aj výstupný výkon.

D. Hardvérové riešenie snímania vstupného a výstupného výkonu

Rovnako ako v prípade budičov aj v tomto prípade kvôli ochrane riadiacich obvodov boli jednotlivé signály z navrhnutých snímačov galvanicky oddelené. Keďže je potrebné merať vstupné aj výstupné napätie a prúd boli navrhnuté dva obvody. Prvý reálne zhotovený obvod je znázornený na obrázku (Obr. 13). Druhý reálne zhotovený obvod je znázornený na obrázku (Obr. 14).



Obr. 13 Zhotovený plošný spoj pre snímanie vstupného prúdu a napätia s galvanickým oddelením



Obr. 14 Zhotovená DPS pre snímanie výstupného prúdu a napätia s galvanickým oddelením

Napät'ové signály zo snímačov sú privedené do analógových vstupov zvoleného mikrokontroléra. Na meranie vstupných a výstupných veličín sú použité dva 12-bitové A/D prevodníky. Každý z prevodníkov obsluhuje dva kanály (prúd a napätie).


S takto navrhnutým hardvérovým riešením je možné pristúpiť k ďalšej časti, ktorá na základe vstupných parametrov bude vykonávať zmenu stried. Keďže FV panely majú jedno maximum, bol navrhnutý riadiaci algoritmus, ktorý nie len že upravuje pracovaný bod DC/DC meniča k tomu, aby sa dosiahol bod maximálneho výkonu, ale navyiac upravuje počet vetiev za účelom dosiahnutia najvyššej účinnosti prenosu energie do záťaže.

V nasledujúcej kapitole je uvedený navrhovaný riadiaci algoritmus.

IV. NAVRHOVANÝ ALGORITMUS RIADENIA


Za posledných 10 rokov bolo vynájdenných a publikovaných veľa metód, ktorými je možné sledovať bod maximálneho výkonu. Niektoré metódy sa líšia v rôznych aspektoch. Medzi tieto aspekty patria: množstvo použitých senzorov, zložitosť, cena, rozsah účinnosti, rýchlosť a korektnosť sledovania MPP pri zmene intenzity slnečného žiarenia a/alebo teploty a mnohé ďalšie. [3]-[9].

Navrhovaný algoritmus okrem sledovania MPP, musí byť schopný riadiť viacvetvové meniče. Preto bolo potrebné okrem návrhu MPPT algoritmu navrhnuť aj spôsob riadenia viacvetvových meničov. Hlavnou myšlienkou je navrhnuť algoritmus tak, aby bolo možné upravovať počet vetiev na základe nameranej účinnosti. Z toho dôvodu bolo potrebné navrhnuť optimálny spôsob snímania vstupného a výstupného výkonu. Skôr ako sa uvedie navrhovaný algoritmus bolo by dobré spomenúť, že experimentálne testovanie navrhovaného algoritmu bolo vykonávané za pomoci laboratórneho programovateľného zdroja HAMEG HMP4040. Samozrejme boli namerané volt ampérové charakteristiky zdroja aj FV panela. Napät'ovo výkonová charakteristika FV panela je znázornená na obrázku (Obr. 15). Skratový prúd počas merania bol 2,5A, a napätie naprázdno bolo 80V.



Obr. 15 Nameraná výkonová krivka FV panela

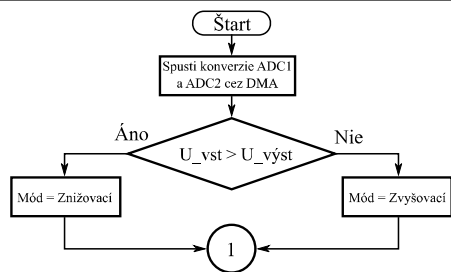
Následne bola nameraná volt ampérová charakteristika laboratórneho zdroja. Nameranú charakteristiku laboratórneho zdroja je možné vidieť na obrázku (Obr. 16).



Obr. 16 Nameraná výkonová krivka laboratórneho zdroja

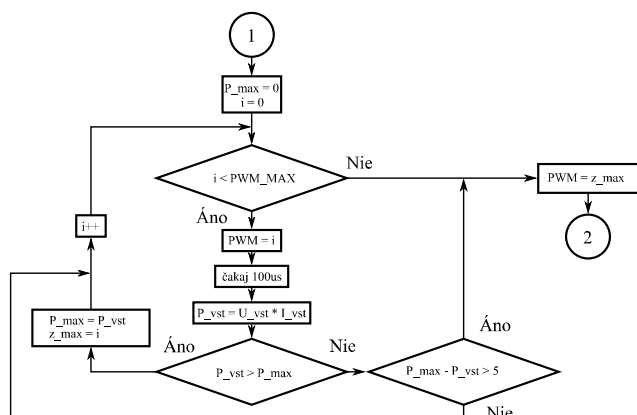
Z porovnaní oboch charakteristík je možné usúdiť, že volt ampérová charakteristika laboratórneho zdroja má veľmi podobný priebeh volt ampérovej charakteristike FV panela. Nakoľko oblasť maximálneho výkonu laboratórneho zdroja je podstatne užšia než oblasť maximálneho výkonu FV panela, je možné poznamenať, že ak navrhovaný algoritmus dokáže sledovať bod maximálneho výkonu laboratórneho zdroja, nebude mať žiadny problém sledovať bod maximálneho výkonu z FV panela. Jednou z výhod použitia laboratórneho zdroja je možnosť zmeny napätia, alebo prúdu efektívnejším spôsobom. Teda s použitím laboratórneho zdroja namiesto FV panela, je možné jednoduchšie otestovať správanie navrhovaného algoritmu pri skokových zmenách vstupného výkonu.

Pre účely testovania, bol vytvorený algoritmus riadenia viacvetvových meničov, pri ktorom je možné sledovať MPP so zmenou aj bez zmeny topológie. Navrhovaný algoritmus riadenia viacvetvových meničov je kvôli rozsiahlosti rozdelený do desiatich častí. Pre lepšiu predstavu fungovania riadiaceho procesu, boli vytvorené vývojové diagramy. Prvá časť, ako je znázornené na obrázku, (Obr. 17) sa vykonáva pri prvom spustení MPPT algoritmu.



Obr. 17 Vývojový diagram štartovacej časti navrhovaného algoritmu

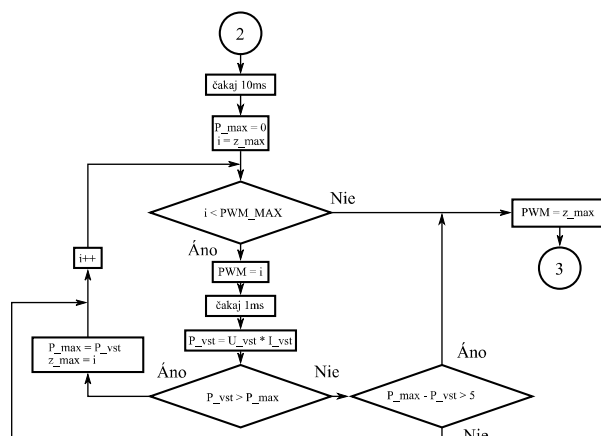
Prvá časť vývojového diagramu spustí konverzie A/D prevodníkov a následne porovná vstupné napätie z výstupným. Ak je vstupné napätie nižšie ako výstupné, menič začne pracovať vo zvyšovacom režime. Menič začne pracovať v znižovacom režime, ak je vstupné napätie vyššie ako výstupné. Po určení správneho režimu sa spustí druhá časť riadiaceho algoritmu, ktorá začína pod číslom 1. Tento algoritmus je znázornený na obrázku (Obr. 18).



Obr. 18 Vývojový diagram druhej časti navrhovaného algoritmu

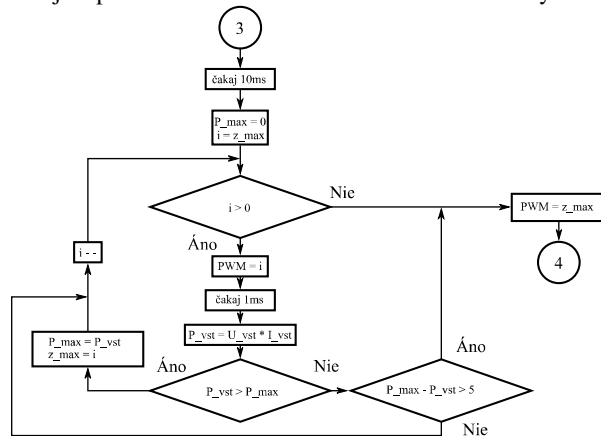
Táto časť navrhovaného algoritmu slúži pre rýchle, ale nie presné vyhľadanie MPP. Algoritmus je volaný v prípade, ak je MPPT spustený prvý raz, alebo ak nastane zmena pracovného režimu. Teda, ak prejde pracovný režim zo znižovacieho na zvyšovací a naopak. Dôvod nepresnosti je ten, že riadenie vykonáva zmenu skôr ako sa stihne načítať správna hodnota z A/D prevodníkov. Princíp činnosti je nasledujúci: Na začiatku tejto časti algoritmu sa nastaví premenná typu číslo bez znamienka (*uint*) P_{max} na nulovú hodnotu. Zároveň sa nastaví premenná rovnakého typu tiež na nulovú hodnotu. Ak je hodnota premennej i menšia ako maximálna hodnota PWM signálu (2160), tak sa nastaví šírka impulzu na hodnotu rovnú i . S malým časovým oneskorením sa načítajú vstupné veličiny (napätie a prúd) a určí sa aktuálny vstupný výkon. Následne je aktuálna hodnota vstupného výkonu porovnávaná s doteraz zaznamenanou maximálnou hodnotou vstupného výkonu. Ak je hodnota vstupného výkonu vyššia ako doposiaľ uložená hodnota maximálneho výkonu, tak sa aktuálny výkon uloží do premennej P_{max} . Zároveň sa uloží hodnota šírky impulzu (i), pri ktorej nastal tento výkon, do premennej z_{max} . Následne sa inkrementuje premenná i o 1. Premenná i sa zvyšuje pokiaľ

jej hodnota nepresiahne maximálnu hodnotu striedy, alebo pokiaľ nie je splnená druhá podmienka, kedy je výkon P_{max} vyšší ako vstupný. To znamená, že výkon sa s rastúcou hodnotou striedy začne znižovať. Čo má za následok preskočenie ďalšieho nárastu striedy. Následne sa nastaví strieda, kde bol zaznamenaný najvyšší vstupný výkon. Tento algoritmus sa vykonáva veľmi rýchlo, čo má za následok nepresnosť nájdeného MPP. Nepresnosť vykompenzuje tretia a štvrtá časť navrhovaného algoritmu. Tretia a štvrtá časť sa neustále vykonáva. Tretia časť algoritmu pracuje rovnako ako druhá časť s tým rozdielom, že pracuje pomalšie, čím sa získa vyššia presnosť. Štvrtá časť je veľmi podobná druhej a tretej časti. Rozdiel spočíva v tom, že teraz je hľadaný maximálny výkon pri znižovaní striedy. Obidva vývojové diagramy sú znázornené na obrázkoch (Obr. 19) a (Obr. 20).



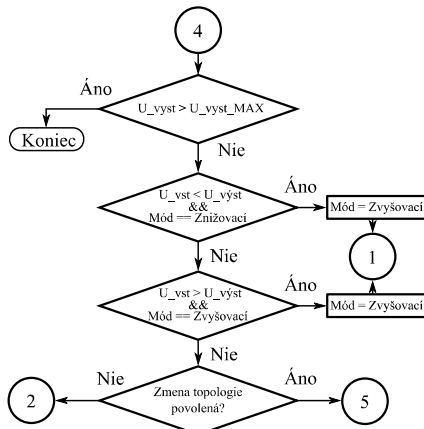
Obr. 19 Vývojový diagram tretej časti navrhovaného algoritmu

Tieto dve časti (tretia a štvrtá) sa vykonávajú podstatne pomalšie než druhá časť. Výraznejší rozdiel je aj ten, že teraz sa hľadá výkon nie od nulovej hodnoty striedy, ale od striedy, kde bol zaznamenaný posledný maximálny vstupný výkon. Keďže princíp je rovnaký, prejde sa k piatej časti (časť algoritmu začínajúca pod číslom 4). Na začiatku piateho algoritmu sa zisťuje, či výstupné napätie nepresiahlo maximálne dovolené napätie na 12V batérii. Ak áno ukončí sa nabíjací proces a zastaví sa hľadanie maximálneho výkonu.



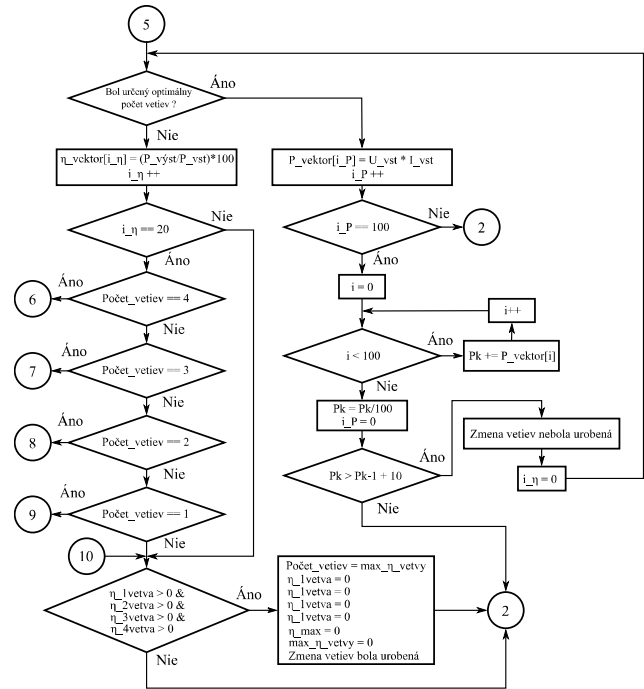
Obr. 20 Vývojový diagram štvrtej časti navrhovaného algoritmu

Ak napätie na batérií nepresiahlo maximálnu dovolenú hodnotu, pristúpi sa k druhej podmienke. Druhá podmienka platí, ak sa zmení vstupné napätie pod úroveň výstupného napätia. Následne sa upraví pracovný režim a zavolá sa funkcia rýchleho hľadania MPP. Ak druhá podmienka neplatí, pristúpi sa k tretej podmienke. Tretia podmienka platí, ak sa zmení vstupné napätie nad úroveň výstupného napätia. Následne sa upraví pracovný režim a zavolá sa funkcia rýchleho hľadania MPP. Ak neplatí ani tretia podmienka, pristúpi sa k štvrtej podmienke, ktorá zisťuje či je povolený riadiaci algoritmus so zmenou, alebo bez zmeny topológie. Ak neplatí podmienka, to znamená, že zmena topológie nie je povolená, zavolá sa tretia časť riadiaceho algoritmu. Týmto spôsobom sa neustále opakuje hľadanie maximálneho výkonu pomalším spôsobom bez zmeny topológie. Vývojový diagram piatej časti navrhovaného algoritmu je znázornený na obrázku (Obr. 21).



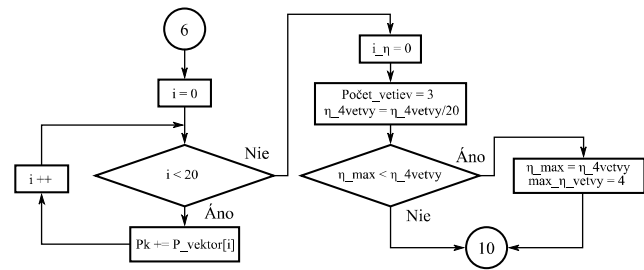
Obr. 21 Vývojový diagram piatej časti navrhovaného algoritmu

Ak je štvrtá podmienka splnená (zmena topológie povolená), pristúpi sa k šiestej časti navrhovaného algoritmu. Táto časť algoritmu hľadá optimálny počet vetiev v základe vstupného a výstupného výkonu. Princíp spočíva v tom, že sa namerajú a vypočítajú viaceré hodnoty účinnosti pre daný počet vetiev z ktorých sa vypočíta stredná hodnota. Následne sa upraví počet vetiev podľa toho, ktorý počet vetiev má pri danom výkone najvyššiu účinnosť. Tento prípad nastane, ak nie je splnená prvá podmienka vo vývojovom diagrame, ktorý je znázornený na obrázku (Obr. 22). Ak je podmienka splnená, to znamená, že už je zvolený optimálny počet vetiev pre daný výkon, bude sa okrem hľadania MPP neustále vykonávať časť algoritmu, ktorá zisťuje, či nedošlo k veľkej zmene výkonu. Ak dôjde k väčšej zmene výkonu, tak sa znova spustí hľadanie optimálneho počtu vetiev.



Obr. 22 Vývojový diagram šiestej časti navrhovaného algoritmu

Z obrázka (Obr. 22) je možné vidieť, že táto časť algoritmu sa odkazuje na ďalšie štyri časti (6, 7, 8, 9). Zvyšné časti algoritmu pracujú na rovnakom princípe. Úlohou týchto častí algoritmov je vypočítať strednú hodnotu účinnosti, a zaznamenať doterajšiu maximálnu účinnosť. Následne sa všetky zvyšné časti algoritmu odkazujú naspäť. Prepojenie medzi zvyšnými časťami algoritmu s piatou časťou algoritmu je označené pod číslom 10. Ako príklad je na nasledujúcom obrázku (Obr. 23) uvedený jeden zo štyroch algoritmov.



Obr. 23 Vývojový diagram počítania strednej hodnoty účinnosti pre štyri vetvy

Následne bolo vytvorené užívateľské prostredie, ktoré umožňuje riadiť celý proces.

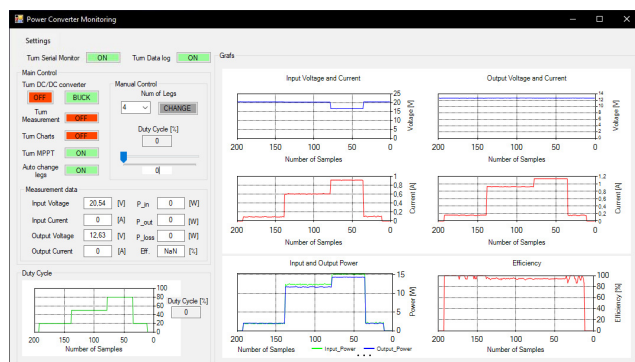
V. NÁVRH GRAFICKÉHO UŽÍVATEĽSKÉHO PROSTREDIA

Pre riadenie ako aj spätnú väzbu z navrhovaného obvodového riešenia boli vytvorené dve grafické prostredia. Prvé (obsiahlejšie) grafické prostredie je naprogramované za pomoci programovacieho jazyka C# a je určené pre PC. Druhé

grafické prostredie bolo naprogramované pre dotykový LCD (Liquid Crystal Display) displej s rozlíšením 240x400. Obe grafické prostredia umožňujú riadiť hlavné funkcie meniča ako aj zobrazovať: Vstupné napätie, Vstupný prúd, Výstupné napätie, Výstupný prúd, Vstupný výkon, Výstupný výkon, Straty, Účinnosť, Striedu a aktívny počet vetiev. Grafické prostredie určené pre PC umožňuje navyše znázorniť časové priebehy nameraných údajov, ako aj zaznamenávanie údajov do textového dokumentu.

V dolnej časti ovládacieho panela je umiestnený graf, znázorňujúci priebeh zmeny striedy. Uvádzaná hodnota striedy je prepočítaná na percentá. Graf sa aktualizuje s každou novou hodnotou. Keďže nové hodnoty prichádzajú každých 100ms a maximum hodnôt v grafe je 200, je možné poznamenať, že maximálna dĺžka zachyteného priebehu je 20s. Väčší počet údajov je potom možné načítať z textového dokumentu, do ktorého sa ukladajú všetky údaje. Čas odkedy a dokedy sa údaje majú zapisovať do textového dokumentu je daný užívateľom.


Rovnaká dĺžka priebehov je nastavená pre všetky zvyšné veličiny. Ovládací panel so zapnutými grafmi a štyrmi rôznymi hodnotami striedy je možné vidieť na obrázku (Obr. 24). Presnejšie 0, 20, 50 a 80 percent.



Obr. 24 Ovládací panel so zapnutými grafmi

Ako je možné vidieť na obrázku (Obr. 24), tak jednotlivé grafy zachytávajú 20s úseky nameraných hodnôt vstupných a výstupných napätí a prúdov, plus veličín vypočítaných z nameraných údajov. Pre overenie správnosti fungovania je možné na nasledujúcom oscilogram, znázornenom na obrázku (Obr. 25), vidieť ekvivalentné priebehy vstupného napätia a prúdu s priebehmi uvedenými v navrhnutom grafickom prostredí.

Za pomoci grafického prostredia pre PC a osciloskopu boli v ďalšom kroku namerané experimentálne výsledky, ktoré sú uvedené v nasledujúcej kapitole.




Obr. 25 Oscilogram časového priebehu vstupného napätia a prúdu pri 4 hodnotách striedy

VI. EXPERIMENTÁLNE VÝSLEDKY

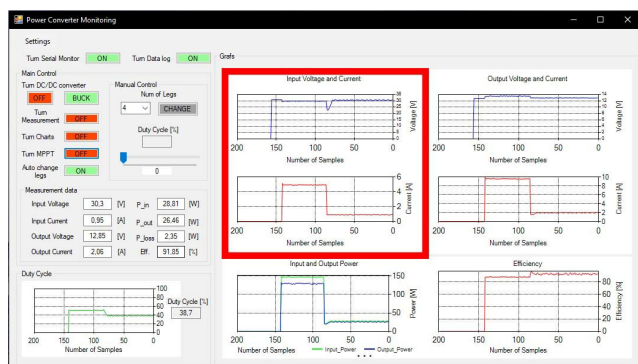
V tejto kapitole sú znázornené experimentálne výsledky navrhnutého riadiaceho algoritmu. Experimentálne výsledky boli získané za pomoci navrhnutého obvodového riešenia s využitím navrhnutého grafického prostredia pre PC, ktoré boli porovnané s výsledkami získanými pomocou osciloskopu. Zo získaných časových priebehov je možné spozorovať nie len totožnosť získaných výsledkov (medzi osciloskopom a navrhnutým grafickým prostredím), ale aj rýchlosť navrhovaného algoritmu. V prípade aktivovania funkcie, kedy riadiaci algoritmus rozhoduje o tom, koľko vetiev je pre daný vstupný výkon optimálny, sú výsledky získané za použitia grafického prostredia, konkrétne s využitím funkcie, ktorá umožňuje ukladať všetky prijímané údaje z mikrokontroléra do textového súboru. Následne sú údaje spracované v programe Microsoft Excel. S takto získanými údajmi sú znázornené priebehy účinnosti pre aktuálny počet vetiev. Podrobnejšie je to popísané pri znázornených priebehoch.

Spomínané priebehy, ktoré zachytávajú funkčnosť a rýchlosť navrhovaného algoritmu, bez zmeny počtu vetiev, sú znázornené na obrázku (Obr. 26). Pre uvedené oscilogramy platí: C1 je vstupné napätie a C2 je vstupný prúd.

Namerané priebehy zároveň zachytávajú proces hľadania bodu maximálneho výkonu hneď po zapnutí MPPT algoritmu a následne po skokovej zmene vstupného prúdu z 5A na 1A. Táto situácia môže napríklad nastať po zmene slnečného žiarenia, s príchodom mračen. Samozrejme, v reálnom prípade je zmena prúdu pomalšia. Pomocou tohto priebehu je možné určiť rýchlosť hľadania MPP. Pri tomto procese hľadania MPP boli výsledky získané osciloskopom porovnané so zaznamenanými časovými priebehmi (grafov) navrhnutého grafického užívateľského prostredia. Výsledky získané z grafického prostredia sú znázornené na obrázku (Obr. 27).




Obr. 26 Oscilogram časového priebehu vstupného prúdu a napätia



Obr. 27 Ekvivalentné priebehy zapnutia MPPT algoritmu získane navrhnutým obvodom

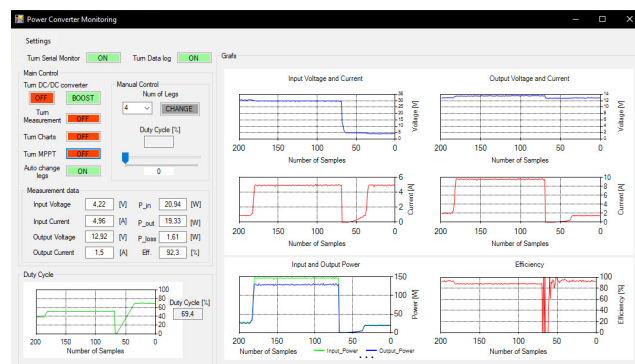
Z obrázka (Obr. 27) je možné vidieť, že priebehy namerané osciloskopom sú identické s priebehmi zaznamenané v navrhnutom grafickom prostredí. Ďalšie obrázky zachytávajú prechod z jedného režimu do druhého. Oscilogram na obrázku (Obr. 28)



Obr. 28 Oscilogram časových priebehov vstupného napätia a prúdu pri zmene pracovného režimu (zo znižovacieho na zvyšovací)


zachytáva časový priebeh vstupného prúdu a napätia. Priebehy začínajú v čase, kedy je vstupné napätie nastavené na 30V a vstupný prúd je obmedzený na 1A. Po krátkom okamihu bol upravený maximálny dovolený prúd odoberaný zo zdroja na 5A. Po chvíľe trvania tohto stavu, bola upravená hodnota napätia z 30V na 5V. Po poslednej úprave prejde napätie na nižšiu hodnotu než je hodnota napätia na batérii. Týmto spôsobom je zachytená rýchlosť algoritmu nie len pri zmene prúdu, ale aj pri zmene napätia, kedy menič musí upraviť pracovný režim z doterajšieho znižovacieho na zvyšovací.

Ekvivalentné priebehy boli zachytené pomocou navrhnutého obvodu a znázornené v grafickom užívateľskom prostredí, ako to je možné vidieť na obrázku (Obr. 29).

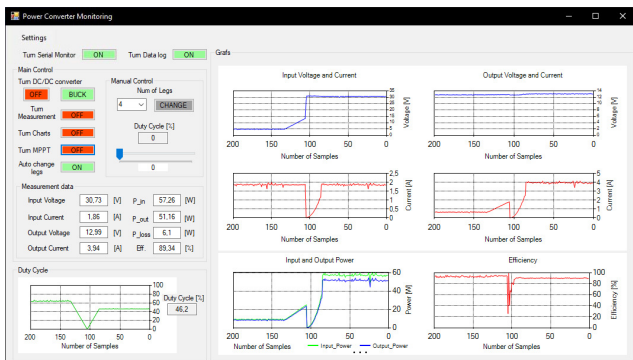


Obr. 29 Oscilogram časových priebehov vstupného napätia a prúdu pri zmene pracovného režimu (zo znižovacieho na zvyšovací)

Rovnakým postupom boli namerané priebehy v čase, kedy pracovná činnosť meniča prechádza zo zvyšovacieho režimu na znižovací. Obrázok (Obr. 30) znázorňuje výsledok zachytený pomocou osciloskopu a následne je uvedený obrázok (Obr. 31), ktorý znázorňuje výsledok zachytený grafickým prostredím.




Obr. 30 Oscilogram časových priebehov vstupného napätia a prúdu pri zmene pracovného režimu (zo zvyšovacieho na znižovací)



Obr. 31 Ekvivalentné priebehy získané navrhnutým obvodom pri zmene pracovného režimu (zo zvyšovacieho na znižovací)

Následne boli spracované výsledky z uložených hodnôt. Pomocou týchto hodnôt boli vytvorené grafy, ktoré potvrdzujú funkčnosť a teóriu, že nie vždy je optimálne používať vyšší počet vetiev. Pre názornosť boli zaznamenané situácie, kedy je optimálne použiť dve vetvy, tri vetvy a štyri vetvy pri znižovacom režime. Pri zvyšovacom režime je uvedený jeden príklad, kedy je účelnejšie použiť štyri vetvy. Pri všetkých prípadoch sa výber vhodného počtu vetiev vykonával automaticky s navrhnutým riadiacim algoritmom.

Navrhované obvodové riešenie nameria účinnosti pre každý počet vetiev a nastaví taký počet vetiev, pri ktorom bola zaznamenaná najvyššia účinnosť. Pre prípad, kedy navrhované obvodové riešenie vyhodnotí, že účelnejšie je použiť dve vetvy, namiesto viacerých, bol vytvorený graf z nameraných údajov. Popisovaná situácia je znázornená na obrázku (Obr. 32).




Obr. 32 Časový priebeh vyhodnocovania optimálneho počtu vetiev pre situáciu, kedy je výhodnejšie použiť dve vetvy


Podobným spôsobom bol vytvorený graf, ktorý je znázornený na obrázku (Obr. 33) pre situáciu, kedy je výhodnejšie použiť tri vetvy.

Ďalej bol vytvorený graf, ktorý je znázornený na obrázku (Obr. 34) pre situáciu, kedy je výhodnejšie použiť 4 vetvy.


Následne bol vytvorený graf z nameraných údajov, pre situáciu kedy menič pracuje vo zvyšovacom režime. Spomínaný graf je znázornený na obrázku (Obr. 35).



Obr. 33 Časový priebeh vyhodnocovania optimálneho počtu vetiev pre situáciu, kedy je výhodnejšie použiť tri vetvy



Obr. 34 Časový priebeh vyhodnocovania optimálneho počtu vetiev pre situáciu, kedy je výhodnejšie použiť 4 vetvy



Obr. 35 Časový priebeh vyhodnocovania optimálneho počtu vetiev pre situáciu, kedy menič pracuje vo zvyšovacom režime

Z uvedeného grafu je možné vidieť, že pri zvyšovacom pracovnom režime je účelnejšie používať vyšší počet vetiev. Keďže je v tomto prípade použitá 12V batéria, nebolo možné namerať účinnosti zvyšovacieho režimu pre vyššie vstupné napätia ako 12V.

Z uvedených experimentálnych výsledkov je možné poznamenať, že navrhnuté obvodové riešenie naozaj dokáže hľadať maximálny bod výkonu bez zmeny, ale aj so zmenou topológie, čím sa získa maximálny prenos energie za každých podmienok. Zároveň je navrhované obvodové riešenie schopné upravovať pracovný režim na základe porovnávania vstupného napätia s výstupným. S navrhnutým grafickým prostredím je možné jednoducho skontrolovať stav meniča, po prípade vykonať požadovaný zásah. Jednoduchou úpravou,

napríklad pridaním Bluetooth modulu je možné riadiť celé zariadenie bezdrôtovo.

VII. ZÁVER

Vďaka tomu, že navrhovaný algoritmus vykonáva zmenu topológie na základe reálne nameraných vstupných a výstupných hodnôt napätia a prúdu, je možné tento algoritmus použiť s ľubovoľnými elektronickými súčiastkami v rámci výkonového obvodu. Samozrejme je potrebné dbať na maximálne dovolené hodnoty napätia a prúdu použitých súčiastok. Týmto spôsobom je možné navrhnúť menič, ktorý pracuje s vysokou účinnosťou v podstatne širšom rozsahu vstupného výkonu, než s použitím klasického jednovetvového meniča, alebo viacvetvového meniča pracujúceho bez možnosti upravovania počtu vetiev.

Vďaka rýchlym zásahom, ktoré navrhovaný algoritmus vykonáva je možné navrhované obvodové riešenie použiť nie len pre potreby získavania elektrickej energie z FV panelov, ale aj pre potreby získavania elektrickej energie z veterných turbín.

REFERENCES

- [1] D. Kováč, M. Bereš, I. Kováčová, T. Vince, J. Molnár, J. Dziak, P. Jacko, R. Bučko, I. Tomčíková, D. Schweiner, „Circuit Elements Influence on Optimal Number Of Phases Of Dc/dc Buck Converter“2018, Electronics Letters, vol. 54, no. 7, pp. 435-437, 2018, doi: 10.1049/el.2018.0043
- [2] H. Glavaš, M. Vukobratović, M. Primorac and D. Muštran, "Infrared thermography in inspection of photovoltaic panels," 2017 International Conference on Smart Systems and Technologies (SST), Osijek, 2017, pp. 63-68. doi: 10.1109/SST.2017.8188671
- [3] Y. S. Joel, H. V. Saikumar and S. S. R. Patange, "Design & performance analysis of Fuzzy based MPPT control using two-switch non inverting Buck-Boost converter," 2016 International Conference on Electrical Power and Energy Systems (ICEPES), Bhopal, 2016, pp. 414-419. doi: 10.1109/ICEPES.2016.7915967
- [4] D. C. Huynh and M. W. Dunnigan, "Development and Comparison of an Improved Incremental Conductance Algorithm for Tracking the MPP of a Solar PV Panel," in IEEE Transactions on Sustainable Energy, vol. 7, no. 4, pp. 1421-1429, Oct. 2016. doi: 10.1109/TSTE.2016.2556678
- [5] D. Ajiatmo and I. Robandi, "A hybrid Fuzzy Logic Controller-Firefly Algorithm (FLC-FA) based for MPPT Photovoltaic (PV) system in solar car," 2016 IEEE International Conference on Power and Renewable Energy (ICPRE), Shanghai, 2016, pp. 606-610. doi: 10.1109/ICPRE.2016.7871149
- [6] M. M. Shebani, T. Iqbal and J. E. Quaicoe, "Comparing bisection numerical algorithm with fractional short circuit current and open circuit voltage methods for MPPT photovoltaic systems," 2016 IEEE Electrical Power and Energy Conference (EPEC), Ottawa, ON, 2016, pp. 1-5. doi: 10.1109/EPEC.2016.7771689
- [7] E. Mamarelis, G. Petrone and G. Spagnuolo, "Capacitor peak current control for MPPT photovoltaic applications," IECON 2013 - 39th Annual Conference of the IEEE Industrial Electronics Society, Vienna, 2013, pp. 3347-3352. doi: 10.1109/IECON.2013.6699665
- [8] R. L. Lin and H. Z. Chou, "MPPT photovoltaic wide load-range ZVS phase-shift full-bridge charger with DC-link current regulation," 2012 IEEE Industry Applications Society Annual Meeting, Las Vegas, NV, 2012, pp. 1-8. doi: 10.1109/IAS.2012.6373991
- [9] Guan-Chyun Hsieh, Hung-Liang Chen, Yaohwa Chen, Chee-Ming Tsai and Shian-Shing Shyu, "Variable frequency controlled incremental conductance derived MPPT photovoltaic stand-alone DC bus system," 2008 Twenty-Third Annual IEEE Applied Power Electronics Conference and Exposition, Austin, TX, 2008, pp. 1849-1854. doi: 10.1109/APEC.2008.4522978

Vytvorenie metodiky procesu multikriteriálnej optimalizácie výrobných liniek

Ján Čabala

Katedra Kybernetiky a Umelej Inteligencie
Technická univerzita v Košiciach
Košice, Slovensko
jan.cabala@tuke.sk

Ján Jadlovský

Katedra Kybernetiky a Umelej Inteligencie
Technická univerzita v Košiciach
Košice, Slovensko
jan.jadlovsky@tuke.sk

Abstrakt — Článok sa zaoberá vtvorením metodiky procesu multikriteriálnej optimalizácie výrobných liniek a jej overením v laboratórnych podmienkach. Definovaná metodika pozostáva z krokov spadajúcich do oblasti modelovania výrobných procesov, multikriteriálneho rozhodovania a multikriteriálnej optimalizácie. V oblasti modelovania výrobných procesov boli vytvorené simulačné modely rôznych konfigurácií výrobnej linky využitím programového prostredia Matlab/Simulink. Vzniknuté modely boli realizované s využitím experimentálnych dát získaných z reálneho modelu výrobnej linky, ako aj na základe modelov daných výrobných procesov vytvorených prostredníctvom Petriho sietí. Na úrovni multikriteriálneho rozhodovania sú výstupy zo simulačných modelov transformované do formy vstupov vhodných pre riešenie úlohy multikriteriálnej optimalizácie zameranej na identifikáciu optimálnej konfigurácie výrobnej linky s využitím metód ELECTRE, AGREPREF, TOPSIS a AHP. Z pohľadu multikriteriálnej optimalizácie sú výstupy simulačných modelov využité pre definovanie matematického modelu úlohy multikriteriálnej optimalizácie špecializovanej na problém optimálneho produkčného procesu s dôrazom na optimalizáciu zisku a času výroby. Navrhnutý bol taktiež spôsob syntézy výsledkov riešenia úloh multikriteriálneho rozhodovania resp. optimalizácie pomocou rôznych metód za účelom vyššej objektívnosti získaných riešení. Na aplikačnej úrovni je implementovaná aplikácia pre riešenie úloh multikriteriálneho rozhodovania a multikriteriálnej optimalizácie v oblasti optimalizácie činnosti výrobných liniek v programovom prostredí MATLAB.

Kľúčové slová— *Výrobné procesy, modelovanie systémov s diskretnými udalosťami, multikriteriálne rozhodovanie, multikriteriálna optimalizácia, evolučné algoritmy, Matlab/Simulink, Stateflow*

I. ÚVOD

Rozhodovanie a optimalizácia sú predmetom najrôznejších výskumov a štúdií vedeckých tímov prakticky z celého sveta. Táto téma je veľmi aktuálna, nakoľko algoritimizácia metód rozhodovania a optimalizácie umožňuje obmedziť vplyv človeka na výsledok rozhodovania a prenechať rozhodnutie metódam postaveným na matematickom základe. Využitie týchto metód zároveň zabezpečuje objektívnosť prijatých rozhodnutí a stratégií.

V procese rozhodovania resp. optimalizácie nie je možné vždy prijať výsledné rozhodnutie len na základe jedného

kritéria, v praxi sú najčastejšie riešené problémy, pri ktorých na rozhodnutie vplýva viacero kritérií, ktoré sú často protichodné a je potrebné nájsť riešenie tak ,aby čo najviac vyhovovalo každému z rozhodovacích kritérií. Pre riešenie takýchto úloh existujú metódy multikriteriálneho rozhodovania (MKR) resp. multikriteriálnej optimalizácie (MO), ktorými sa budeme v článku zaoberať.

Článok popisuje návrh komplexnej metodiky procesu multikriteriálnej optimalizácie výrobných liniek a aplikácie metód multikriteriálneho rozhodovania a optimalizácie pri tomto procese na modeloch výrobných liniek, ktorými disponuje Centrum Moderných Metód Riadenia a Priemyselnej Informatiky na Katedre Kybernetiky a Umelej Inteligencie Technickej Univerzity v Košiciach.

Vytvorená metodika procesu riešenia úloh multikriteriálneho rozhodovania a multikriteriálnej optimalizácie popisuje tri základné oblasti, pomocou ktorých je možné riešiť problém multikriteriálnej optimalizácie činnosti výrobných liniek, konkrétne modelovanie výrobných liniek, multikriteriálne rozhodovanie a multikriteriálnu optimalizáciu.

V oblasti modelovania výrobných liniek je potrebná realizácia simulačných modelov rôznych konfigurácií výrobných liniek. Vytvorené simulačné modely boli realizované na základe dát z reálnych modelov výrobných liniek, ako aj z modelov výrobných liniek vytvorených pomocou Petriho sietí. Vytvorené modely poskytujú pre procesy multikriteriálnej optimalizácie a multikriteriálneho rozhodovania vstupné dáta, ktoré sú ďalej transformované do podoby vhodnej pre vstup do procesu multikriteriálneho rozhodovania, resp. pre definovanie matematického modelu úlohy multikriteriálnej optimalizácie. Pre implementáciu simulačných modelov bolo zvolené modelovanie pomocou Stateflow diagramov, ktoré sú súčasťou programového prostredia Matlab/Simulink.

Pre definovanie optimálnej konfigurácie výrobnej linky sú využité dáta zo simulačných modelov, ktoré ďalej slúžia ako vstupy do procesu MKR, v ktorom sa pomocou metód objektívizácie hodnotiacich kritérií a metód multikriteriálneho rozhodovania vyberie optimálna konfigurácia výrobnej linky vzhľadom na rôzne obmedzenia rozhodovacieho procesu. V tejto časti riešenia problému sú využité priame metódy

a metódy prahov citlivosti pre riešenie úloh multikriteriálneho rozhodovania.

Ich aplikačný potenciál v rámci procesu optimalizácie výrobných liniek je v procesoch nastavenia váhy optimalizovaných faktorov, ako aj pri procese výberu niektorého z variantov riešenia, napr. pri rozložení niektorých častí výrobnéj linky a pod.

Hľadanie optimálnej konfigurácie montážnej linky je len jednou z mnohých možností aplikácie metód multikriteriálneho rozhodovania. Tieto metódy nachádzajú svoje uplatnenie aj v iných aplikačných oblastiach, napr. prípadová štúdia [1] sa zaoberá výberom optimálneho plánu maľovania áut v automobilovom priemysle v Portugalsku, pričom sú využité metódy AHP a MAMAS. V štúdiu je pri riešení rôznymi metódami vidieť rozdielne usporiadanie alternatív na druhom a ďalších miestach, avšak zvolenú stratégiu potvrdili obe vybrané metódy. Riešenie environmentálnych problémov s použitím metód SMART, PROMETHEE a ELECTRE III je diskutované v [2]. Z výsledkov štúdie vyzdvihujú autori skutočnosť, že možnosť využitia prahov veta pri metóde ELECTRE III môže spôsobiť úplne rozdielne výsledné poradie alternatív, než pri metódach SMART a PROMETHEE.

Podľa [3] je problematika multikriteriálneho rozhodovania využiteľná a aplikovateľná v oblasti výroby pri riešení týchto problémov:

- výber materiálu pre zvolenú inžiniersku aplikáciu,
- ohodnotenie rôznych návrhov dizajnu produktu,
- ohodnotenie spracovateľnosti výrobných materiálov,
- ohodnotenie a výber moderných metód výroby,
- ohodnotenie a výber flexibilných montážnych systémov,
- výber roboty pre danú priemyselnú aplikáciu,
- výber softvéru pre návrh a zostavenie výrobného procesu,
- posúdenie vplyvu výrobného procesu na životné prostredie,
- výber lokality pre výstavbu výrobnéj haly,
- výber obchodníka v dodávateľskom reťazci atď.

V oblasti výrobných procesov sa prístupy a metódy multikriteriálneho rozhodovania využívajú aj na ohodnotenie a výber dodávateľov. Prehľad metód a prístupov v tejto oblasti je predmetom štúdie [4]. Jednou z najpopulárnejších metód pre riešenie úloh v tejto oblasti je podľa výsledkov štúdia metóda AHP. Štúdia [5] poskytuje okrem iného aj prehľad metód MKR s frekvenciou ich využitia pri riešení problému výberu dodávateľa, kde sa na pomerne vysokých priečkach umiestnili metódy AHP a TOPSIS, ktoré sú využité taktiež v tejto dizertačnej práci.

Motivácia pre výber prístupu MKR k riešeniu problému optimálnej konfigurácie výrobnéj linky vyplynula z aplikovateľnosti týchto metód pre riešenie uvedeného problému. Z výsledkov štúdií [1] a [2] uvedených vyššie vyplýva, že riešenie pomocou rôznych metód MKR môže poskytovať rozdielne výsledné usporiadanie alternatív. Tento fakt bol motiváciou pre realizáciu spôsobu syntézy výsledkov

procesu MKR získaných pomocou rôznych metód ako súčasťou výpočtového procesu riešenia úlohy MKR.

V rámci výberu metód ocenenia hodnotiacich kritérií, ako aj metód pre samotné riešenie úloh MKR boli z portfólia metód zvolené metódy s možnosťou jednoduchéj algoritmickej s dôrazom na čo najväčšiu objektivizáciu riešeného problému. V rámci metód MKR bol pri výbere kladený dôraz aj na rozmanitosť zvolených prístupov tak, aby zvolené metódy zahrnuli rozdielne prístupy k riešeniu úlohy MKR s cieľom napomôcť väčšej objektivite pri syntéze čiastkových výsledkov. Ďalším faktorom bola taktiež absencia matematického aparátu využiteľného pri syntéze výsledkov získaných pomocou rôznych metód MKR. V realizácii spomínanej syntézy výsledkov a definovaní matematického aparátu pre jej splnenie tvorí jeden z prínosov tejto práce.

Vstupy zo simulačných modelov sú taktiež využiteľné v procese riešenia multikriteriálnej optimalizácie výrobného plánu s cieľom maximalizovať zisk a časovú úsporu výrobného procesu. Pre riešenie tejto úlohy je využitá kombinácia matematických metód a metód umelej inteligencie.

Pokiaľ sa zameriame na metódy umelej inteligencie, tak sa v problematike multikriteriálnej optimalizácie využívajú najmä evolučné algoritmy. Sú jedným z prístupov umožňujúcich hľadanie najlepších riešení pri skúmaní relatívne malého počtu možných riešení, pretože rozsah možných riešení je v mnohých prípadoch veľmi rozsiahly.

Niektoré algoritmy týchto skupín dokážu zvládnuť rôzne formy účelových funkcií a vyriešiť úlohy s komplikovanými množinami nedominovaných riešení (MOEA / D alebo NSGA-II) [6]. Práve komplexnosť bola jedným z dôvodov pre výber algoritmu NSGA-II na zostavenie množiny nedominovaných riešení pre riešenie cieľov DZP.

Evolučné algoritmy pracujú s populáciou jednotlivcov. Táto populácia zvyčajne obsahuje viac jednotlivcov, často stovky alebo dokonca tisíce. Prvá populácia je spravidla generovaná náhodne, takže pravdepodobnosť generovania každého potenciálneho riešenia je rovnaká. Táto populácia je potom ohodnotená na základe hodnotiacej funkcie (zodpovedá účelovej funkcii pri úlohách MO) a pričom najlepšie hodnotené jedince ostávajú v evolučnom procese, zatiaľ čo horšie sú vylúčené.

Na riešenie úloh multikriteriálnej optimalizácie sa spravidla používajú algoritmy skupiny VEGA (Vector Evaluated Genetic Algorithms). Podrobnejší popis tejto skupiny algoritmov možno nájsť v [7].

Motivácia pre výber kombinácie matematických metód a metód umelej inteligencie na vyriešenie úlohy definície optimálneho výrobného procesu na modeli montážnej linky PVS umiestnenej v rámci CMMRaPI KKUI FEI TUKE bola iniciovaná širokým aplikačným potenciálom týchto metód. Napr. pri riešení problému spoľahlivosti systému bol problém s alokáciou redundancie vyriešený algoritmom NSGA - [8]. Z výsledkov vyplýva, že rozhodovateľ dostáva na výstupe množinu nedominovaných riešení, ktorá zodpovedá jeho preferenciám pomocou rôznych metód MO. Výsledkom však nie je výber konkrétnej alternatívy riešenia problému. [9] popisuje využitie algoritmu MOGA (Multi-Objective Genetic Algorithm)

pri vyvážení činnosti výrobných liniek, zaoberajúci sa hlavne výkonom navrhnutého algoritmu pri zmenách parametrov optimalizačného procesu, ktoré ovplyvňujú kvalitu a diverzitu optimalizačného procesu. Využitie optimalizácie pomocou kolónie mravcov popisujú články [10], v ktorom sú taktiež zostavené množiny nedominantných riešení na základe rôznych modifikácií navrhnutého algoritmu kolónie mravcov, a [11], v ktorom je porovnaná výkonnosť algoritmu kolónie mravcov s algoritmi ULINO a simulovaným žíhaním, pričom algoritmus kolónie mravcov dosahuje v tomto prípade výrazne lepšie výsledky ako ostatné skúmané algoritmy. Genetické algoritmy sa môžu použiť aj na riešenie plánovania sekvencie výrobných zariadení v rámci výrobných liniek, čo je uvedené v [12]. Ďalšie možnosti aplikácie súvisiace s problémami dynamickej multikriteriálnej optimalizácie (množina nedominovaných riešení sa v čase mení) sú uvedené v [13]. Aplikácia MO v oblasti výrobných liniek je ilustrovaná v [14], kde sa cieľové programovanie používa na vyvázenie obojstrannej montážnej linky, pričom optimalizovanými faktormi je minimalizácia počtu prepojených pracovných staníc, minimalizácia počtu pracovných staníc a minimalizácia času výrobného cyklu.

Ďalším z dôvodov pre zvolenie kombinácie matematického prístupu a prístupu umelej inteligencie pre riešenie tohto problému vyplynula z potreby výberu konkrétnej stratégie pre riešenie problému optimálneho výrobného procesu na výrobných linkách PVS, pričom využité matematické metódy popísané v nasledujúcich kapitolách poskytujú ľahko implementovateľný a vhodný nástroj pre výber výsledného riešenia z množiny nedominovaných riešení. Taktiež bol v práci navrhnutý spôsob syntézy výsledkov pomocou rôznych matematických metód pre zabezpečenie väčšej objektívnosti výsledkov riešenia úlohy multikriteriálnej optimalizácie.

Výsledkom navrhutej metodiky je definícia optimálnej konfigurácie výrobných liniek a určenie optimálneho výrobného procesu prebiehajúceho na linke vzhľadom k definovaným cieľom výrobného procesu.

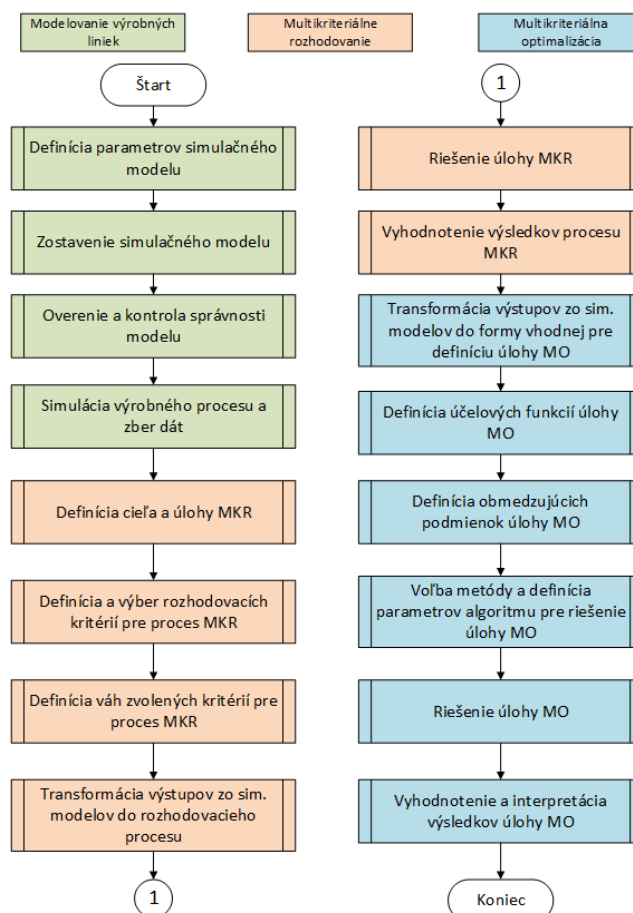
II. METODIKA PROCESU MULTIKRITERIÁLNEJ OPTIMALIZÁCIE VÝROBNÝCH LINIEK

Táto časť článku popisuje postupy realizácie jednotlivých úkonov potrebných pre riešenie problému optimálnej konfigurácie a výpočte optimálneho produkčného plánu výrobných liniek. Táto metodika bude následne v ďalších kapitolách overená pri riešení problémov optimálnej konfigurácie a optimálneho produkčného procesu modelov automatizovaných výrobných liniek FMP a PVS umiestnených v rámci CMMRaPI KKUI FEI TUKE.

Návrh metodiky procesu multikriteriálnej optimalizácie výrobných liniek je možné rozdeliť do 3 častí, ktoré sa podieľajú na riešení čiastkových úloh celého procesu návrhu a vedú ku komplexnému riešeniu zadaného problému:

1. modelovanie výrobných liniek,
2. definícia optimálnej konfigurácie výrobných liniek pomocou metód multikriteriálneho rozhodovania,
3. definícia optimálneho produkčného plánu výrobných liniek pomocou metód multikriteriálnej optimalizácie.

Celý proces definovania metodiky je rozdelený do týchto 3 častí, v rámci ktorých sú popísané jednotlivé kroky vedúce k splneniu ako čiastkových cieľov daného kroku, tak aj komplexného cieľa – zabezpečenia optimálnej činnosti automatizovanej výrobných liniek. Metodický postup pri riešení úlohy MKR je znázornený na Obr. 1.



Obr. 1 Postupnosť krokov metodiky procesu multikriteriálnej optimalizácie výrobných liniek

A. Modelovanie výrobných liniek

Hlavnou úlohou modelovania a implementácie simulačných modelov výrobných liniek do zvoleného programového prostredia je vytvorenie modelu, ktorý sa následne využíva na simuláciu výrobného procesu danej výrobných liniek. Výhodou simulačných modelov je ich menšia finančná náročnosť v porovnaní s budovaním reálnych prototypov. S využitím Stateflow diagramov v programovom prostredí Matlab/Simulink, vieme vytvoriť pomerne presný simulačný model výrobného procesu, ktorý poskytuje výstupy a parametre výrobného procesu, ktoré môžu byť následne ďalej spracované a využité v procese optimalizácie činnosti výrobných liniek.

Taktiež, je možné v simulačnom prostredí realizovať a testovať rôzne možnosti konfigurácie výrobných liniek, ktoré nie je možné v daných podmienkach testovať reálne, či už z dôvodu finančných, časových alebo priestorových obmedzení.

Metodika v oblasti modelovania výrobných liniek pozostáva z nasledujúcich krokov:

1. **Definícia parametrov modelu** - pre zostavenie modelu je nevyhnutný dostatočný počet parametrov, ktoré definujú výrobný proces a ktoré sú potrebné pre zostavenie simulačného modelu danej výrobnej linky
2. **Zostavenie simulačného modelu** - v tomto kroku sa na základe definovaných parametrov realizuje samotná tvorba simulačného modelu výrobnej linky vo zvolenom programovom prostredí. Výber programového prostredia sa odvíja od účelu simulačného modelu (cieľom môže byť napr. vizualizácia konkrétnych činností na linke, alebo je žiaduce proces výroby znázorniť schematicky a zozbierať výstupné parametre simulácie výrobného procesu). Navrhnutá metodika využíva simulačný model výrobnej linky najmä na zisk výstupných parametrov výrobného procesu, ktoré sú v ďalších krokoch využité ako vstupy do procesov multikriteriálneho rozhodovania resp. optimalizácie
3. **Overenie a kontrola správnosti modelu** - proces overenia a kontroly (validácie) vytvoreného modelu opäť prebieha v závislosti na celi, za ktorým bol model realizovaný. V prípade, že bol model tvorený vo fáze návrhu výrobnej linky, je overenie možné realizovať pomocou detailného sledovania funkcionality modelu, ktorá musí zodpovedať predstave realizátora modelu. Taktiež je potrebné sledovať výstupné parametre modelu, ktoré by mali korešpondovať s predpokladanými výstupmi. Výstupné parametre sú dôležité aj pri realizácii modelu na základe už existujúcej výrobnej linky, tu je však kontrola správnosti modelu jednoduchšia, nakoľko je výsledky simulácie možné porovnať z výstupmi z reálneho modelu.
4. **Simulácia výrobného procesu a zber údajov z modelu** - Posledným krokom realizovaným v rámci procesu modelovania je samotná simulácia výrobného procesu na jednotlivých simulačných modeloch a zber výstupných parametrov z týchto modelov. Výstupné parametre jednotlivých simulácií sú následne spracované a využité v procese multikriteriálnej optimalizácie a multikriteriálneho rozhodovania. Pre realizáciu simulácie výrobného procesu je nevyhnutné taktiež zdefinovať vstupy do procesu simulácie, ktoré sa počas realizácie jednotlivých simulácií nemenia: definícia typu produktu, počet vyrábaných produktov atď.

Modelovanie výrobných liniek prostredníctvom Stateflow diagramov v laboratórnom prostredí CMMRaPI KKUI FEI TUKE je predmetom článku [15].

B. Multikriteriálne rozhodovanie

Úlohou metód multikriteriálneho rozhodovania pri definovaní metodiky procesu multikriteriálnej optimalizácie činnosti výrobných liniek je na základe vstupných parametrov získaných rôznymi spôsobmi zvoliť najlepšiu alternatívu z určitého konečného množstva ponúkaných alternatív riešenia.

Pri navrhovanej metodike sú metódy multikriteriálneho rozhodovania využité pre výber najlepšej možnej konfigurácie resp. rozloženia výrobných pracovísk v rámci výrobnej linky. Navrhnutá metodika pozostáva v oblasti MKR z nasledujúcich krokov:

1. **Definícia úlohy a cieľa** - prvým krokom pri riešení úlohy multikriteriálneho rozhodovania je definícia cieľa tejto úlohy. V týchto úlohách by mal byť cieľ spravidla jeden, na rozdiel od úloh multikriteriálnej optimalizácie. Definícia cieľa vzniká väčšinou ako konsenzus názorov viacerých členov predstavenstva organizácie. Cieľ v tomto prípade nemusí byť definovaný konkrétne, skôr predstavuje popis problému, ktorý by mal byť prostredníctvom MKR vyriešený. Cieľ musí byť dosiahnuteľný viacerými spôsobmi, ktoré predstavujú rôzne alternatívy riešenia úlohy MKR. V úlohe z laboratórneho prostredia CMMRaPI KKUI FEI TUKE je cieľov voľba optimálnej konfigurácie výrobnej linky FMP.
2. **Definícia a výber rozhodovacích kritérií** - môžu nastať 2 situácie: individuálne rozhodovanie - v tomto prípade definuje kritériá pre rozhodovanie sám rozhodovateľ, alebo skupinové rozhodovanie - v tomto prípade definuje kritériá pre rozhodovanie skupina ľudí (expertov)
3. **Definícia váh zvolených rozhodovacích kritérií** - významnú mieru pri riešení úlohy MKR zohráva váha resp. dôležitosť jednotlivých kritérií, ktoré ovplyvňujú výsledok rozhodovania. Pri individuálnom rozhodovaní je proces jednoduchší, pri skupinovom sa využívajú metódy na to určené (napr. Bodovacia metóda, metóda expertov)
4. **Transformácia výstupov zo simulačných modelov na vstupy do rozhodovacieho procesu** - výstupy zo simulačných modelov musia byť pre potreby multikriteriálneho rozhodovania transformované do vhodnej podoby. Spôsob zmeny týchto parametrov hodnotenia jednotlivých alternatív vstupujúcich do procesu rozhodovania môže byť realizovaný pomocou relatívneho alebo absolútneho hodnotenia.
5. **Riešenie úlohy MKR** - v tomto kroku riešenia úlohy MKR sa realizuje proces výberu najlepšej alternatívy z ponúknutého spektra navrhovaných riešení. Výber je možné realizovať rôznymi metódami multikriteriálneho rozhodovania (ELECTRE I – IV, AFGREPREF, TOPSIS, AHP. Pre väčšiu objektivnosť rozhodovacieho procesu je možné riešiť úlohu MKR pomocou rôznych metód postavených na rôznych matematických základoch
6. **Vyhodnotenie výsledkov procesu MKR** - v prípade, že rozhodovateľ využije pre určenie výsledkov procesu MKR jednu metódu spracovania vstupných údajov, tak výsledkom je spravidla poradie alternatív podľa ich užitočnosti. V prípade, že sú rozdiely medzi ohodnotením alternatív malé, alternatívy vykazujú rovnakú hodnotu hodnotiaceho ukazovateľa. V takejto situácii môže rozhodovateľ kvôli väčšej objektivnosti

rozhodovacieho procesu využiť pre riešenie úlohy MKR viaceré metódy s rôznym rozhodovacím procesom. V tomto prípade je však potrebné definovať, ako sa riešiteľ resp. skupina riešiteľov vysporiada s prípadom, keď nebudú výsledky procesu MKR podľa jednotlivých metód konzistentné.

C. Multikritériálna optimalizácia

Multikritériálna optimalizácia je optimalizácia sledujúca viac než jeden cieľ pri hľadaní optimálnej alternatívy. Rozdiel medzi využitím MKR a MO je v tom, že pri multikritériálnom rozhodovaní sa rozhodovateľ rozhoduje medzi konečným počtom definovaných alternatív, pri multikritériálnej optimalizácii je úloha definovaná ako optimalizácia viac ako jednej účelovej funkcie pri dodržaní všetkých obmedzení danej úlohy MO. V aplikačnej oblasti optimalizácie činnosti výrobných liniek je možné riešiť pomocou MO napr. úlohy optimálneho výrobného plánu. Metodika v tejto oblasti pozostáva z krokov:

1. **Transformácia výstupov zo sim. modelov do formy vhodnej pre definíciu úlohy MO** - pre správny popis matematického modelu výrobného procesu prebiehajúceho na výrobných linkách je potrebné čo najlepšie poznať výrobný proces. Pri tomto procese je možné opäť využiť simulačné modely výrobných liniek, ktoré na základe výstupov simulácií dokážu dodať detailné informácie ohľadom výrobného procesu, z ktorých je následne možné zdefinovať matematický model úlohy multikritériálnej optimalizácie.
2. **Definícia účelových funkcií** - Veľmi dôležitým krokom v procese multikritériálnej optimalizácie výrobných liniek je definícia matematického modelu úlohy MO. V tomto kroku je potrebné definovať ciele optimalizácie, ako aj smer optimalizácie každého z definovaných cieľov – či sa jedná o minimalizáciu alebo maximalizáciu daného ukazovateľa.[16]
3. **Definícia obmedzujúcich podmienok** - ďalším krokom pri procese riešenia úlohy MO je definovanie obmedzujúcich podmienok. Tie sú definované vo forme rovníc alebo nerovnic, ktoré musia platiť, aby sa dané riešenie úlohy MO dalo považovať za prípustné. Ak riešenie nespĺňa niektorú z obmedzujúcich podmienok, je považované za neprípustné a ďalej sa s ním v procese riešenia neuvažuje. Obmedzenia úlohy sú reprezentované rovnicami a nerovnicami, ktoré musia platiť (v praxi predstavujú napr. obmedzenia zásob, obmedzené možnosti investícií atď.).[16]
4. **Voľba metódy a definícia parametrov algoritmu** - Po zadaní úplného matematického modelu úlohy MO je úloha multikritériálnej optimalizácie pripravená na riešenie. Spôsobov a metód pre riešenie úloh MO je mnoho, medzi základné patria matematické metódy a metódy umelej inteligencie. V rámci navrhutej metodiky je využité riešenie pomocou fúzie týchto prístupov k riešeniu úloh MO. Riešenie úlohy MO pozostáva v navrhutej metodike

z 2 častí: definícia Pareto frontu, resp. množiny nedominovaných riešení pomocou metód umelej inteligencie a následný výber riešenia úlohy MO prostredníctvom matematických metód.

5. **Riešenie úlohy MO** - v prvej fáze riešenia úlohy multikritériálnej optimalizácie využijeme metódy umelej inteligencie, konkrétne modifikovaný evolučný algoritmus NSGA-II pre špecifikáciu tzv. Pareto frontu, resp. množiny nedominovaných riešení danej úlohy multikritériálnej optimalizácie. Pre nájdenie jedincov patriacich do Pareto frontu je možné využiť aj matematické metódy, avšak najmä vzhľadom k pomerne náročnému procesu jeho identifikácie, zvlášť pri zložitejších tvaroch účelových funkcií, sme zvolili pre riešenie tejto časti úlohy MO evolučný algoritmus. V druhej fáze sa spomedzi riešení, ktoré sú obsiahnuté v množine nedominovaných riešení, zvolí optimálne riešenie úlohy MO. Keďže existuje viacero spôsobov resp. metód výberu optimálneho riešenia, je ideálne porovnať viaceré metódy a na základe ich výsledkov zvoliť optimálne riešenie.
6. **Vyhodnotenie a interpretácia výsledkov procesu MO** - výstupom z procesu riešenia úlohy multikritériálnej optimalizácie je poradie potenciálnych riešení zoradené podľa ich umiestnenia v danom Pareto fronte. V rámci jednotlivých frontov sú riešenia usporiadané podľa zvolenej matematickej metódy usporiadania týchto riešení. V prípade, že zvolené riešenie nekorešponduje s predstavami rozhodovateľa, je možné optimalizačný proces zopakovať so zmenenými parametrami a porovnať výsledky získané pomocou rôznych metód a následne zvoliť riešenie, ktoré najviac korešponduje s potrebami rozhodovateľa.

Riešenie úloh multikritériálnej optimalizácie z ekonomického prostredia prostredníctvom nástrojov programového prostredia Matlab/Simulink je uvedené v [17].

V ďalších kapitolách článku budú zobrazené výstupy získané v procese overenia správnosti vytvorenej metodiky v laboratórnom prostredí Centra moderných metód riadenia a priemyselnej informatiky pracujúceho v rámci Katedry Kybernetiky a Umelej Inteligencie Fakulty elektrotechniky a Informatiky technickej Univerzity v Košiciach (CMMRaPI KKUI FEI TUKE).


III. MODELOVANIE A SIMULÁCIA VÝROBNÉHO PROCESU VÝROBNÝCH LINIEK

V rámci overenia správnosti navrhutej metodiky boli v oblasti modelovania a simulácie výrobných procesov zostavené simulačné modely rôznych konfigurácií výrobných liniek FMP. Proces tvorby týchto simulačných modelov sleduje navrhnutú metodiku procesu multikritériálnej optimalizácie výrobných liniek, uvedenú v predchádzajúcej kapitole. Konkrétne sa jedná o tieto konfigurácie:

- V1: súčasný stav (1 pracovisko na každom poste),
- V2: pridanie jedného pracoviska na post 3,

- V3: prídanie jedného pracoviska na post 4,
- V4: prídanie jedného pracoviska na posty 3 a 4,
- V5: prídanie jedného pracoviska na posty 3, 4 a 5.


Simulačné modely (schémy sú zobrazené na Obr. 2) boli vytvorené v pomoci Stateflow diagramov v programovom prostredí Matlab/Simulink. Predpokladom pre ich vznik bol model výrobnéj linky FMP popísaný pomocou Petriho sietí, ktorý bol vytvorený ako výstup 1. fázy riešenia projektu Technicom. Zdrojom dát pre vytvorenie simulačných modelov boli taktiež hodnoty jednotlivých úkonov namerané v reálnom výrobnom procese na laboratórnom modeli FMP.



Obr. 2 Uvažované konfigurácie výrobnéj linky FMP

Proces overenia a kontroly správnosti modelu opäť prebehol na základe porovnania časov realizácie výrobkov na reálnom modeli výrobnéj linky a realizáciou simulácií na modeli alternatívy V1 (zodpovedajúca súčasnému stavu reálneho modelu výrobnéj linky FMP). V rámci výrobného procesu realizovaného na reálnom modeli FMP bolo vyrobených 10 výrobkov a časy vykonávania jednotlivých úkonov boli zaznamenané do tabuľky vytvorenej v programe Microsoft Excel.

Pre realizáciu porovnania funkcionality činnosti simulačného a reálneho modelu bolo realizovaných 25 simulácií výroby 100 výrobkov na simulačnom modeli alternatívy V1, pričom bol následne vypočítaný priemerný čas výroby jedného výrobku. Táto hodnota sa v jednotlivých simuláciách pohybuje medzi 55 a 60 sekúnd, čo znamená odchýlku 2 až 3 sekundy od času výroby na reálnom modeli - Obr. 3.



Obr. 3 Porovnanie času výroby výrobku v reálnom a simulačnom modeli výrobnéj linky FMP

Po vytvorení a porovnaní funkcionality simulačného a reálneho modelu výrobnéj linky prebehla realizácia simulácií a zberu údajov zo simulačných modelov. Výstupy z modelov sú následne ďalej využité ako vstupy pre riešenie úloh

multikriteriálneho rozhodovania a multikriteriálnej optimalizácie – TABUĽKA 1.

TABUĽKA 1 Výstupy zo simulačných modelov rôznych konfigurácií výrobnéj linky FMP

Variant riešenia	Priem. dĺžka vyr. cyklu (s)	Priem. čas čakania výrobku na poste 3 (s)	Priem. čas čakania výrobku na poste 4 (s)	Priem. čas čakania výrobku na poste 5 (s)	Priem. čas čakania výrobku v rade (s)
V1	523,6	136,19	27,57	3,89	167,65
V2	494,89	1,5	76,65	6,58	84,73
V3	477,11	67,89	0,09	13,92	81,90
V4	448,22	5,97	0,03	9,16	15,16
V5	335,72	1,79	6,08	3,37	11,24

IV. APLIKÁCIA NAVRHNUTEJ METODIKY V PROCESE VÝBERU OPTIMÁLNEJ KONFIGURÁCIE VÝROBNÉJ LINKY

V tejto kapitole je predstavené využitie navrhutej metodiky v procese výberu optimálnej konfigurácie výrobnéj linky Flexibilný montážny podnik (FMP), ktorej reálnym model CMMRaPI KKUI FEI TUKE disponuje. V rámci kapitoly sú taktiež popísané jednotlivé kroky aplikovania metodiky pri riešení tohto problému, samotné riešenie problému rôznymi metódami multikriteriálneho rozhodovania (MKR), ako aj vyhodnotenie a interpretácia riešenia.

Cieľom tejto úlohy multikriteriálneho rozhodovania je voľba optimálnej konfigurácie výrobnéj linky FMP. V tejto úlohe boli pri riešení uvažované 4 rozhodovacie kritériá (na kritériách sa zhodli 5 členovia CMMRaPI KKUI FEI TUKE, ďalej označovaní ako „experti“):

- C1: zvýšenie efektivity výrobného procesu,
- C2: minimalizácia prestojov vo výrobnom procese,
- C3: dopad na životné prostredie,
- C4: veľkosť investície.

Proces definovania váh teda začína ohodnotením váh jednotlivých rozhodovacích kritérií expertmi. Každý z expertov hodnotil váhami dôležitosť jednotlivých kritérií tak, aby bol súčet váh rovný 1. Jednotlivé ohodnotenia sú zapísané v TABUĽKA 2:

TABUĽKA 2 Ohodnotenie dôležitosti kritérií expertmi

Expert/Kritérium	C1	C2	C3	C4
E1	0.7	0.1	0	0.2
E2	0.8	0.1	0.05	0.05
E3	0.5	0.1	0.3	0.1
E4	0.6	0.05	0.1	0.25
E5	0.5	0.2	0.2	0.1

Aplikovaním metódy expertov na ohodnotenie jednotlivých váh expertmi boli získané nasledujúce váhy kritérií – TABUĽKA 3:

TABUĽKA 3 Výsledné váhy kritérií získané metódou expertov

Kritérium	C1	C2	C3	C4
Váha	0.6922	0.082	0.0547	0.1711

Pre proces MKR je vstupy (namerané dáta zo sim. modelov, ako aj vstupy pre definovanie miery splnenia každého kritéria každou z možných alternatív riešenia) potrebné upraviť na jednotný formát, pretože momentálne sú ich hodnoty udávané v rôznych jednotkách. Pre úpravu vhodnú pre proces MKR využijeme škálu od 0 po 100, ktorá bude predstavovať percentuálne splnenie každého kritéria každou z alternatív – TABUĽKA 4.

TABUĽKA 4 Vstupy do procesu MKR

	C1	C2	C3	C4
V1	0	0	100	100
V2	15	53	75	89
V3	25	55	50	42
V4	40	97	25	32
V5	100	100	0	0

Výsledky riešenia úlohy MKR pomocou jednotlivých metód môžeme zhrnúť do prehľadnej tabuľky, v ktorej uvedieme poradie jednotlivých alternatív podľa hodnotiaceho ukazovateľa jednotlivých metód MKR – TABUĽKA 5:

TABUĽKA 5 Výsledky riešenia úlohy MKR rôznymi metódami

Poradie/ Metóda	ELECTRE III		AGREPREF		TOPSIS		AHP	
1.	V5	1	V5	4	V5	0,7951	V5	0,4772
2.	V2	1,5	V4	2	V4	0,4039	V4	0,1483
3.	V4	2	V3	0	V3	0,2684	V1	0,1362
4.	V1	2,5	V2	-2	V2	0,2472	V2	0,1335
5.	V3	3	V1	-4	V1	0,2049	V3	0,1047

Jedným zo spôsobov je obodovanie poradia alternatív podľa ich umiestnenia v rozhodovacom procese podľa každej z využitých metód (najlepšia alternatíva podľa každej z metód získava 1 bod, najhoršia *pv* bodov) a následná syntéza tohto bodovania pomocou vzťahu:

$$pb_i = \sum_{j=1}^{pm} b_{ij}, \text{ pre } i = 1, 2, \dots, pv, \quad (1)$$

kde pb_i je výsledný počet bodov *i*-tej alternatívy, b_{ij} je bodové ohodnotenie *i*-tej alternatívy v *j*-tej metóde, *pm* je počet metód a *pv* je počet výsledkov.

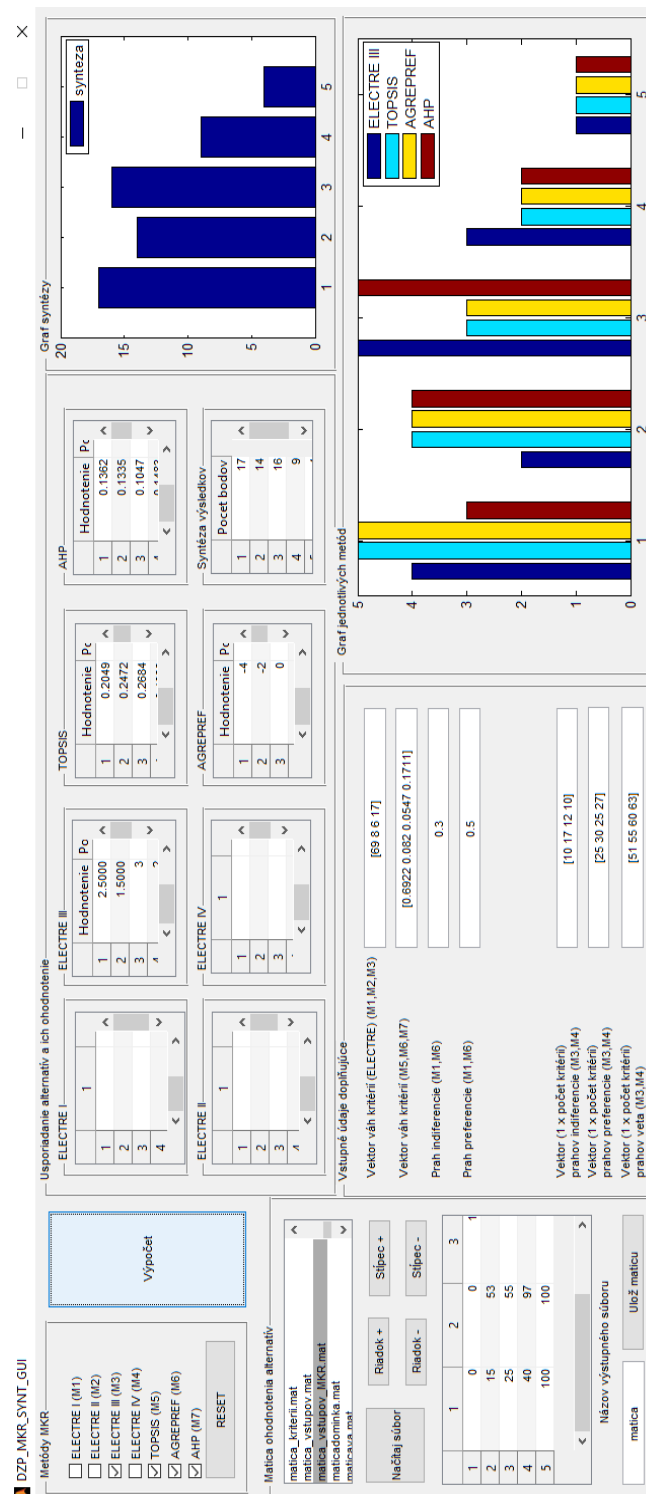
V tomto prípade sú hodnoty matice obodovania nasledovné (TABUĽKA 6):

TABUĽKA 6 Výsledok syntézy riešení úlohy MKR využitím rôznych metód

	ELECTRE III	AGREPREF	TOPSIS	AHP	pb_i	Poradie
V1	4	5	5	3	17	5.
V2	2	4	4	4	14	3.
V3	5	3	3	5	16	4.
V4	3	2	2	2	9	2.
V5	1	1	1	1	4	1.

Z uvedenej tabuľky je zrejmé, že podľa všetkých v práci využitých metód je víťaznou alternatívou alternatíva V5: pridané pracoviská na posty 3,4 a 5. Za týmto jednoznačným výsledkom je možné hľadať pomerne nerovnomerné rozdelenie váh jednotlivých kritérií (jednoznačná preferencia kritéria C1: zvýšenie efektivity výrobného procesu, pred ostatnými

kritériami) v kombinácii s vysokým ohodnotením práve tohto kritéria pri víťaznej alternatíve, keďže táto dokázala vyprodukovať 24 výrobkov vo výrazne najkratšom čase.



Obr. 4 Riešenie úlohy MKR pomocou aplikácie vytvorenej počas doktorandského štúdia

Ohliadnuc od jednoznačného výberu alternatívy V5 ako víťaznej, poradie ostatných alternatív sa v závislosti od metódy mení. Vystáva preto otázka, ako sa vysporiadať s rôznymi výsledkami podľa rôznych metód.

Môžeme usudzovať, že po jednoznačne najlepšej alternatíve V5, sa na 2. mieste podľa syntézy dielčích hodnotení umiestnila alternatíva V4, nasledovaná postupne alternatívami V2, V3 a V1. Podľa grafu na Obr. 4 môžeme ďalej zhodnotiť, že metódy AGREPREF a TOPSIS uprednostnili alternatívu s vyššou investíciou a skrátením času výroby (V3) pred alternatívami s lepším hodnotením v oblastiach dopadu na životné prostredie a veľkosti počiatočnej investície (V1 resp. V2). Naopak, metódy ELECTRE III a AHP uprednostnili alternatívy V1 a V2 pred alternatívou V3.

Riešenie úlohy MKR pomocou uvedených metód je publikované v [18].

V. APLIKÁCIA NAVRHNUTEJ METODIKY PRI OPTIMALIZÁCIÍ VÝROBNÉHO PROCESU VÝROBNEJ LINKY

V nasledujúcej časti je popísaný spôsob aplikácie definovanej metodiky procesu multikriteriálnej optimalizácie výrobnéj linky pri optimalizácii výrobného procesu Pružného Výrobného Systému (model automatizovanej výrobnéj linky v rámci CMMRaPI KKUI FEI TUKE).

V rámci výrobnéj linky PVS je definovaná požiadavka na výrobu 4 rôznych typov výrobkov (mozaík), ktoré sú vytvárané zo 4 rôznych typov farebných kociek: modrých, bielych, zelených a čiernych. Počet jednotlivých typov kociek potrebných pre výrobu daného výrobku je uvedený v TABUĽKA 7, rovnako ako aj kapacitné obmedzenie jednotlivých typov kociek pre jeden výrobný cyklus tejto výrobnéj linky.

TABUĽKA 7 Počet jednotlivých typov kociek potrebných na výrobu výrobkov

Kocka/výrobok	A	B	C	D	Kapacita
Modrá	5	7	7	3	100
Biela	3	4	2	4	80
Zelená	4	6	3	2	90
Čierna	5	5	6	6	120

Zisk z každej modrej kocky obsiahnutej v mozaike je 3 €, pri bielej kocke je to 5 €, pri zelenej 4 € a pri čiernej 2 €. Od počtu kociek, z ktorých sa mozaika skladá, sa taktiež odvíja čas výroby danej mozaiky. V rámci jedného výrobného cyklu je možné vyrobiť maximálne 24 výrobkov, nakoľko takýto počet výrobkov je možné naraz uskladniť. Konkrétne hodnoty dĺžky výroby každého z výrobkov získame zo simulačného modelu výrobnéj linky, ktorý bol realizovaný v rámci diplomovej práce Ing. Slavomíra Vartovníka [19], na ktorej som sa podieľal ako konzultant. Cieľom tejto úlohy MO je definovať výrobný proces tak, aby spĺňal všetky obmedzenia, a aby bol maximalizovaný ako zisk z predaja jednotlivých výrobkov, tak aj časová úspora výrobného procesu.

V rámci spomenutej DP bol vytvorený simulačný model a realizované simulácie rôznych variant výrobného procesu na linke. Pre riešenie úlohy MO je potrebné definovať dĺžku procesu vkladania kocky do mozaiky, ktorá je podľa

vykonaných simulácií stanovená na 1,6 sekundy. Táto hodnota je dôležitá pre definíciu účelovej funkcie časovej úspory. Transformácia údajov v tomto prípade nie je tak rozsiahla ako v prípade riešenia úlohy MKR, nakoľko využiteľnosť simulačného modelu pri tomto type úlohy je obmedzená. Na druhej strane, pri zmene optimalizovaných parametrov by realizácia a transformácia výstupov zo simulačného modelu nabrala na význame.

Po výpočte zisku a časovej úspory z výroby jednotlivých výrobkov boli účelové funkcie definované nasledovne:

$$J_1(x) = 56x_1 + 75x_2 + 55x_3 + 49x_4 \rightarrow \max. \quad (2)$$

$$J_2(x) = 12,8x_1 + 4,8x_2 + 11,2x_3 + 16x_4 \rightarrow \max. \quad (3)$$

Obmedzenie výrobného procesu vyplynuli z kapacitných obmedzení, ako aj z ďalších obmedzení výrobného procesu a boli definované nasledovne:

$$5x_1 + 7x_2 + 7x_3 + 3x_4 \leq 100, \quad (4)$$

$$3x_1 + 4x_2 + 2x_3 + 4x_4 \leq 80, \quad (5)$$

$$4x_1 + 6x_2 + 3x_3 + 2x_4 \leq 90, \quad (6)$$

$$5x_1 + 5x_2 + 6x_3 + 6x_4 \leq 120, \quad (7)$$

$$x_1 + x_2 + x_3 + x_4 \leq 24, \quad (8)$$

$$x_1, x_2, x_3, x_4 \geq 0. \quad (9)$$

Riešenie tejto úlohy multikriteriálnej optimalizácie má 2 fázy: najprv je využitý evolučný algoritmus NSGA-II pre zostavenie Pareto frontu (množiny nedominovaných riešení úlohy MO). Po ukončení výpočtového procesu zoradíme riešenia patriace do Pareto frontu podľa ich vhodnosti pre riešenie úlohy MO – TABUĽKA 8.

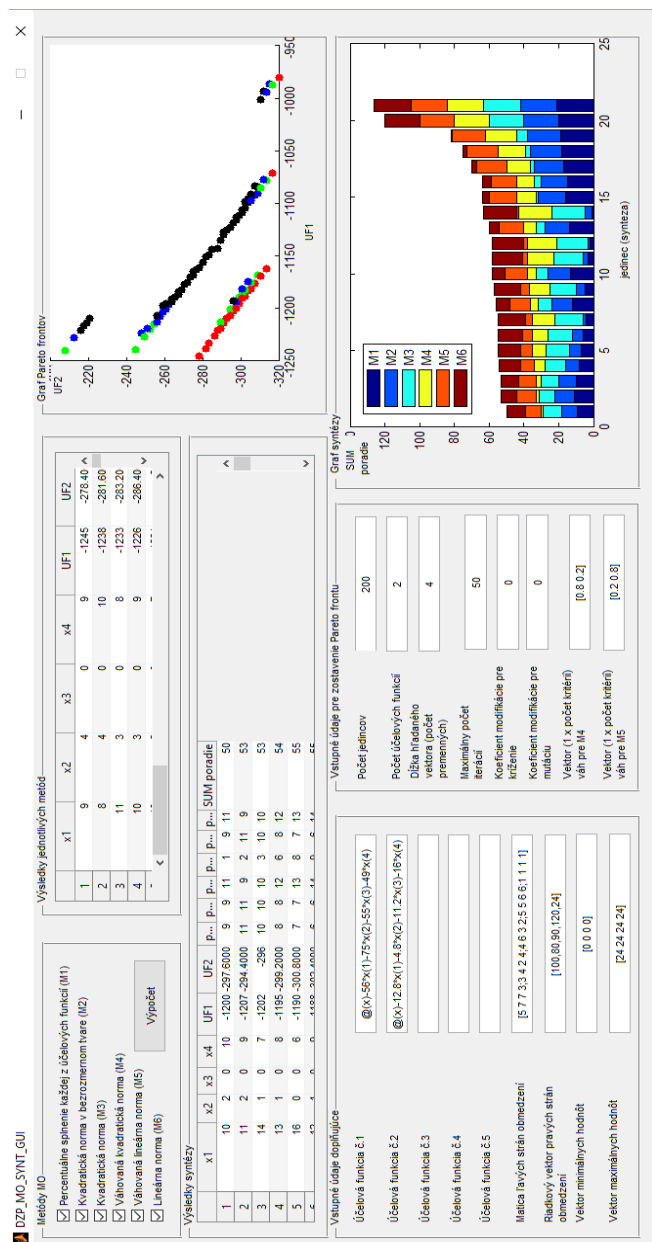
TABUĽKA 8 Jedince Pareto frontu zoradené podľa percentuálneho splnenia každej z účelových funkcií

x_1	x_2	x_3	x_4	$J_1(x)$	$J_2(x)$	$\delta J_1(x)$	$\delta J_2(x)$	$\sum \delta J_i(x)$
12	0	0	10	-1162	-313,6	0,066	0,02	0,086
13	0	0	9	-1169	-310,4	0,061	0,03	0,091
14	0	0	8	-1176	-307,2	0,055	0,04	0,095
11	1	0	10	-1181	-305,6	0,051	0,045	0,096
15	0	0	7	-1183	-304	0,049	0,05	0,099
12	1	0	9	-1188	-302,4	0,045	0,055	0,100
16	0	0	6	-1190	-300,8	0,044	0,06	0,104
13	1	0	8	-1195	-299,2	0,040	0,065	0,105
10	2	0	10	-1200	-297,6	0,036	0,07	0,106
14	1	0	7	-1202	-296	0,034	0,075	0,109
11	2	0	9	-1207	-294,4	0,030	0,08	0,110
15	1	0	6	-1209	-292,8	0,028	0,085	0,113
12	2	0	8	-1214	-291,2	0,024	0,09	0,114
9	3	0	10	-1219	-289,6	0,020	0,095	0,115
13	2	0	7	-1221	-288	0,019	0,1	0,119
10	3	0	9	-1226	-286,4	0,015	0,105	0,120
11	3	0	8	-1233	-283,2	0,009	0,115	0,124
8	4	0	10	-1238	-281,6	0,005	0,12	0,125
9	4	0	9	-1245	-278,4	0	0,13	0,13
6	0	0	15	-1071	-316,8	0,139	0,01	0,149
0	0	0	20	-980	-320	0,212	0	0,212

Riešením tejto úlohy multikriteriálnej optimalizácie je vektor $x=[12,0,0,10]$. To znamená, že podľa metódy percentuálneho splnenia každej z účelových funkcií by mala výrobná linka pri splnení všetkých obmedzení vyrobiť 12 výrobkov typu A a 10 výrobkov typu D. Zisk z jedného výrobného cyklu by v tomto prípade predstavoval 1162 €

a časová úspora oproti výrobe výrobkov s 25 kockami by bola 313,6 sekundy. Odchýlka od maximálnych vypočítaných hodnôt predstavuje 6,67% od maximálnej zistenej hodnoty zisku a 2% od maximálnej zistenej hodnoty časovej úspory. Spolu teda odchýlka od maximálnych zistených hodnôt účelových funkcií predstavuje 8,67%, čo je o 0,43% menej, ako v prípade druhej najlepšej alternatívy.

Keďže výsledky s využitím rôznych metód sú pomerne konfliktné, jedným zo spôsobov realizácie syntézy výsledkov rôznych metód MO je odobranie poradia alternatív podľa ich umiestnenia v optimalizačnom procese podľa každej z využitých metód podľa vzťahu (1).



Obr. 5 Riešenie úlohy MO pomocou aplikácie vytvorenej počas doktorandského štúdia

Proces riešenia úlohy pomocou syntézy 6 matematických metód je zobrazený vo výstupe z aplikácie, ktorá bola pre riešenie úloh MKR a MO vytvorená v programovom prostredí MATLAB.

Ako je možné vidieť z Obr. 5, po syntéze výsledkov sa najvhodnejšou alternatívou riešenia javí alternatíva $x=[10,2,0,10]$ tesne nasledovaná alternatívami $x=[11,2,0,9]$ a $x=[14,1,0,7]$. Zaujímavé je taktiež zistenie, že najlepšie riešenie získané pomocou metód percentuálneho splnenia každej z účelových funkcií, sa pri riešení pomocou syntézy viacerých matematických metód umiestnilo až na 14. mieste.

Z grafu je taktiež možné vidieť pomerne veľkú vyrovnanosť výsledkov syntézy, nakoľko až 17 z 21 jedincov z Pareto frontu delilo od seba pri syntéze 6 metód len 20 bodov. Pri bližšom pohľade na Obr. 5 je možné vidieť že 2 najnižšie a 2 najvyššie položené jedince Pareto frontu sú od ostatných pomerne vzdialené, vďaka čomu môžeme odôvodniť ich zlé umiestnenie v rámci syntézy riešenia pomocou rôznych metód. Vzhľadom k pomerne veľkej vyrovnanosti výsledkov syntézy môžeme taktiež usudzovať, že pri aplikácii rozličných konfigurácií výrobného procesu z popredných priečok syntézy by boli rozdiely v dosiahnutých výsledkoch výrobného procesu minimálne, čomu napovedajú aj malé rozdiely v hodnotách účelových funkcií týchto jedincov.

Vo výstupoch z aplikácie je uvedené poradie jednotlivých jedincov podľa rôznych matematických metód MO, ako aj výsledná hodnota syntézy týchto metód. Taktiež sú uvedené hodnoty účelových funkcií a hodnoty hodnotiacich charakteristík pri jednotlivých matematických metódach. V grafoch sú zobrazené jedince prislúchajúce do prvých piatich frontov, a taktiež je zobrazený výsledok syntézy riešenia úlohy MO.

VI. ZHRNUTIE

Výsledkom práce je komplexná metodika procesu multikriteriálnej optimalizácie výrobných liniek, overená na príkladoch riešených v laboratórnych podmienkach v rámci CMMRaPI KKUI FEI TUKE. Výstupy z modelovaných scenárov riešených v laboratórnych podmienkach demonštrujú využiteľnosť zostavenej metodiky pri riešení problémov v reálnych výrobných procesoch, pričom dôraz pri riešení je kladený predovšetkým na zabezpečenie čo najväčšej miery objektivity zvoleného rozhodnutia. Tento cieľ je zabezpečený využitím metód z rôznym matematickým základom, pričom vyhodnotenie riešenia je v oboch modelových scenároch realizované syntézou výsledkov získaných viacerými metódami. Zvolená metóda syntézy nereflektuje mieru preferencie jednotlivých výsledkov medzi sebou, vytvára len poradie alternatív. Pre exaktnejšie riešenie týchto problémov by bolo možné uvažovať o definícii spôsobu syntézy metód zohľadňujúcej aj mieru preferencie (rozdiel užitočnosti resp. hodnotiacej charakteristiky danej metódy) medzi jednotlivými alternatívami riešenia.

Predpokladom pre riešenie aplikčných úloh z oblasti multikriteriálneho rozhodovania a multikriteriálnej optimalizácie bola realizácia simulačných modelov rôznych konfigurácií výrobných liniek, ktorej cieľov bol zisk dát

potrebných pre vstupy do procesu rozhodovania resp. optimalizácie.

V rámci práce je pomocou metód multikriteriálneho rozhodovania zvolená optimálna konfigurácia modelu výrobnéj linky s ohľadom na dĺžku výrobného procesu, efektivitu využitia jednotlivých pracovísk, environmentálny aspekt a veľkosť investície rešpektujú kapacitné a priestorové obmedzenia pre potenciálnu implementáciu zvoleného riešenia.

Druhou aplikačnou oblasťou je voľba optimálneho produkčného procesu riešená kombináciou metód umelej inteligencie (modifikovaný algoritmus NSGA-II) a tradičných matematických metód vzhľadom na optimalizáciu zisku a času výroby, rešpektujú obmedzenia výrobného procesu riešeného modelu výrobnéj linky.

V oboch aplikačných oblastiach riešenie realizované ako pomocou jednotlivých metód, tak aj pomocou syntézy riešení získaných jednotlivými metódami multikriteriálneho rozhodovania resp. optimalizácie. Vytvorená aplikácia umožňuje syntézu 7 metód riešenia úloh multikriteriálneho rozhodovania a 6 matematických metód multikriteriálnej optimalizácie. Taktiež je možné zvoliť akúkoľvek kombináciu týchto metód, čo vytvára široké portfólio možností riešenia úloh z vymedzenej oblasti, pričom voľba metód závisí len od preferencií rozhodovateľa. Aplikácia taktiež umožňuje automatizáciu procesov transformácie vstupných dát do formy potrebnej pre proces multikriteriálnej optimalizácie, ako aj objektivizáciu váh hodnotiacich kritérií bodovacou metódou alebo metódou expertov. Komplexnosťou realizácie programov výstup prekračuje hranice zvolenej aplikačnej oblasti a je využiteľný pre riešenie úloh z rôznych iných oblastí, v ktorých je možné využiť metódy, ktoré boli v rámci práce programovo spracované.

POĎAKOVANIE

Článok, rovnako ako aj dizertačná práca je výsledkom riešenia projektu:

- projekt Univerzitný vedecký park Technicom pre inovačné aplikácie s podporou znalostných technológií, kód ITMS:26220220182, spolufinancovaný zo zdrojov Európskeho fondu regionálneho rozvoja, Centrum pre nedeštruktívnu diagnostiku technologických procesov so štandardným softvérovým vybavením pre riadenie a komunikáciu (aktivita 3.1), (2013 - 2015);
- projekt Univerzitný vedecký park Technicom pre inovačné aplikácie s podporou znalostných technológií - II.fáza, kód ITMS:313011D232, spolufinancovaný zo zdrojov Európskeho fondu regionálneho rozvoja, (2015 - 2017), Centrum pre nedeštruktívnu diagnostiku technologických procesov so štandardným softvérovým vybavením pre riadenie a komunikáciu (aktivita 3.1, PP7), (2015 - 2017);
- projekt KEGA c.001TUKE-4/2015, CyberLabTrainSystem – demonstrátor a tréner informáčno-riadiaceho systému - inovácia (2015 - 2017) ;grant FEI TUKE 2015-33 s názvom Výskumné laboratórium nelineárnych podaktuovaných systémov

(Research laboratory for nonlinear underactuated systems), (1/2017 - 12/2017);

- projekt ALICE KE FEI TUKE (0222/2016 - 2/2016-DOT) s názvom Experiment ALICE na LHC v CERN: Štúdium silno interagujúcej hmoty v extrémnych podmienkach, (2016-2020).

LITERATÚRA

- [1] OLIVEIRA, Márcia; FONTES, Dalila BMM; PEREIRA, Teresa. Multicriteria decision making: a case study in the automobile industry. *Annals of Management Science*, 2014, 3.1: 109.
- [2] SALMINEN, Pekka; HOKKANEN, Joonas; LAHDELMA, Risto. Comparing multi-criteria methods in the context of environmental problems. *European Journal of Operational Research*, 1998, 104.3: 485-496.
- [3] RAO, Ravipudi Venkata. Decision making in the manufacturing environment: using graph theory and fuzzy multiple attribute decision making methods. Springer Science & Business Media, 2007.
- [4] HO, William; XU, Xiaowei; DEY, Prasanta K. Multi-criteria decision making approaches for supplier evaluation and selection: A literature review. *European Journal of Operational Research*, 2010, 202.1: 16-24.
- [5] CHAI, Junyi; LIU, James NK; NGAI, Eric WT. Application of decision-making techniques in supplier selection: A systematic review of literature. *Expert Systems with Applications*, 2013, 40.10: 3872-3885.
- [6] LI, Hui; ZHANG, Qingfu. Multiobjective optimization problems with complicated Pareto sets, MOEA/D and NSGA-II. *IEEE Transactions on evolutionary computation*, 2009, 13.2: 284-302.
- [7] FONSECA, Carlos M., et al. Genetic Algorithms for Multiobjective Optimization: Formulation Discussion and Generalization. In: ICGA. 1993. p. 416-423.
- [8] TABOADA, Heidi A., et al. Practical solutions for multi-objective optimization: An application to system reliability design problems. *Reliability Engineering & System Safety*, 2007, 92.3: 314-322.
- [9] MANSOURI, S. Afshin. A multi-objective genetic algorithm for mixed-model sequencing on JIT assembly lines. *European Journal of Operational Research*, 2005, 167.3: 696-716.
- [10] BAUTISTA, Joaquín; PEREIRA, Jordi. Ant algorithms for a time and space constrained assembly line balancing problem. *European journal of operational research*, 2007, 177.3: 2016-2032.
- [11] SABUNCUOGLU, Ihsan; EREL, Erdal; ALP, Arda. Ant colony optimization for the single model U-type assembly line balancing problem. *International Journal of Production Economics*, 2009, 120.2: 287-300.
- [12] CHOI, Young-Keun; LEE, Dong Myung; CHO, Yeong Bin. An approach to multi-criteria assembly sequence planning using genetic algorithms. *The International Journal of Advanced Manufacturing Technology*, 2009, 42.1-2: 180-188.
- [13] FARINA, Marco; DEB, Kalyanmoy; AMATO, Paolo. Dynamic multiobjective optimization problems: test cases, approximations, and applications. *IEEE Transactions on evolutionary computation*, 2004, 8.5: 425-442.
- [14] ÖZCAN, Uğur; TOKLU, Bilal. Multiple-criteria decision-making in two-sided assembly line balancing: A goal programming and a fuzzy goal programming models. *Computers & Operations Research*, 2009, 36.6: 1955-1965.
- [15] ČABALA, J., JADLOVSKÝ J.: Application of Stateflow Diagrams in Production Line Modeling. 2016. In: SAMI 2016. - Danvers : IEEE, 2016 S. 125-130. - ISBN 978-1-4673-8739-2
- [16] ROSINOVÁ, Danica; DÚBRAVSKÁ Mária : Optimalizácia.1.vyd. Bratislava : STU, 2008. 190 s. - ISBN: 8022727952.
- [17] ČABALA, J., JADLOVSKÝ J.: Optimization Toolbox Usage in Solving Vector Optimization Tasks - 2015. In: Technical Computing Bratislava 2014 Proceedings. - Saarbrücken : Lap Lambert Academic Publishing, 2015 P. 45-64. - ISBN 978-3-659-40792-5

-
- [18] ČABALA, J., JADLOVSKÝ J.: Solving optimal assembly line configuration task by multi-objective decision making methods. 2017. In: Acta Electrotechnica et Informatica. Roč. 17, č. 2 (2017), s. 53-60. - ISSN 1335-8243
- [19] VARTOVNÍK, Slavomír: Modelovanie a vizualizácia priemyselných procesov, Diplomová práca, KKUI FEI TUKE, Košice, 2016.

Nové metódy obrazovej steganografie

Vladimír Hajduk

Katedra elektroniky a multimediálnych telekomunikácií,
Fakulta elektrotechniky a informatiky,
Technická univerzita v Košiciach
Košice, Slovensko
vladimir.hajduk@tuke.sk

Dušan Levický

Katedra elektroniky a multimediálnych telekomunikácií,
Fakulta elektrotechniky a informatiky,
Technická univerzita v Košiciach
Košice, Slovensko
dusan.levicky@tuke.sk

Abstrakt—Tento článok predstavuje vybrané metódy obrazovej steganografie publikované v dizertačnej práci autora. Statické obrazy použité v metódach boli pred procesom vkladania transformované diskretnou waveletovou transformáciou, jednalo sa teda o obrazovú steganografiu v transformačnej oblasti. Publikácia predstavuje vkladaciu metódu rešpektujúcu konverziu medzi viacerými farebnými obrazovými modelmi bez straty vlozenej informácie. Táto metóda bola použitá na vkladanie v nástrojoch steganografie s výberom krycieho obrazu. Vytvorený algoritmus priniesol zníženie vplyvu vkladania na vybraný krycí obraz v porovnaní s náhodou vybraným krycím obrazom. Metóda bola následne zrýchlená a jej účinnosť zvýšená vnútro-snímkomým prehľadávaním.

Kľúčové slová—výber krycieho obrazu; obrazová steganografia; obrazová stegoanalýza; ukryvanie informácií; tajná správa; porovnanie


Abstract—This article presents selected methods of image steganography published in the dissertation thesis of the author. The static images utilized in the methods were transformed by the discrete wavelet transform before the embedding process, so it was a steganography in the transformation domain. The publication presents an insertion method that respects the conversion between multiple color image models without any secret information loss. This method was used for embedding in cover selection steganography tools. The proposed algorithm has reduced the impact of insertion on the selected cover image compared to the randomly selected cover image. The method was then accelerated, and its effectiveness enhanced by intra-image scanning.

Keywords—cover selection, image steganography, image steganalysis, information hiding, secret message, comparison

I. ÚVOD

Steganografia vo všeobecnosti predstavuje vednú disciplínu, ktorá sa zaoberá špecifickou metódou utajenej komunikácie. V tejto metóde sa tajná správa vloží (ukryje) do neškodne vyzerajúceho média, ktoré sa prenáša bez toho, aby vzbudilo podozrenie. Steganografia spadá podľa [1] [2] do širšej oblasti nazývanej ukryvanie informácií (Obr. 1). Táto základná disciplína v sebe zahŕňa štyri podoblasti, a to podprahové kanály, ktoré predstavujú komunikačné kanály

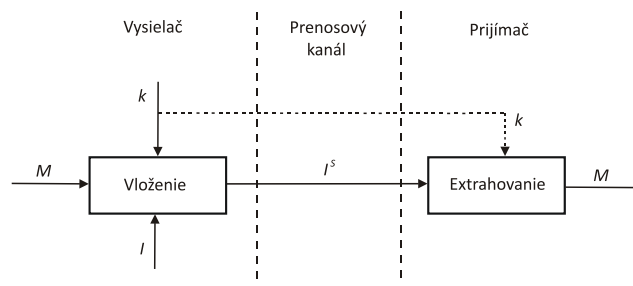
použité na iný účel ako je ten, pre ktorý boli navrhnuté, anonymita v zmysle poskytnutia autorizácie zdroja dát, ochrana obsahu a steganografia, ako spôsob utajenej komunikácia prostredníctvom podprahových kanálov.



Obr. 1. Klasifikácia metód ukrytia informácie

Medzi metódy ochrany obsahu spadajú rôzne typy vodoznakov (krehký, viditeľný, neviditeľný) a ochrana obsahu pomocou biometrie.

V technickej, lingvistickej alebo modernej steganografii sa ich model v základe nemení. Na Obr. 2 je znázornený všeobecný model steganografie, ktorý sa vo väčšine literatúry uvádza rovnaký [3] [4] [5].



Obr. 2. Model všeobecnej steganografie

Všeobecný model steganografie možno definovať v troch oblastiach. Sú to vysielač, prenosový kanál a prijímač. Na strane vysielača prebieha operácia vloženia tajnej správy M do krycích dát I za prítomnosti tajného kľúča k , ktorý slúži na prípadné šifrovanie tajnej správy pred vložením. Výsledkom tohto procesu sú tzv. označené dáta I^s , ktoré sú vyslané cez prenosový kanál k ich adresátovi. Počas prenosu môžu byť


označené dáta zachytené nepovolanou osobou (útočník) a podrobené analýze. Analýzou správ s cieľom prelomiť steganografický systém sa zaoberá stegoanalýza. Ak správa nájde svojho adresáta, z prijatých označených dát P^s (stego dát) sa extrahuje tajná správa. Extrakcia predstavuje inverznú operáciu k operácii vloženia. Ak bol použitý tajný kľúč k pri vkladani, je nutné, aby bol prítomný aj na strane prijímača. Niektoré metódy požadujú pri extrakcii aj prítomnosť krycích dát.

Stegoanalýza sa zaoberá odhalením utajenej komunikácie, ktorá bola vytvorená steganografickým systémom. Úlohou stegoanalýzy je sledovať prenosový kanál s cieľom odhaliť stopy použitia steganografického systému. Stegoanalýza zachytenej komunikácie je považovaná za úspešnú, ak je útočník presvedčený o prebiehajúcej tajnej komunikácii s dostatočne veľkou pravdepodobnosťou. Úspešnú stegoanalýzu je možné nazvať ako prelomenie steganografického systému. Metódy stegoanalýzy sú výpočtovo podstatne náročnejšie ako metódy steganografie, a preto vyžadujú vyššie výpočtové vybavenie. Základom súčasnej stegoanalýzy je fakt, že vloženie tajnej správy má vplyv na určité štatistické parametre krycieho média. Aplikovanie stegoanalýzy sa nazýva útok. Ak je cieľom stegoanalýzy objaviť známky vlozenej tajnej informácie v statickom obraze, jedná sa o obrazovú stegoanalýzu [4] [6].

II. STEGANOGRAFIA S VÝBEROM KRYCIEHO OBRÁZU

V steganografii s generovaním krycieho objektu sa na základe tajnej správy vytvorí konkrétny krycí objekt. Ak sa vhodný krycí objekt k tajnej správe vyhľadá v databáze krycích objektov, jedná sa o steganografiu s výberom krycieho objektu, v obrazovej steganografii analogicky, steganografiu s výberom krycieho obrazu (Cover Selection steganography, CS steganography) [7].

Na Obr. 3 je zobrazená všeobecná bloková schéma steganografie s výberom krycieho obrazu, ktorá pozostáva z niekoľkých blokov. Sú to tajná správa, databáza krycích obrazov, vkladanie (tajnej správy), porovnanie a prenos.



Obr. 3. Bloková schéma steganografie s výberom krycieho obrazu

Tajná správa vstupuje do bloku vkladania, kde sa vloží do prvého krycieho obrazu z databázy. Výstupom je označený obraz, ktorý sa v bloku porovnania podrobí analýze. Zisťuje sa, či určitý porovnávací parameter extrahovaný z obrazu vyhovuje zvolenému kritériu. V prípade splnenia požadovaného kritéria sa obraz posielá k adresátovi. V opačnom prípade sa vyberie ďalší krycí obraz a celý proces sa zopakuje. Ak sa nenájde ani jeden označený obraz, ktorý by kritériu vyhovoval, vyberie sa ten, ktorý je k zvolenej hranici najbližšie.

A. Porovnanie

V pôvodných CS steganografických algoritmoch v tejto práci, ktoré predpokladajú prípad bez vedomosti o stegoanalýze, bol zvolený parameter *počet zmien* (Number of Changes, $NoCh$), teda počet zmenených bitov po vkladani tajnej správy. V praxi to znamená, že CS metóda hľadá taký označený obraz, v ktorom bolo zmenených najmenej bitov. Parameter $NoCh$ sa vypočíta podľa vzťahu (1).

$$NoCh = \sum_{i=1}^k |s(i) - c(i)| \quad (1)$$

kde s predstavuje sekvenciu bitov tajnej správy, c sekvenciu bitov zodpovedajúcej vkladacej oblasti v krycom obraze a k počet bitov tajnej správy.

B. Vkladanie tajnej správy v DWT oblasti

V práci je uvedených viacero pôvodných steganografických metód. Všetky z týchto metód využívajú transformovanie krycieho obrazu do transformačnej oblasti. Teda jedná sa o transformačné metódy steganografie. Transformovanie obrazu pred samotným vladením tajnej správy zabezpečuje vyššiu odolnosť algoritmu voči stegoanalýze v priestorovej oblasti. Vo všetkých nástrojoch steganografie sa správa vkladala v oblasti po DWT transformácii. Výsledkom je nástroj odolnejší voči stegoanalýze extrahujúcej štatistiky z priestorovej a transformačnej oblasti po DCT transformácii. Na transformáciu signálov sa používa viacero druhov waveletov, avšak pre prípad transformácie diskretných signálov je výhodný Haarov wavelet.

C. Substitučná metóda LSB

Samotné vkladanie sa v navrhnutých steganografických algoritmoch vykonáva substitúciou najmenej významných bitov jednotlivých transformačných koeficientov, teda metódou LSB. Z teórie pravdepodobnosti vyplýva, že so zvyšujúcou sa dĺžkou tajnej správy sa počet bitov, ktoré sa po vkladani zmenia a počet bitov, ktoré sú na daných pozíciách rovnaké ako bity tajnej správy vyrovnáva. Teda platí, že počet bitov, ktorých hodnota sa po vkladani zmení sa blíži k hodnote rovnej polovici celkového počtu vkladanych bitov k .

Pri extrakcii sa najprv LSB bity z daných koeficientov usporiadajú do kódových slov, prevedú do desiatkového tvaru a ak bola pôvodná tajná správa v textovej forme, s využitím ASCII tabuľky sa získajú znaky pôvodného textu. Vkladanie tajnej správy v navrhnutých steganografických algoritmoch teda patrí do oblasti transformačných a substitučných metód, resp. je ich kombináciou.

Aj pri krátkych správach sa po vkladani zmení v priemere polovica bitov. Teda čím viac výpočtov s rôznymi správami a obrazmi sa vykoná, tým sa priemer blíži k spomínanej polovici. Cieľom CS metódy je však hľadanie extrémov. To znamená, že sa hľadá obraz, v ktorom sa po vložení tajnej správy zmení čo najmenej bitov. Aj v tomto prípade platí, že so vzrastajúcim počtom výpočtov sa rozdiel medzi extrémami zvyšuje. Počet výpočtov priamo závisí od veľkosti databázy krycích obrazov.

D. Obrazová databáza

Databáza krycích obrazov pre CS metódy sa vyznačovala týmito vlastnosťami:

- prirodzené a farebné obrázky
- jasová rozlišovacia schopnosť – 24bit/op
- priestorová rozlišovacia schopnosť – 512×512 op (veľkosť originálnych obrazov bola upravená na uvedenú veľkosť)
- obrazový štandard BMP (konverzia JPEG obrazov na BMP obrázky)
- veľkosť databázy – 2 000 obrazov (výber z celkového množstva 10 000 obrazov)

Z uvedených 10 000 obrazov bolo vybraných 2 000 obrazov, ktorých priestorová rozlišovacia schopnosť bola upravená na veľkosť 512×512 op. Táto zmena veľkosti bola vykonaná z dôvodu dosiahnutia jasne reprodukovateľných výsledkov.

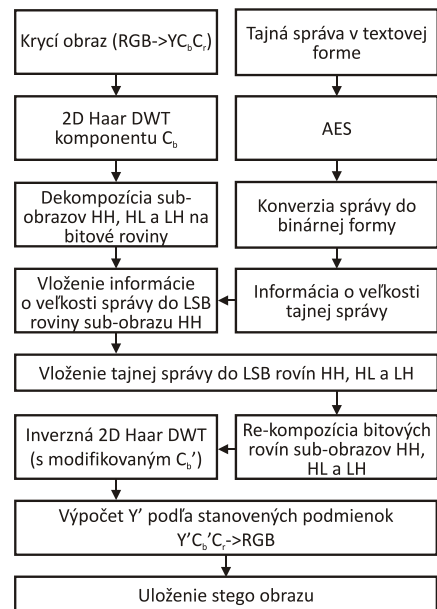
III. NAVRHNUTÉ METÓDY A EXPERIMENTÁLNE VÝSLEDKY

Všetky experimenty v tejto kapitole boli vykonané v programovom prostredí MATLAB, na počítači s procesorom Intel Core Quad 2,66GHz a operačnou pamäťou 4GB.

A. Vkladacia metóda založená na obrazovom modeli $YCbCr$ a DWT

Prvou metódou obrazovej steganografie bola metóda vkladajúca tajnú správu v oblasti po DWT transformácii [8]. Navrhnutá metóda sa vyznačuje vkladáním tajnej správy v textovej forme do farebného obrazu. Metóda zabezpečuje po vkladání do chrominancnej zložky bezstratovú kompresiu medzi farebnými obrazovými modelmi RGB a $YCbCr$. Tajná správa sa vkladá do modrej zložky C_b , pretože na zmenu modrej farby je ľudské oko najmenej citlivé. Pred vkladáním sa komponent C_b transformuje pomocou dvojrozsmernej DWT s Haarovým waveletom a samotné vkladanie ovplyvňuje LSB roviny sub-obrazov HH, HL a LH. Bloková schéma celého algoritmu je zobrazená na Obr. 4. Farebný krycí obraz načítaný vo farebnom obrazovom modeli RGB je v prvom kroku prevedený do farebného obrazového modelu $YCbCr$. Komponent C_b je transformovaný pomocou Haarového waveletu do waveletovej oblasti a vzniknuté sub-obrazy HH, HL a LH dekomponované na bitové roviny. V druhej vetve sa načíta tajná správa v textovej forme, kóduje sa pomocou ASCII kódu a následne šifruje symetrickou šifrou AES v režime zreťazenia zašifrovaného textu CBC (Cipher Block Chaining). Šifrovanie zvyšuje celkovú bezpečnosť systému, pričom režim CBC využíva spätnú väzbu, čím sa dosiahne, že šifrovaním toho istého bloku sa získajú rôzne bloky zašifrovaného textu [9]. Šifrovanie navyše odstráni štatistické charakteristiky pôvodného textu. Každý prvok zašifrovaného textu (0-255) sa prevedie do binárnej formy (8bit). Aby bolo v prijímači jasné, aký dlhý reťazec tajnej správy bol vložený, do prvých 20 bitov LSB roviny HH sa vloží informácia o dĺžke správy. 20 bitov je postačujúcich pri využití

maximálnej kapacity pre obraz do HD rozlíšenia 1280×720 . Pri vyššom rozlíšení obrazu je potrebné rezervovať väčší počet bitov. Zašifrovaná tajná správa sa vloží priamo za informáciu o jej dĺžke do LSB roviny HH. Ak je jej dĺžka väčšia ako kapacita tejto roviny, vkladanie pokračuje v LSB rovinách sub-obrazov LH a HL. Vkladanie sa vykonáva na báze substitúcie. Po vložení sa vyskladáním sub-pásiam a inverznou DWT transformáciou získa výsledný component C_b' .



Obr. 4 Bloková schéma navrhnutého metódy steganografie na báze DWT

Modifikácia komponentu C_b však môže spôsobiť to, že po konverzii z farebného obrazového modelu $YCbCr$ na RGB sa môžu niektoré hodnoty ocitnúť mimo rozsah 0-255. Takéto hodnoty sa zaokrúhľia na 0 alebo 255, čo spôsobí určitú stratu informácie a to môže vyústiť k chybnému extrakcii tajnej správy. Aby sa tomu predišlo, je potrebné upraviť prvky matice Y takým spôsobom, že sa vypočíta dolná hranica Y_d a horná hranica Y_u pre každý komponent RGB modelu v závislosti od matíc C_b' a C_r . Pôvodné prvky matice Y , ktoré presahujú dané hranice sa nastavujú na Y_d , resp. Y_u . Konkrétny postup úpravy je uvedený v dizertačnej práci.

Proces extrakcie tajnej správy v prijímači vyzerá nasledovne:

- načítanie stego obrazu a jeho konverzia do $YCbCr$
- 2D Haar DWT zložky C_b
- dekompozícia na sub-pásma
- extrakcia informácie o dĺžke tajnej správy (prvých 20 LSB bitov z HH)
- extrakcia tajnej správy z LSB rovín sub-obrazu HH, prípadne HL a LH
- konverzia bitov tajnej správy na decimálne hodnoty (bloky 8 bitov)

- dešifrovanie AES s použitím rovnakého kľúča ako pri šifrovaní
- prevedenie textu z ASCII kódu na typ „char“

Výsledkom extrakcie je pôvodná tajná správa v textovej podobe. Navrhnutá vkladacia metóda bola testovaná objektívnymi hodnoteniami kvality PSNR a MSE. Výsledné hodnoty predstavujú priemerné hodnoty zohľadňujúce všetky tri komponenty R, G a B. V TAB. I sú zobrazené výsledky meraní pre dva testovacie obrázky s priestorovou rozlišovacou schopnosťou 256 × 256op a 512 × 512op a tri veľkosti tajných správ C_{HH} (63), C_{HH+HL} a C_{HH+HL+LH}. C_{HH} vyjadruje využitie maximálnej kapacity sub-pásma HH, C_{HH+HL} maximálnu kapacitu HH+HL a C_{HH+HL+LH} využitie celkovej kapacity obrazu pre danú metódu (HH+HL+LH). Vkladaním do obrazu o rozmere 512 × 512op kapacita C_{HH} = 65 388bit, C_{HH+HL} = 130 924bit a C_{HH+HL+LH} = 196 460bit. V tabuľke sú porovnané výsledky s použitím a bez použitia šifrovania AES. Keďže AES v tomto prípade pracuje v móde CBC, používa tzv. inicializačný vektor (IV) o veľkosti 16 bajtov (128bit), ktorý sa pripojí na začiatok zašifrovanej správy. Kapacita sub-obrazu HH sa vypočíta podľa vzťahu (2).

$$C_{HH} = \frac{m \cdot n}{4} - 20 - 128 \quad (2)$$

kde *m* a *n* sú rozmery obrazu, 20 predstavuje počet bitov rezervovaných na vloženie informácie o veľkosti správy a 128 počet bitov IV.

TABUĽKA I. HODNOTY PSNR A MSE TROCH TESTOVACÍCH STEGO OBRAZOV V ZÁVISLOSTI OD VEĽKOSTI TAJNEJ SPRÁVY A ŠIFROVANIA

Testovací obraz	Rozmer obrazu [op]	Veľkosť tajnej správy	s AES		bez AES	
			PSNR [dB]	MSE [-]	PSNR [dB]	MSE [-]
Lena	256 × 256	C _{HH}	50,60	0,56	50,67	0,55
		C _{HH+HL}	48,8	0,85	48,89	0,83
		C _{HH+HL+LH}	47,31	1,20	47,39	1,18
	512 × 512	C _{HH}	50,57	0,56	50,63	0,56
		C _{HH+HL}	48,77	0,86	48,85	0,84
		C _{HH+HL+LH}	47,11	1,26	47,18	1,24
Baboon	256 × 256	C _{HH}	50,53	0,57	50,53	0,57
		C _{HH+HL}	48,87	0,84	48,88	0,84
		C _{HH+HL+LH}	47,36	1,19	47,37	1,19
	512 × 512	C _{HH}	50,53	0,57	50,54	0,57
		C _{HH+HL}	48,87	0,84	48,84	0,84
		C _{HH+HL+LH}	47,34	1,19	47,37	1,19
Girl	384 × 256	C _{HH}	50,67	0,55	50,70	0,55
		C _{HH+HL}	48,81	0,85	48,96	0,83
		C _{HH+HL+LH}	47,23	1,22	47,28	1,21
	768 × 512	C _{HH}	50,68	0,55	50,69	0,55
		C _{HH+HL}	48,77	0,86	48,91	0,83
		C _{HH+HL+LH}	47,05	1,28	47,09	1,26

Výsledky meraní v TAB. I sa pre jednotlivé testovacie obrázky veľmi nelíšili. Hodnota PSNR sa so zväčšujúcou sa

tajnou správou klesala, pričom MSE sa správalo opačne. Využitie celej kapacity LSB roviny sub-obrazu HH (C_{HH}) na vloženie tajnej správy vyústilo v hodnotu PSNR okolo 50,6dB. Vloženie približne dvakrát väčšej správy (C_{HH+HL}) spôsobilo v priemere pokles o 1,8dB, a využitie plnej kapacity C_{HH+HL+LH} ďalší pokles o 1,4dB. Zmena o takéto hodnoty nie je systémom HVS postrehnuteľná. Z výsledkov je zrejmé, že metóda bez použitia šifrovania AES dosiahla o niekoľko stotín jednotiek lepšie výsledky. Pravdepodobne je to spôsobené vložením IV, ktoré zvyšuje počet zmenených bitov po vložení.

V TAB. II boli výsledky porovnané s dvoma steganografickými metódami, LSB metódou [10] a DCT steganografickým nástrojom [11].

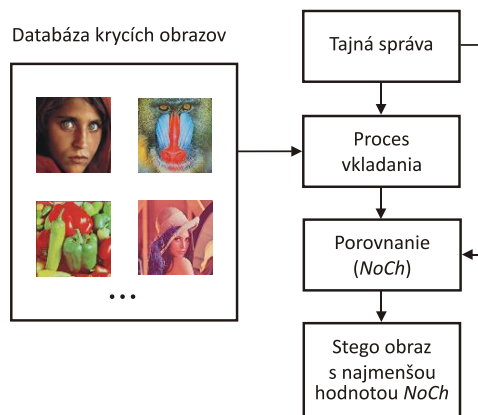
TABUĽKA II. POROVNANIE NAVRHNUTEJ METÓDY S METÓDAMI LSB A DCT Z POHĽADU PSNR MEDZI KRYCÍM A OZNAČENÝM OBRAZOM

Rozmer obrazu [op]	Veľkosť tajnej správy [bit]	Navrhnutá metóda DWT	LSB [10]	DCT [11]
		PSNR [dB]	PSNR [dB]	PSNR [dB]
256 × 256	49 004	47,31	42,34	NA
512 × 512	4 096	52,02	46,31	50,06

Do obrazu s rozmerom 256 × 256op bola vložená správa s veľkosťou 49 004bit, čo predstavuje využitie plnej kapacity obrazu C_{HH+HL+LH} s daným počtom obrazových prvkov. Vloženie správy sa vykonalo postupne tromi steganografickými nástrojmi. Navrhnutá metóda DWT dosiahla hodnotu PSNR = 47,31dB, zatiaľ čo metóda LSB hodnotu nižšiu takmer o 5dB. Tajná správa s takouto veľkosťou presiahla maximálnu kapacitu uvedenej metódy DCT. Do obrazu s rozlíšením 512 × 512op bola vkladaná správa s veľkosťou 4 096bit. Aj v tomto prípade dosiahla najlepší výsledok s PSNR = 52,02dB navrhovaná metóda.

B. Steganografia s výmerom krycieho obrazu

Na Obr. 5 je znázornená bloková schéma CS metódy.

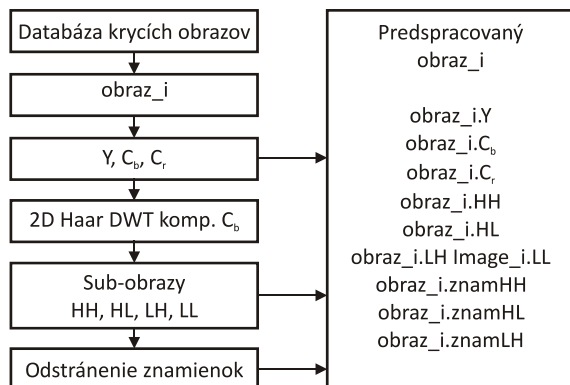


Obr. 5. Proces steganografie na báze výberu krycieho obrazu

Bity tajnej správy sú porovnané s bitmi zodpovedajúcej časti LSB roviny sub-obrazov HH, HL a LH jednotlivých

krycích obrazov. Obraz, ktorý dosiahol minimálnu hodnotu porovnávacieho kritéria (*NoCh*) sa vyberie a označí tajnou správou. Vzniknutý označený (stego) obraz následne putuje k adresátovi. Adresát z prijatého obrazu extrahuje tajnú správu. Proces extrakcie sa skladá z inverzných operácií k operáciám vkladania.

Vkladací algoritmus je založený na metóde opísanej v predchádzajúcej kapitole. DWT transformácia a dekompozícia každého obrazu v obrazovej databáze je časovo náročná, a preto je najprv predspracovaná. Proces jej predspracovania zobrazuje Obr. 6.



Obr. 6. Predspracovanie databázy krycích obrazov

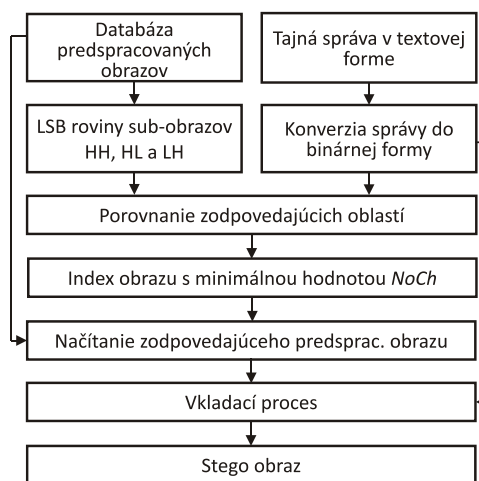
Proces predspracovania *i*-tého krycieho obrazu prebieha v nasledujúcich krokoch:

- Obraz je dekomponovaný na zložky *Y*, *C_b* a *C_r*. Pre ďalšie spracovanie sa vyberie komponent *C_b*, pretože na zmenu modrej farby je HVS najmenej citlivé.
- DWT transformácia zložky *C_b* do transformačnej oblasti za pomoci Haarovho waveletu. Výstupom sú sub-obrazy HH, HL, LH a LL.
- Odstránenie znamienok zo subpásíem HH, HL a LH. Ďalej sa pracuje s kladnými číslami.
- Uloženie komponentov z predošlých krokov ako štruktúru pre daný obraz v databáze.

Všetky 4 kroky sa vykonajú pre každý obraz v databáze krycích obrazov. Výsledkom je databáza predspracovaných obrazov. Proces výberu optimálneho krycieho obrazu a vloženia tajnej správy je uvedený na Obr. 7 a pozostáva z nasledujúcich krokov:

- Tajná správa v textovej forme je konvertovaná na binárnu pomocou ASCII kódu.
- V bloku „Porovnanie zodpovedajúcich oblastí“ sa vypočíta Hammingová vzdialenosť medzi bitmi tajnej správy a LSB bitmi sub-pásíem HH, HL a LH, ktoré majú byť nahradené bitmi tajnej správy a ktoré sú vyberané sekvenčne.
- Obraz s najmenšou Hammingovou vzdialenosťou je zvolený ako optimálny obraz na vloženie tajnej správy.

- Na vloženie tajnej správy sa použije DWT steganografická metóda.
- Výsledkom je označený obraz, pozostávajúci z modifikovaného komponentu *C_b* a pôvodných komponentov *Y* a *C_r*, ktorý putuje k príjemcovi.



Obr. 7. Postup vkladania tajnej správy do vybraného krycieho obrazu

Uvedená metóda CS [12] bola testovaná z pohľadu redukcie spôsobených zmien vzhľadom na vkladanie do ľubovoľného obrazu (redukcia parametra *NoCh*), z pohľadu vplyvu veľkosti obrazovej databázy na veľkosť *NoCh* a z pohľadu vplyvu veľkosti tajnej správy na celkový čas výberu optimálneho obrazu a jeho označenie tajnou správou. Do obrazov bolo vkladáných 10 rôznych tajných správ, pričom výsledky v tabuľkách a grafe predstavujú priemerné hodnoty pre jednu správu.

V TAB. III sú zobrazené výsledky prvého experimentu, v ktorom boli postupne vkladané tajné správy s tromi rôznymi veľkosťami *k* do obrazu s rozmerom 512 × 512. Databáza krycích obrazov obsahovala 2 000 obrazov. Vkladanie bolo vykonané s použitím CS metódy a počet zmenených bitov po vkladaní *NoCh* porovnaný s obvyčajným náhodným výberom krycieho obrazu. Náhodnému výberu zodpovedá *NoCh* rovné polovici počtu bitov tajnej správy.

TABUĽKA III. ROZDIEL V HODNOTÁCH *NoCh* MEDZI KRYCÍM OBRAZ VYBRANÝM CS METÓDOU A NÁHODNE ZVOLENÝM KRYCÍM OBRAZOM

		Náhodný výber	Metóda CS		
Rozmer obrazu [op]	<i>k</i> [bit]	<i>NoCh</i> [-]	<i>NoCh</i> [-]	Rozdiel [-]	Rozdiel [%]
512 × 512	21 760	10 880	9 837	1 043	9,59
	43 520	21 760	19 726	2 034	9,35
	65 280	32 640	29 376	3 264	10

Rozdiel (*Difference, Diff.*) (3) pri všetkých troch veľkostiach správ predstavoval hodnotu medzi 9% a 10%. To znamená, že *NoCh* optimálneho krycieho obrazu v databáze 2 000 obrazov napr. pre tajnú správu o veľkosti 65 280 bitov

predstavuje 90% z priemerného počtu zmien po vložení do náhodného obrazu. Z toho vyplýva, že metóda CS dosiahla 10%-nú úsporu substituovanej oblasti bitov (pre dané parametre experimentu). Menší počet zmenených bitov priamo súvisí s modifikáciou krycieho obrazu a teda aj hodnoty extrahovaných štatistík sa pri zvyšovaní *NoCh* zákonite približujú kryciemu obrazu bez vlozenej tajnej správy. Metóda takto zvyšuje bezpečnosť voči detegovaniu tajnej správy v procese stegoanalýzy.

$$Difference = \frac{\frac{l}{2} - NoCh}{\frac{l}{2}} \cdot 100 \quad [\%] \quad (3)$$


kde *l* predstavuje počet bitov tajnej správy a *NoCh* Hammingovú vzdialenosť medzi vektorom tajnej správy a príslušnou oblasťou na vkladanie vo vybranom krycom obraze pomocou metódy CS.

V ďalšom experimente boli zvolené rovnaké veľkosti správ ako v predchádzajúcom. Z TAB. IV je zrejmé, že metóda s výberom krycieho obrazu je časovo podstatne náročnejšia ako metóda bez výberu krycieho obrazu.

TABUĽKA IV. CELKOVÝ ČAS VKLADANIA CS METÓDY V POROVNANÍ S VKLADACOU METÓDOU DWT BEZ CS

Rozmer obrazu [op]	Veľkosť t. s. [bit]	Metóda bez CS	Metóda CS
		<i>t</i> [s]	<i>t</i> [min]
512 × 512	21 760	3,5	30
	43 520	4	106
	65 280	4,5	350

Pre správu s veľkosťou 21 760 bitov bol čas vkladania 30 minút v porovnaní s 3,5 sekundami. Správu s veľkosťou 65 280bit metóda CS vkladala takmer 6 hodín, pričom metóda bez výberu krycieho obrazu iba 4,5s. Dlhý čas vkladania metódy CS je spôsobený porovnávaním bitov tajnej správy s bitmi všetkých krycích obrazov v databáze.



Obr. 8. Vplyv veľkosti databázy krycích obrazov na počet zmien

Posledný experiment spočíval v sledovaní zmeny *NoCh* v závislosti na zvyšujúcom sa počte krycích obrazov v databáze. V tomto meraní bola vkladaná tajná správa

s veľkosťou 16 128bit. Na Obr. 8 je vidieť, že *NoCh* so zväčšujúcou sa databázou klesalo.


Vloženie správy do náhodného obrazu zmenilo 8 084 bitov, čo je niečo viac ako polovica počtu bitov tajnej správy. Už pri porovnávaní tajnej správy s 10 obrazmi, *NoCh* kleslo na hodnotu 7 649 (*Rozdiel* 5,3%). Pri porovnaní s 500 obrazmi, na 7 444 (7,9%) a s 2 000 obrazmi 7 421, čo predstavuje 8,2%. Graf má charakter klesajúcej logaritmickú funkcie. Z uvedených databáz je zrejme najefektívnejšie použiť databázu s počtom obrazov 500. *Rozdiel* v *NoCh* medzi 500 obrazmi a 2 000 obrazmi v databáze predstavoval 23 bitov, čo sa rovná zlepšeniu iba o 0,3%. Ak je potrebné znížiť čas vkladania *t*, jeden z efektívnych spôsobov by mohlo byť zníženie počtu obrazov v databáze z 2 000 na 500.

C. Zrýchlená CS metóda

Metóda CS predstavuje zvýšenie časovej náročnosti vkladania oproti vkladaniu do jedného náhodne vybraného obrazu. Doba hľadania je priamo úmerná veľkosti obrazovej databázy a dĺžke tajnej správy. Zrýchlenie celého procesu výberu optimálneho obrazu je možné dvomi spôsobmi, a to:

- zrýchlením výpočtov
- zredukovaním výpočtov pri porovnávaní

Keďže porovnanie bolo v CS metóde realizované pomocou operácie *exclusive or* (XOR), najšť rýchlejší spôsob výpočtu bolo náročné. Preto bola pozornosť zameraná na redukcii počtu samotných výpočtov. Jeden so spôsobov je orezanie sekvencie bitov tajnej správy o určitý počet bitov (Obr. 9).



Obr. 9. Skrátene sekvencie bitov tajnej správy pred blokom porovnania

Takto skrátenej reťazec sa použije v bloku porovnania a hľadania optimálneho krycieho obrazu, pričom do zvoleného obrazu sa vkladá už celý reťazec bitov. Výsledkom je najšť určitú hranicu, kedy metóda ešte dokáže vybrať rovnaký krycí obraz pri maximálne skrátenej tajnej správe. Vytvorená metóda zrýchlenej steganografie s výberom krycieho obrazu (Accelerated Cover Selection steganographic method, ACS method) bola podrobená experimentom, pričom výsledky sú uvedené v nasledujúcej kapitole [13].

Databáza krycích obrazov pri testovaní ACR metódy bola zredukovaná na 500 obrazov. Vďaka tomu sa výpočty urýchlili a pri tajnej správe s veľkosťou 21 760 bitov sa doba hľadania skrátila z 30min iba na 5min. Pre vernosť výsledkov bolo do obrazov vkladných 10 rôznych správ o rovnakej dĺžke (21 760bit), pričom výsledky predstavujú priemerné hodnoty na 1 správu.


V TAB. V sú zobrazené hodnoty *NoCh*, *Rozdiel* medzi aktuálnym *NoCh* a *NoCh* pri náhodnom výbere krycieho obrazu a časová náročnosť vkladania *t* v závislosti od skracovania sekvencie tajnej správy. Koefficient *a* predstavuje percentuálnu hodnotu tajnej správy, ktorá bola použitá v procese hľadania a výberu optimálneho krycieho obrazu.

NoCh náhodne vybraného obrazu predstavuje hodnotu 10 880bit.

TABUĽKA V. VPLYV SKRACOVANIA TAJNEJ SPRÁVY NA *NoCh* A CELKOVÝ ČAS VKLADANIA


<i>a</i> [%]	<i>NoCh</i> [-]	Rozdiel [-]	Rozdiel [%]	<i>t</i> [min]
100	10 108	772	7,09	5
90	10 108	772	7,09	4
80	10 108	772	7,09	3,5
70	10 135	745	6,85	2,5
60	10 295	584	5,37	2
50	10 255	624	5,74	1,5

Získané výsledky sú graficky zobrazené na nasledujúcich obrázkoch. Obr. 10 zobrazuje zmenu *Rozdielu* od koeficienta *a*. Je vidieť, že percentuálna hodnota *Rozdielu* pri skrátaní vektora tajnej správy na 90% a 80% zostala rovnaká. Pri použití 70% veľkosti vektora bola zaznamenaná degradácia o 0,24%. Ďalšie skracovanie tajnej správy na 60% a 50% spôsobilo už výraznejšie zníženie *Rozdielu*.



Obr. 10. Vplyv skracovania tajnej správy na veľkosť *Rozdielu*

Na Obr. 11 je zobrazený čas výberu krycieho obrazu v závislosti od koeficienta *a*.



Obr. 11. Vplyv skracovania tajnej správy na čas výberu optimálneho krycieho obrazu

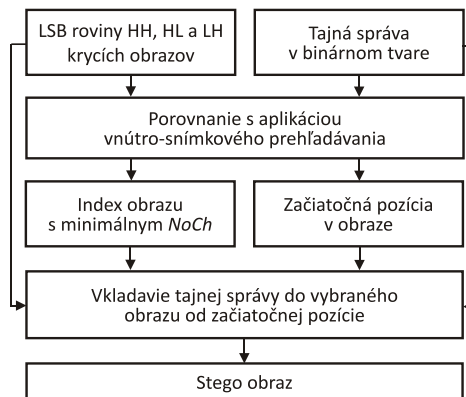
Čas klesal takmer lineárne, pričom pri použití 90% tajnej správy sa skrátal o 1min, čo pri daných podmienkach predstavuje zrýchlenie o 20%. Skrátanie na 80% spôsobilo zrýchlenie metódy o 30% a nastavenie koeficienta *a* na

hodnotu 70% skrátalo výber krycieho obrazu presne na polovicu. Každé ďalšie skracovanie vylepšilo čas hľadania o 0,5min, čiže o 10%.

Zrýchlená metóda steganografie s výberom krycieho objektu ACS predstavuje účinný nástroj na zníženie náročnosti CS metódy z pohľadu času výberu optimálneho krycieho obrazu. Avšak, skracovanie tajnej správy spôsobuje nárast hodnoty *NoCh*. To znamená, že vybraný obraz už nie je ten optimálny. Z experimentov však vyplýva, že pri skrátaní tajnej správy na 90% a 80% nespôsobilo žiadnu degradáciu *Rozdielu*, resp. nárast *NoCh*. Skrátanie správy na 80% predstavovalo zrýchlenie metódy o 30%. Skrátaním tajnej správy na 70% pôvodnej sa čas výberu znížil na polovicu a to pri degradácii *Rozdielu* iba o 0,24%. Metóda ACS prináša zrýchlenie metódy CS až o 30% a to bez akéhokoľvek nárastu *NoCh*.

D. CS metóda s vnútro-snímkovým prehľadávaním

Metóda CS s vnútro-snímkovým prehľadávaním predstavuje rozšírenie CS metódy o hľadanie najlepšej pozície pre vloženie tajnej správy v krycom obraze [14].



Obr. 12. Blokový diagram CS metódy s vnútro-snímkovým prehľadávaním

Bloková schéma uvedenej metódy je zobrazená na Obr. 12 a spočíva v týchto krokoch:

- Tajná správa je podľa ASCII kódu konvertovaná z textovej formy na binárnu.
- Načítanie LSB rovín sub-obrazov HH, HL a LH z databázy predspracovaných krycích obrazov.
- Vektor tajnej správy sa porovná s každou možnou pozíciou v krycom obraze a vypočíta sa príslušný parameter *NoCh* (vnútro-snímkové prehľadávanie).
- Toto prehľadávanie sa vykoná pre všetky obrazy v databáze, pričom sa uloží index obrazu a pozícia v ňom, ktorá minimalizovala hodnotu *NoCh*.
- Načítanie obrazu s príslušným indexom. Do tohto obrazu sa bude vkladat' tajná správa.
- Vkladanie bitov tajnej správy do krycieho obrazu, pričom vkladanie sa vykoná sekvenčne, od pozície v obraze, ktorá bola nájdená vo vnútro-

snímkovom prehľadávaní. Informácia o tejto pozícii sa vloží na začiatok LSB roviny sub-obrazu HH. Táto informácia je dôležitá pre adresáta počas extrakcie tajnej správy z obrazu. Na túto informáciu je rezervovaných 18 bitov, pretože takáto hodnota je postačujúca pre definíciu akejkoľvek pozície v obraze s rozlíšením 512×512 op. V prípade použitia obrazovej databázy s iným rozlíšením je potrebné túto veľkosť optimalizovať.

- Pridanie znamienok, inverzná DWT a kompozícia stego obrazu spojením príslušných zložiek.

Vnútro-snímkové prehľadávanie znamená hľadanie optimálnej pozície na vloženie tajnej správy v celej databáze krycích obrazov. Optimálny obraz je obraz, v ktorom bola táto pozícia nájdená. V CS metóde bola v jednom krycom obraze možná práve jedna pozícia na vloženie tajnej správy. Vnútro-snímkové prehľadávanie porovnáva viacero pozícií v jednom obraze. Presný počet potenciálnych pozícií na vloženie správy v jednom obraze závisí od veľkosti vkladanej správy a rozmeru krycieho obrazu. Parametre $NoCh$ pre n pozícií v krycom obraze sú vypočítané podľa vzťahu (4).

$$NoCh_n = \sum_{i=1}^k |s(i) - c(i+n)| \quad (4)$$

kde s predstavuje sekvenciu bitov tajnej správy, c sekvenciu bitov zodpovedajúcej časti krycieho obrazu a k dĺžku správy. Pridanie vnútro-snímkového prehľadávania výrazne zvyšuje počet porovnaní, efektívne využíva databázu krycích obrazov a má vplyv na zníženie hodnoty parametra $NoCh$.

V nasledujúcich simuláciách bola použitá obrazová databáza zredukovaná na 1 000 obrazov. Do obrazov boli vkladane tajné správy v textovej forme s veľkosťou: 144bit (fráza), 400bit (veta), 2 960bit (odstavec) a 21 760bit (1/9 celkovej kapacity = 1,5 strany). V každom meraní bolo vkladanych 5 rôznych správ s príslušnou dĺžkou, pričom výsledky predstavujú priemerné hodnoty na 1 správu.

V TAB. VI sú uvedené výsledky merania *Rozdielu* a časovej náročnosti metódy pre vyššie uvedené veľkosti správ, ktoré predstavovali určité typické časti textu.

TABUĽKA VI. ÚČINNOSŤ A ČASOVÁ NÁROČNOSŤ CS METÓDY S VNÚTRO-SNÍMKOVÝM PREHĽADÁVANÍM V ZÁVISLOSTI NA DĹŽKE TAJNEJ SPRÁVY

	Náhodný výber	CS s vnútro-snímk. p.			
k [bit]	$NoCh$ [-]	$NoCh$ [-]	$Rozdiel$ [-]	$Rozdiel$ [%]	t [min]
144	81	43	38	46,7	299
400	209	135	74	35,3	315
2 960	1 489	1 075	414	28,4	435
21 760	10 889	9 330	1 559	14,2	936

Je zrejmé, že efektivita metódy bola pre kratšie textové reťazce vyššia. Správe s veľkosťou 21 760bit zodpovedal


Rozdiel 14,2%, pričom najmenšej správe (144bit) až 46,7%. Doba trvania výberu optimálneho krycieho obrazu sa vyšplhala na vyše 15h pri najdlhšej správe a 5h pri najkratšej správe. To je výrazný nárast oproti metóde CS bez vnútro-snímkového prehľadávania, kde pri vkladaní rovnako-veľkej tajnej správy (21 760bit) v 2-krát väčšej databáze obrazov (2 000) sa optimálny krycí obraz našiel len za 30min.

Závislosť *Rozdielu* a času vkladania t od veľkosti obrazovej databázy je uvedený v TAB. VII. Do obrazu bola vkladaná tajná správa s veľkosťou 2 960bit.

TABUĽKA VII. ZMENA ROZDIELU A DOBY VKLADANIA V ZÁVISLOSTI OD VEĽKOSTI DATABÁZY KRYCÍCH OBRAZOV

Počet obrazov	$NoCh$ [-]	$Rozdiel$ [%]	t [min]
1	1 489	0	0,36
10	1 325	11	4,8
100	1 262	15,2	46,6
500	1 262	15,2	239
1 000	1 075	28,4	435

$NoCh$ so vzrastajúcou databázou očakávané klesal, čo najlepšie vyjadruje nárast *Rozdielu*. *Rozdiel* pri desiatich obrazoch mal hodnotu 11%, pričom pri veľkosti 1 000 obrazov v databáze dosiahol takmer 28,5%. Doba celého procesu narastala priamo úmerne počtu obrazov v databáze. V databáze 10-tich obrazov sa optimálny obraz našiel za 4,8min, v databáze 100 obrazov za 46,6min a v obrazovej databáze pozostávajúcej z 1 000 obrazov trval výber 435 minút. Pre lepšie porovnanie je nárast *Rozdielu* a časový nárast v závislosti od zvyšujúceho sa počtu obrazov v databáze zobrazený na Obr. 13.




Obr. 13. Zmena *Rozdielu* a času vkladania t v závislosti od počtu obrazov v obrazovej databáze

Porovnanie pôvodnej CS metódy a metódy s vnútro-snímkovým prehľadávaním z hľadiska *Rozdielu* je ilustrované na Obr. 14. V oboch prípadoch bola vstupom tajná správa s veľkosťou 16 128bit a databáza krycích obrazov obsahovala 10, 100, 500 a 1 000 farebných obrazov s veľkosťou 512×512 op.

Je vidieť, že metóda s vnútro-snímkovým prehľadávaním dosiahla výrazne nižší počet zmien ($NoCh$), čo sa odzrkadlilo vo vyššej percentuálnej hodnote *Rozdielu*, pričom so zvyšujúcou sa databázou krycích obrazov *Rozdiel* narastal. Pri

databáze 1 000 obrazov bolo zaznamenané takmer 9%-né zlepšenie oproti klasickej metóde CS.



Obr. 14. Závislosť Rozdielu od veľkosti databázy krycích obrazov dvoch CS metód

Keďže vnútro-snímkové prehľadávanie výrazne zvyšuje čas vkladania, je možné uplatniť princíp zrýchlenia ACS metódy a sice skrátiť vkladajúcu sekvenciu pred procesom vyhľadávania.

V TAB. VIII sú zobrazené Rozdiel a čas vkladania pri použití 90, 80, 70 a 50% z vkladanej sekvencie pre proces vyhľadávania optimálneho krycieho obrazu. Koeficient a určuje percento vkladanej sekvencie, použitej pre proces vyhľadávania optimálneho krycieho obrazu. V experimente bola použitá tajná správa s veľkosťou 2 960bit a databáza s 1 000 obrazmi.


TABUĽKA VIII. APLIKÁCIA ACS METÓDY NA PREDSTAVOVANÝ ALGORITMUS

a [%]	Rozdiel [%]	t [min]
100	28,4	435
90	27,4	400
80	17,8	379
70	8,4	367
50	9,8	326

Rovnako ako v ACS metóde, pri skracovaní reťazca sa čas vkladania znižoval, avšak na úkor Rozdielu. Pri 90%-nom vektore sa čas vkladania skrátil o 35min, čo predstavuje zlepšenie o 8% v porovnaní s pôvodným časom. Rozdiel sa znížil o 1%, čo predstavuje zhoršenie o 3,5% (ak je za vzťažnú považovaná hodnota Rozdielu – 28,4%). Keď sa vkladajúca správa skrátila na 80%, čas vkladania predstavoval 379min, teda zrýchlenie o 12,9%. Rozdiel však klesol už na 17,8%, teda klesol až o 37,3%. Toto meranie predstavuje už hraničnú hodnotu, pretože z TAB. VII vyplýva, že hodnotu Rozdielu 15% dosiahla táto metóda znížením počtu obrazov v databáze na 500, pričom celkový čas bol len 239min naproti 379min. Efektívne zrýchlenie teda dosiahlo skrátenie vkladajúcej sekvencie bitov na 90%.

Obr. 15 zobrazuje porovnanie CS metódy s vnútro-snímkovým prehľadávaním, CS metódy, DWT metódy

použitej v oboch CS algoritmoch, LSB metódy navrhnuté v [10] a DCT steganografického nástroja publikovaného v [11]. Algoritmy boli porovnávané z pohľadu perceptívnej transparentnosti. Vkladaná bola tajná správa s veľkosťou 4 096bit do obrazu s rozmerom 512 × 512op.



Obr. 15. Porovnanie CS metódy s vnútro-snímkovým prehľadávaním s inými steganografickými metódami z pohľadu PSNR

Najnižšiu hodnotu PSNR dosiahla metóda LSB so 46,31dB. S hodnotou o niečo vyššou ako; 50dB obsadila druhé miesto steganografická metóda DCT. Predstavovaný algoritmus vkladania, pracujúci vo waveletovej oblasti, nadobudol pomer PSNR rovný 52,02dB. Najlepšie v porovnaní obstála CS metóda s vnútro-snímkovým prehľadávaním, v ktorej sa hodnota PSNR zvýšila na úroveň 54,6dB.

IV. ZÁVER

Nová metóda steganografie s výberom krycieho obrazu znížila parameter $NoCh$ o 10% v porovnaní s náhodným výberom krycieho obrazu. V ďalšej metóde sa podarilo skrátiť čas výberu optimálneho obrazu o viac ako polovicu pri minimálnom náraste $NoCh$. Pre porovnávanie tajnej správy s krycimi obrazmi bola použitá iba určitá percentuálna časť správy. Pridanie vnútro-snímkového prehľadávania prinieslo výrazné zvýšenie počtu porovnaní bez nutnosti zvýšiť veľkosť obrazovej databázy. Určité skrátenie doby výberu obrazu bolo možné docieľiť rovnakým princípom ako v predchádzajúcej metóde.

Zmenou vkladacieho algoritmu a porovnávacieho parametra by bolo možné vytvorenú CS metódu použiť ako prídavok na vylepšenie akejkoľvek metódy obrazovej steganografie. Navyše zmenou obrazovej databázy na databázu iných modalít (napr. audio, video) je možné jej uplatnenie ešte rozšíriť.

Keďže sa oblasť obrazovej steganografie a stegoanalýzy doposiaľ stále nepovažuje za uzavretú, prínosy práce môžu dopomôcť k ich ďalšiemu vývoju. Princíp steganografie s výberom krycieho obrazu by bolo možné v ďalšom výskume použiť ako prídavok na zníženie miery detegovateľnosti viacerých vkladacích algoritmov. Ako porovnávací parameter by bolo vhodné zvoliť takú štatistiku, na ktorej zmenu má proces vkladania najväčší vplyv a ktorá sa najčastejšie používa v stegoanalýze danej metódy. Namiesto jednej štatistiky by bolo možné zvoliť aj súbor vhodných porovnávacích štatistických parametrov.

POĎAKOVANIE

Táto publikácia vznikla vďaka podpore Ministerstva školstva Slovenskej republiky (MŠ SR) VEGA Grant č. 1/0511/17.

BIBLIOGRAFICKÉ ODKAZY

- [1] A.P. Petitcolas Fabien, R.J. Anderson, M.G. Kuhn, "Information hiding-a survey," in Proceedings of the IEEE , vol. 87, no. 7, pp. 1062-1078, Jul 1999.
- [2] W.J. Buchanan, "Introduction to security and network forensics," Boca Raton: Taylor & Francis Group, 2011, ISBN 978-1-4200-1310-8
- [3] J. Kodovský, "Steganalysis of digital images using rich imagerepresentations and ensemble classifiers," dizertačná práca, New York: Binghamton University, 2012.
- [4] R. Böhme, "Advanced Statistical Steganalysis," Dresden: Springer, 2010, ISBN 978-3-642-14312-0
- [5] T. Pevný, "Kernel methods in steganalysis," dizertačná práca, New York: Binghamton University, 2008.
- [6] M. Broda, V. Hajduk, D. Levický, "Universal Statistical Steganalytic Method," in Journal of Electrical Engineering, vol. 68, no. 2, pp. 117-124, 2017, ISSN 1335-3632
- [7] Kharrazi, M.; Sencar, H. T.; Memon, N., „Cover selection for steganographic embedding” 2006 International Conference on Image Processing, Atlanta, GA, 2006, pp. 117-120.
- [8] M. Broda, V. Hajduk, D. Levický "Image Steganography Based on Combination of YCbCr Color Model and DWT," in Proceedings ELMAR-2015, 57th International Symposium, Zadar, 2015, pp.201-204.
- [9] D. Levický, "Aplikovaná kryptografia," Košice: Elfä, 2018, ISBN 978-80-8086-265-7
- [10] D. Rawat, V. Bhandari, "A Steganography Technique for Hiding Image in an Image using LSB Method for 24 Bit Color Image", in International Journal of Computer Applications, vol. 64, no. 20, Feb 2013, pp. 15-19.
- [11] S. Maurya, V. Shrivastava, "An Improved Novel Steganographic Technique For RGB And YCbCr Colorspace", in Journal of Computer Engineering, vol. 16, no. 2, pp. 155-157, 2014, ISSN: 2278-8727
- [12] V. Hajduk, D. Levický, „Cover selection steganography,” in Proceedings ELMAR-2016, 58th International Symposium, Zadar, 2016, pp. 205-208, ISBN 978-953-184-221-1
- [13] V. Hajduk, D. Levický, "Accelerated Cover Selection Steganography," Radioelektronika 2017, Brno: IEEE, pp. 1-4, 2017, ISBN 978-15090-4591-4
- [14] V. Hajduk, D. Levický, "Cover Selection Steganography with Intra-Image Scanning," Radioelektronika 2018, Praha: IEEE, 2018, ISBN 978-1-5386-2485-2

Ovplyvňovanie nelineárnych javov v pásme C s využitím EDFA ako medzilinkového zosilňovača

Tomáš Ivaniga

Katedra elektroniky a multimediálnych telekomunikácií,
Fakulta elektroniky a informatiky
Technická Univerzita v Košiciach
Slovenská Republika
tomas.ivaniga@tuke.sk

Ján Turán, Ľuboš Ovseník

Katedra elektroniky a multimediálnych telekomunikácií,
Fakulta elektroniky a informatiky
Technická Univerzita v Košiciach
Slovenská Republika
jan.turan@tuke.sk, lubos.ovsenik@tuke.sk

Abstrakt— V dnešnej dobe nie je možné realizovať plne optický komunikačný systém bez softvérových nástrojov, ktoré by simulovali reálnu prevádzku. V našom príspevku je opísaný fyzikálny princíp najpoužívanejšieho vláknového zosilňovača EDFA (Erbium Doped Fiber Amplifier) v DWDM (Dense Wavelength Division Multiplex) systéme. Je realizovaná konfigurácia zapojenia ktorá poukazuje na nutnosť použitia EDFA ako IN-Line zosilňovača na diaľkovej optickej linke. Daná konfigurácia zapojenia poukazuje na vhodnú dĺžku erbiom dopovaného vlákna a na to ako klesá bitová chybovosť BER (Bit Error Rate) so vzrastajúcou bitovou rýchlosťou. Keďže pri vysokých výkonoch a veľkých vzdialenostiach dochádza k degradácii signálu zamerali sme sa ďalej na elimináciu nelineárnych javov typu XPM (Cross Phase Modulation) a SPM (Self Phase Modulation). Jednotlivé výsledky sú porovnávané s výsledkami publikovanými v danej oblasti výskumu.

Abstract— Nowadays, it is not possible to implement a fully optical communication system without software tools that would simulate real operation. In our paper we describe the physical principle of the most widely used EDFA (Erbium Doped Fiber Amplifier) in the DWDM (Dense Wavelength Division Multiplex) system. There is a wiring configuration that points to the need to use EDFA as an IN-Line amplifier on a remote optical line. The given configuration of the connection points to the appropriate length of the erbium doped fiber and how the BER (Bit Error Rate) decreases with increasing bit speed. As the high power signal carried over large distances is degraded, we have focused on eliminating non-linear phenomena such as XPM (Cross Phase Modulation) and SPM (Self Phase Modulation). The individual results are compared with the results published in the research area.

Kľúčové slová—BER; DWDM; OptSim; Q-faktor; SPM; XPM


I. ÚVOD

Elementárny prenosový komunikačný systém obsahuje v podstate tri základné bloky: vysielači, prenosový a prijímači. Keď v roku 1876 bol vynájdený telefón, tak na približne deväťdesiat rokov sa hlavným prenosovým médium stala krútená dvojlinka využívaná v metalickej kabeláži [1], [2]. S nástupom počítačových systémov, so stále rastúcim

objemom dát a s rozširujúcim sa portfóliom telefónnych služieb, narazili metalické vedenia na svoje limity. Prelom nastal v roku 1966, keď Hackman a Kao navrhli ako alternatívne riešenie využívať optické vlákna namiesto krútenej dvojlinky. Veľký prevrat nastal o štyri roky neskôr, keď sa podarilo vyrobiť OV (optické vlákno) s útlmom menším ako 20 dB.km^{-1} . Následne o sedem rokov sa začala doba komerčného nasadenia OV do komunikačnej siete. V neskorších rokoch sa podarilo znížiť hodnotu útlmu pod 1 dB.km^{-1} a dnes sú dostupné OV s hodnotou útlmu pod $0,3 \text{ dB.km}^{-1}$. V súčasnej dobe nie je problémom hodnota útlmu, ale neustále rastúce požiadavky na zvyšovanie prenosovej rýchlosti a prenosovej kapacity už na existujúcich systémoch. Prevádzkovatelia optických komunikačných systémov sú neustále nútení pre rastúci objem prenášaných dát zvyšovať prenosovú kapacitu systému [3]. Tento nárast je predovšetkým spôsobený obľubou využívania cloudových a multimediálnych služieb. Pre poskytovateľov je výhodné pri zväčšovaní kapacity ekonomickým a logicky zvládnuteľným krokom realizovať postupný prechod k vyšším prenosovým rýchlostiam za predpokladu, že bude využitá už jestvujúca infraštruktúra optickej siete, do ktorej boli investované nemalé finančné prostriedky. Jednou z možností, ako efektívne využiť optickú trasu, je použitie vlnových multiplexov WDM.

Pokiaľ využijeme na prenos rýchlosť 10 Gbit.s^{-1} (STM-64) a pomocou WDM vytvoríme 100 spektrálnych kanálov, dostaneme sa na prenosovú rýchlosť až 1 Tbit.s^{-1} po jednom OV. Pri prenose na veľké vzdialenosti – približne nad 100 km – dochádza k zoslabeniu signálu a je potrebné použiť optické zosilňovače k opätovnému zosilneniu signálu. V tomto prípade sa uplatňujú zosilňovače, ktoré umožňujú priame zosilnenie optického signálu [4], [5]. Jednoducho povedané, dĺžka optickej trasy bez použitia optických zosilňovačov je závislá od vysielačieho výkonu lasera umiestneného vo vysielači, druhu OV, prenášaného signálu a od citlivosti optického detektora umiestneného v prijímači. Prenos optickým komunikačným systémom patrí medzi najstabilnejšie, avšak aj tieto systémy majú svoje obmedzenia, t.j. lineárne a nelineárne javy. Nelineárne javy v plne optických komunikačných systémoch hrajú dôležitú úlohu pri výskume a realizácii vysokorýchlostných a vysokokapacitných optických prenosových systémov. Na jednej strane, hneď potom, ako boli tieto nelineárne javy experimentálne dokázané, sa

Tento článok bol vypracovaný vďaka podpore projektov KEGA č. 023TUKE-4/2017 a VEGA č. 1/0772/17



Obr.1 Schéma vlnového multiplexu

konštatovalo, že dokázu ovplyvňovať určité parametre optických vlákien. Spočiatku boli tieto javy irelevantné, avšak príchod WDM a nasadenie optických zosilňovačov urýchlili ich štúdium, keďže dochádzalo ku skresľovaniu signálu prenášaného takýmto systémom [6], [7]. Na druhej strane sa rola nelineárnych javov zásadne mení v oblasti spracovania signálov.

II. VLNOVÝ MULTIPLEX

Predstava samotnej realizácie vlnovo deleného multiplexu WDM bola opísaná a teoreticky spracovaná v minulom storočí na počiatku šesťdesiatych rokov. Koncom sedemdesiatych rokov bol prakticky zrealizovaný prenos dvoch signálov s rôznymi optickými vlnovými dĺžkami cez jedno OV [8]. Od tohto okamihu prebieha intenzívny vývoj zameraný na zlepšovanie WDM. V dvadsiatom prvom storočí sú tieto systémy neodmysliteľnou súčasťou chrbticových optických prenosových sietí, keďže pomocou nich možno prenášať stovky optických signálov s rôznymi optickými vlnovými dĺžkami po jednom OV. Celý systém obsahuje n optických zdrojov a n optických detektorov, pričom na každú použitú vlnovú dĺžku vo vysielačnej jednotke je namodulovaný optický signál. Vysielače sú tvorené zdrojmi optického žiarenia, pričom najčastejšie sa používajú DFB (Distributed Feedback) lasery, pretože ich spektrálna šírka sa pohybuje v jednotkách MHz. DFB využíva rezonátor, ktorý je tvorený Braggovou mriežkou s periodickou zmenou indexu lomu, vďaka čomu generuje úzko spektrálne žiarenie, ktorého šírka neprekračuje šírku jedného kanála DWDM [9], [10]. Zlučovanie všetkých vlnových dĺžok do jedného OV sa deje v bloku multiplexora. Opačná funkcia, teda vydeľovanie jednotlivých vlnových dĺžok, prebieha v bloku demultiplexora. Existujú difrakčné multiplexory s Braggovými mriežkami alebo interferenčné multiplexory AWG [11].

AWG sú vyrobené z dvoch vlnovodov na vstupe a na výstupe z usporiadanej vlnovodovej mriežky, ktorá je zložená z dlhých nesymetrických paralelných vlnovodov. Technológia AWG nám umožňuje 50 GHz multiplexáciu väčšieho počtu kanálov, pričom môže byť integrovaná na vrstve kremíka

a netrpí chromatickou disperziou. Avšak nevýhodou je jej závislosť od teploty. Multiplexory s Braggovými mriežkami dosahujú vysokú presnosť a menšie straty [12], [13]. Nevýhodou je tiež, že k svojej funkcii potrebujú ďalšie komponenty (cirkulátory, väzobné členy), čo v podstate zavádza do systému chromatickú disperziu. Taktiež je možné pridávať a vyčleňovať jednotlivé vlnové dĺžky s využitím OADM (Optical Add-Drop Multiplexer) alebo ROADM (Reconfigurable Optical Add-Drop Multiplexer), a to v závislosti od požiadaviek zákazníka.

Pri prenose optickou trasou dochádza k tlmeniu optického signálu a z tohto dôvodu je nevyhnutné signál po určitých úsekoch obnovovať. Do optickej trasy možno optický zosilňovač vložiť tromi spôsobmi: ako booster, ktorý sa zaraďuje priamo za optický vysielač a slúži k zosilneniu signálu na čo najvyššiu možnú úroveň, ktorú možno do OV naviazať. Ďalej ho možno umiestniť ako IN-Line prvok, ktorý sa vkladá priebiežne do optickej trasy (80 km – 100 km) alebo ako predzosilňovač, ktorý sa zaraďuje pred prijímač a zosilňuje signál na hodnotu akceptovateľnú pre prijímaciu jednotku (akceptovateľná BER) [14]. V praxi sa používajú optické zosilňovače typu EDFA, SOA (Semiconductor Optical Amplifier) a ROA (Raman Optical Amplifier). Na prijímacej strane za demultiplexorom nastáva konverzia signálu z optickej domény do elektrickej domény pomocou fotodiódy PIN (P-I-N Photodiode) alebo APD (Avalanche Photodiode). Aj keď fotodetektor prevádza len intenzitu optického žiarenia na elektrický signál, v prípade pokročilejších modulačných formátov je prijímač vybavený ďalšími prvkami, ako je Mach-Zhenderov interferometer alebo 90° hybridný optický väzobný člen. V súčasnosti sú používané štandardy CWDM a DWDM. Pri výbere, ktorý štandard použiť v praxi, sa rozhodujeme na základe koncovej ceny, počtu používateľov, prenosovej rýchlosti a toho, ako sa bude použitá sieť rozrastať. Základným parametrom WDM systémov je ich celková prenosová kapacita označovaná ako C_{WDM} , ktorú vypočítame ako:

$$C_{WDM} = \sum_{k=1}^n v_{pk} \tag{1}$$

kde v_{pk} je prenosová rýchlosť k -tého kanálu a n je celkový počet kanálov systému WDM [15], [16]. Každému kanálu je priradená určitá šírka spektra, a to bez ohľadu na to, či ju daný kanál využije, alebo nie. Pokiaľ je rozstup medzi kanálmi zbytočne veľký, systém dosahuje horšie celkové spektrálne účinnosti, ktoré môžeme definovať nasledovným vzťahom:

$$\eta_{WDM} = \frac{C_{WDM}}{B_{WDM}}, \quad (2)$$


kde B_{WDM} je celkové pásmo zabraté WDM systémom. WDM technológiu je v dnešnej dobe možné využiť priamo v rozbočovačoch pomocou SFP (Small Form-Factor Pluggable) alebo CSFP (Compact Small Form-Factor Pluggable) slotu v podobe MiniGBIC modulov.

III. BITOVÁ CHYBOVOSŤ BER

Každú optickú sieť je potrebné pred jej uvedením do prevádzky otestovať. Testujeme preto, aby sme zistili, či daná optická sieť je vhodne zapojená a či jej zapojenie je postačujúce na spoľahlivý a bezchybný prenos dát. Pri telekomunikačnom prenose dát predstavuje hodnota BER percento chybných bitov vzhľadom ku celkovému počtu prijatých bitov na vstupe prijímača danej prenosovej cesty. Ináč povedané, BER predstavuje údaj o tom, ako často sa majú údaje opakovanne vysielat' z dôvodu chyby.

A. Vznik diagramu oka

Diagram oka predstavuje v komunikáciách najpoužívanejší nástroj (analýzu) na vyhodnotenie prijatého signálu. Podľa výstupného diagramu môžeme kvantifikovať jednotlivé chyby. Diagram slúži na vyhodnotenie optickej linky daného systému (v našom prípade jednotlivých liniek DWDM). S diagramom oka sú úzko späté pojmy ako Q-faktor, bitová chybovosť BER alebo SNR (Signal to Noise Ratio). Ideálny tvar oka (10^{-40}) by mal obsahovať vysielané „1“ a „0“. Na Obr.2 môžeme vidieť vytvorenie ideálneho diagramu oka.



Obr.2 Vznik ideálneho diagramu oka


B. BER a s ňou súvisiaci Q faktor

BER sa zhoršuje v prípade, keď rozhodovacia úroveň presiahne rušenie, v dôsledku čoho dôjde k nesprávnej interpretácii prijatých optických impulzov. V praxi je optická linka odovzdaná poskytovateľovi (prevádzkovateľovi) siete

s úplnou dokumentáciou a s jednotlivými nameranými hodnotami BER vyhodnocujúcimi jednotlivé linky (BER predstavuje kritérium kvality danej linky) [17], [18]. BER sa vypočíta na základe počtu známych chýb, ktoré boli prijaté v danom optickom signáli:

$$BER = \frac{N_E}{N_A}, \quad (3)$$

pričom N_E predstavuje všetky chybné bity a N_A predstavuje všetky prijaté bity. Na Obr.3 je znázornená hustota pravdepodobnosti BER.



Obr.3 Diagram oka s rozdelenou hustotou pravdepodobnosti

BER je úzko spojená s Q-faktorom, ktorý sa vypočíta pri odčítaní γ_{opt} , čo predstavuje optimálnu hodnotu od strednej hodnoty úrovne logická „0“ a logická „1“:

$$Q = \frac{\mu_1 - \gamma_{opt}}{\sigma_1} = \frac{\gamma_{opt} - \mu_0}{\sigma_0} = \frac{\mu_1 - \mu_0}{\sigma_1 + \sigma_0}, \quad (4)$$

pričom platí:

$$\gamma_{opt} = \frac{\mu_1 \sigma_0 - \mu_0 \sigma_1}{\sigma_0 + \sigma_1}. \quad (5)$$

Na Obr.3 hodnoty pravdepodobnosti BER $P(\mu(t) > \gamma_{opt} | \mu_0) / P(\mu(t) < \gamma_{opt} | \mu_0)$ udávajú hodnoty, ktoré sa udejú, keď daná pravdepodobnosť $\mu(t)$ je väčšia/menšia ako optimálna hodnota γ_{opt} alebo stredná hodnota úrovne logická „1“/„0“. To naznačuje, že dochádza k prekrývaniu daných oblastí a nastáva problém rozlíšiť, či bola prijatá „1“ alebo „0“. Problém rozlíšiť, čo bolo prijaté na výstupe, možno definovať rovnicami zvlášť pre „1“ a zvlášť pre „0“:

$$P(1|0) = \frac{1}{\sigma_0 \sqrt{2\pi}} \int_{\gamma_{opt}}^{\infty} e^{-\frac{1}{2} \left(\frac{\mu - \mu_0}{\sigma_0} \right)^2} d\mu = \frac{1}{2} \operatorname{erfc} \left(\frac{\gamma_{opt} - \mu_0}{\sigma_0 \sqrt{2}} \right), \quad (6)$$

$$P(0|1) = \frac{1}{\sigma_1 \sqrt{2\pi}} \int_{\gamma_{opt}}^{\infty} e^{-\frac{1}{2} \left(\frac{\mu - \mu_1}{\sigma_1} \right)^2} d\mu = \frac{1}{2} \operatorname{erfc} \left(\frac{\mu_1 - \gamma_{opt}}{\sigma_1 \sqrt{2}} \right), \quad (7)$$

z čoho BER bude rovná:

$$BER = \frac{1}{2} [P(1|0) + P(0|1)] = \frac{1}{4} \left[\operatorname{erfc} \left(\frac{\gamma_{opt} - \mu_0}{\sigma_0 \sqrt{2}} \right) + \operatorname{erfc} \left(\frac{\mu_1 - \gamma_{opt}}{\sigma_1 \sqrt{2}} \right) \right], \quad (8)$$

$$BER = \frac{1}{2} \operatorname{erfc} \left(\frac{Q}{\sqrt{2}} \right) \approx \frac{e^{-\left(\frac{Q^2}{2}\right)}}{Q\sqrt{2\pi}}. \quad (9)$$

BER je taktiež veľmi úzko spojená so SNR, ktorý môže byť vyjadrený ako miera výkonu signálu (P_S) k miere výkonu šumu (P_N) [19], [21]. Horizontálne zobrazenie na Obr.3 zobrazuje SNR [22]. Platí, že čím bude menšia BER, tým bude väčšia hodnota SNR:

$$SNR = \frac{P_S}{P_N}. \quad (10)$$

V prípade, že signál obsahuje dodatočný šum, zosilňovač zosilní obidve zložky. Môže nastať situácia, keď nebude možné rozoznať signál pre vysokú hladinu zosilňovaného šumu. Korelácia medzi BER a SNR môže byť potom definovaná ako:

$$BER = \frac{1}{2} \operatorname{erfc} \left(\frac{SNR}{2} \right). \quad (11)$$

Pri malej chybovosti je výhodnejšie počítať Q-faktor pomocou OSNR nasledovne:

$$Q_{dB} = 20 \log \sqrt{OSNR} \sqrt{\frac{B_0}{B_E}} = OSNR_{dB} + 10 \log \frac{B_0}{B_E}, \quad (12)$$

kde B_E definuje elektrickú šírku pásma za prijímačom a B_0 optickú šírku pásma, ktorá dopadá na detektor. Pri využití EDFA sa zvyšuje šumové číslo NF (Noise Figure) predovšetkým spontánnou emisiou. V prípade, ak budeme chcieť skúmať ASE (Amplified Spontaneous Emission) voči signálu, tak OSNR môžeme definovať nasledovne:

$$OSNR = \frac{P_{IN}}{NF \cdot h \cdot f \cdot \Delta f}, \quad (13)$$

pričom h je Planckova konštanta ($6.626 \cdot 10^{-34}$), NF je šumové číslo daného EDFA, P_{IN} definuje vstupný výkon, f je frekvencia žiarenia, Δf je šírka pásma, v ktorom sa meria NF. Podľa vzťahu (13) môžeme zdefinovať celkovú veľkosť OSNR, kde dolný index i označuje stupeň daného systému:

$$\frac{1}{OSNR_{CELK}} = \sum_i \frac{1}{OSNR_i}. \quad (14)$$

Vzťah (13) môžeme rozšíriť pre plne optickú komunikačnú linku tak, aby každý EDFA kompenzoval útlm predchádzajúceho OV pri počte N použitých EDFA s rovnakým ziskom. Potom OSNR bude definovaný ako:

$$OSNR_i = \frac{P_0}{NF \cdot \Gamma \cdot h \cdot f \cdot \Delta f}, \quad (15)$$


kde P_0 je definovaný ako výstupný výkon použitého multiplexu a Γ je útlm prekľenuťnej trasy. Podľa vzťahu (14) môžeme definovať celkovú hodnotu OSNR:

$$OSNR_{CELK} = \frac{1}{\sum_{i=1}^N \frac{NF \cdot \Gamma \cdot h \cdot f \cdot \Delta f}{P_0}} = \frac{1}{N \cdot \frac{NF \cdot \Gamma \cdot h \cdot f \cdot \Delta f}{P_0}} = \frac{P_0}{NF \cdot \Gamma \cdot h \cdot f \cdot \Delta f \cdot N} \quad (16)$$

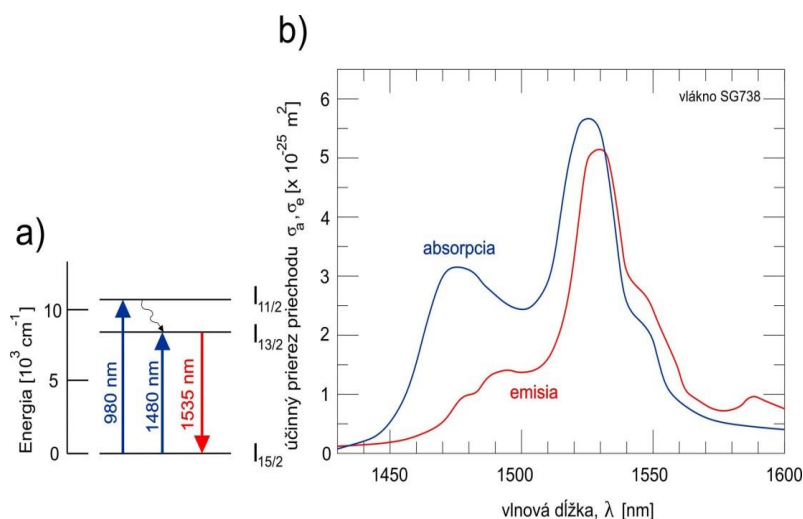
Pri vzťahoch (15) a (16) sme predpokladali, že NF a Γ sa nemenia. Pri použití ROA je OSNR pre stupeň i definovaný ako:

$$OSNR_i = \frac{P_{IN(i)} \cdot G_{RA(i)}}{NF_i \cdot h \cdot f \cdot \Delta f}, \quad (17)$$

kde G_{RA} predstavuje činiteľ, ktorý zvyšuje OSNR pri použití ROA [20]. Zo vzťahu (16) je zrejmé, že pri zväčšujúcej sa vzdialenosti OSNR klesá, ale len pri zapojení s EDFA. Ak by sme chceli redukovať daný pokles, použijeme Ramanove zosilnenie, kde podľa vzťahu (17) sa zvýši vstupný výkon EDFA.



Obr.4 Vzťah medzi BER a Q-faktorom (simulácia v prostredí „Matlab“)



Obr.5 a) Energetické hladiny Erbia b) Absorpčné a emisné spektrum prechodu ${}^4I_{15/2} \leftrightarrow {}^4I_{13/2}$

Pre jednoduchosť bol vytvorený 16-kanálový DWDM systém s odstupom 50 GHz. Daná simulácia bola vytvorená v programovom prostredí „Matlab“, aby sa zobrazil vzťah medzi BER a Q-faktorom. Na Obr.4 je znázornená ideálna krivka pre BER a jej odpovedajúci Q-faktor, pričom červenými bodmi sú zakreslené jednotlivé hodnoty pre konkrétne optické linky. Linka pri rýchlosti 40 Gbit.s⁻¹ môže byť akceptovaná v takom prípade, ak Q-faktor bude mať hodnotu cca 6 a BER bude pod úrovňou 10⁻⁰⁹.

IV. ERBIOM DOPOVANÝ VLÁKONOVÝ ZOSILŇOVAČ

EDFA spôsobil prevrat v oblasti plne optických systémov [23], [24]. Je základným stavebným pilierom, ktorý umožnil vysokorýchlostné a vysokokapacitné spoje na diaľkových trasách a veľkou časťou prispel k rozvoju internetu do takej podoby, v akej ho dnes poznáme [25]. EDFA je tvorený OV s dĺžkou niekoľko desiatok metrov, ktoré je dopované vzácnou zeminou s erbiom Er^{+3} . Princíp bol objavený v šesťdesiatych rokoch dvadsiateho storočia, ale až ekonomickou zvládnuteľnosťou laserových púmp sa začal komerčne vyrábať v deväťdesiatych rokoch. V dnešnej dobe je neodmysliteľnou súčasťou bezpečného množstva xWDM systémov po celom svete [26]. Medzi hlavné výhody môžeme zaradiť najmä možnosť zosilňovania na všetkých vlnových dĺžkach súčasne (schopnosť zvyšovania kapacity namiesto bitovej rýchlosti). Vďaka EDFA rapídne klesla cena výstavby optických sietí. Namiesto jedného drahého opakovača určeného len pre jednu vlnovú dĺžku je možné použiť jeden EDFA pre celé spektrum vlnových dĺžok v jednom OV.

Aby sme výklad zjednodušili, predpokladajme, že ióny Er^{+3} , ktorými je prostredie dopované, môžu existovať najmenej v dvoch diskretných stavoch, a to v základnom alebo excitovanom. V tepelnej rovnováhe je počet iónov nachádzajúcich sa na jednotlivých energetických hladinách daný Boltzmanovým rozdelením. Väčšina iónov sa teda nachádza v základnom stave s minimálnou energiou.

Interakciu takéhoto súboru iónov s kvantami svetelnej energie – fotónmi – teoreticky vysvetlil Albert Einstein.

Hovorí o troch rôznych javoch, ktoré môžu nastať: absorpcia, stimulovaná emisia a spontánna emisia. Absorpciou fotónu s energiou, ktorá sa rovná rozdielu energetických hladín, sa ión v základnom stave prevedie do stavu excitovaného [23], [26]. Z vybudeneho metastabilného stavu môže ión prejsť späť na základnú hladinu buď spontánne, a to za súčasného vyžiarovania fotónu s náhodnou polarizáciou a fázou, alebo je k emisii fotónu stimulovaný iným fotónom. V prípade stimulovanej emisie majú obidva fotóny rovnaké polarizačné a fázové vlastnosti (hovoríme, že sú koherentné).

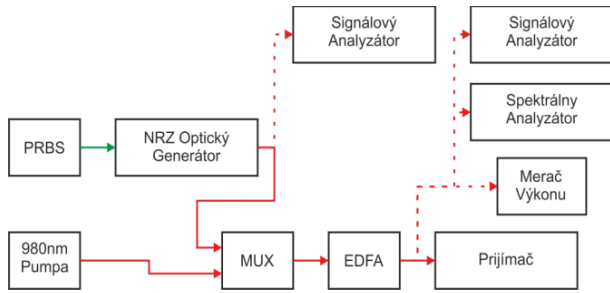
Aktívne prostredie môže byť vyvedené z tepelnej rovnováhy, napr. prítomnosťou čerpaceho svetelného zdroja. Ak iné vplyvy nepôsobia na aktívne prostredie, tak dostatočne silné čerpanie spôsobí, že väčšina iónov zostane v excitovanom stave natrvalo.

Ak privedieme do excitovaného aktívneho prostredia optický signál, bude u fotónov optického signálu prevažovať stimulovaná emisia nad absorpciou, a teda signál bude zosilňovaný. Fotóny generované spontánnou emisiou prispievajú k rastu šumu zosilňovača.

Energetické hladiny významné pre zosilňovanie optického signálu v pásme 1.5 μm zobrazuje Obr. 5a. Na Obr. 5b je metastabilná hladina ${}^4I_{13/2}$, ktorá môže byť čerpaná buď priamo na 1480 nm, alebo cez hladinu ${}^4I_{11/2}$ na 980 nm. Doba života iónu na hladine ${}^4I_{11/2}$ je veľmi krátka (približne 7 μs) v porovnaní s dobou života hladiny ${}^4I_{13/2}$ (približne 10 ms), takže ión vybudovaný na hladinu ${}^4I_{11/2}$ prejde rýchlo na metastabilnú hladinu ${}^4I_{13/2}$. Jednotlivé hladiny sú označené podľa Russelovej-Soundersovej konvencie vychádzajúcej z kvantovej atomárnej teórie. Rozšírenie hladín je na Obr.5b ilustrované na tvare absorpčného a emisného spektra prechodu ${}^4I_{15/2} \leftrightarrow {}^4I_{13/2}$ v erbiom dopovanom optickom vlákne.


A. Realizácia zapojenia EDFA s vhodnou zmenou pumpovacieho výkonu

Celý prvý experimentálny systém obsahuje 5 základných častí, ktoré boli následne implementované do DWDM (Obr.6).



Obr.6 Experimentálny model na zapojenie EDFA s popredným čerpaním

Zdroj dát (PRBS) má nastavenú prenosovú rýchlosť na 10 Gbit.s⁻¹. Ním vytvorený logický signál vstupuje do optického generátora. Generátor využíva kódovanie typu NRZ a využíva filter typu Ring. Generovaný optický signál vstupuje do multiplexu a následne do zosilňovača. Celý realizovaný systém je zosilňovaný v pásme C pre konkrétnu vlnovú dĺžku 1550 nm. Popredná pumpa je nastavená na 980 nm s výkonom 60 mW. V danom zapojení bola vytvorená iterácia so zámerom porovnania zisku, šumového čísla NF a spontánnej emisie ASE. V celej iterácii je menený pumpovací výkon od 10 mW do 85 mW s inkrementom 5 a následne hodnota *k* s inkrementom 0,1 od hodnoty 0 po hodnotu 0,3 (Obr.7).




Obr.7 Zmena pumpovacieho výkonu EDFA voči zisku pri 1550 nm pre k=0, 0.1, 0.2 a 0.3

Na Obr.7 je zobrazený maximálny zisk pre hodnotu *k* = 0 a tiež je znázornené, že so zvyšujúcou sa hodnotou *k* bude klesať zisk EDFA. Z daných grafov vychádza, že maximálny zisk dosahuje hodnotu 44,7531 dB a NF sa rovná 3,25729. Kľúčový komponent EDFA má konštantnú dĺžku vlákna dopovaného erbiom počas všetkých simulácií – 14 m a vláknová saturácia vo vlákne je nastavená na hodnotu 3,1015 m⁻¹s⁻¹.

Na Obr.8 je znázornená zmena pumpovacieho výkonu voči zmene dĺžky optického vlákna. Je vytvorená iterácia, pri ktorej


sa mení pumpovací výkon v rozsahu od 20 mW do 85 mW voči dĺžke vlákna erbiom dopovaného od 2 m do 20 m s inkrementom 1 m. Pri pumpovacom výkone 35 mW bol optický výkon -5,7233 dBm. Pri 50 mW sa výkon zmenil na 2,5419 dBm, pri 65 mW výkone predstavoval hodnotu 3,9082 dBm a pri 80 mW optický výkon dosiahol hodnotu 4,9511 dBm. Z daného grafu bola zvolená dĺžka vlákna dopovaného erbiom. Spektrálny model na 980 nm je typu „rectangular“, straty predstavujú 6,2 dB.m⁻¹ a šírka je nastavená na 20 nm. Zapojenie EDFA je bez zrkadiel.




Obr.8 Zmena dĺžky vlákna erbiom dopovaného pri zmene pumpovacieho výkonu

ASE je šum, teda v podstate svetlo vytvorené samovoľnou emisiou, ktoré je opticky zosilnené procesom stimulovanej emisie žiarenia vo vlákne. ASE nám negatívne ovplyvňuje maximálny zisk, ktorý môžeme teoreticky dosiahnuť.

Na Obr. 9a – c môžeme vidieť spätné pumpovanie pri zmene pumpovacieho výkonu (Obr 9a – 10 mW, Obr. 9b – 50 mW, Obr 9c– 85 mW).



Obr.9 a) Spätné pumpovanie pri 10 mW, b) Spätné pumpovanie pri 50 mW, c) Spätné pumpovanie pri 85 mW



Obr.10 Diagramy oka pre a)-95 km, b)-105 km, c)-115 km bez použitia EDFA.

B. Nutnosť použitia EDFA ako IN-Line


Cieľom tejto simulácie bolo pozorovanie BER pri konštantnej rýchlosti 10 Gbit.s⁻¹ pre OV s dĺžkou 95 km, 105 km a 115 km bez vytvorenia optickej slučky. V tejto topológii boli nastavené nasledovné parametre: CW laser má nastavený výkon na 10 mW, pričom pracuje na vlnovej dĺžke 1550 nm, elektrický generátor je typu NRZ a externý modulátor využíva moduláciu typu „Machzender“. Dĺžka OV bola menená od 95 km do 115 km s inkrementom 10 km na porovnanie BER (Obr.10) a výsledné hodnoty sú v Tab.1. Hodnoty BER_{min} a BER_{max} v Tab.1 označujú minimálnu a maximálnu hodnotu BER pre danú dĺžku. Jednovidové OV malo merný útlm 0,25 dB.km⁻¹ podľa štandardu ITU-T G.652.D, pričom ani v tomto prípade neboli brané do úvahy PMD, SBS ani Ramanov efekt. Prijímač využíval Besselov filter so šírkou pásma 9 GHz. Reprézntácia výsledných hodnôt bola založená na type Monte Carlo.

Pri dĺžke OV 95 km bola nameraná BER = 7,5159⁻¹⁴, čo postačuje na spoľahlivé rozlíšenie impulzov na prijímacej strane. V simulácii pri 105 km bola odsimulovaná BER = 1,4462⁻⁵ a pri 115 km bola BER = 9,1415⁻³, čo ale nie sú hodnoty vhodné pre optické komunikačné systémy. Z tohto vyplýva, že BER klesla na úroveň, ktorá nie je vhodná na diaľkové vedenia a na preklopenie väčšej vzdialenosti je už potrebné použiť optické zosilňovače. V našom prípade sme optické zosilňovače aplikovali na diaľkových spojoch v rozsahu od 80 km do 100 km.

Tab.1 Výstupné hodnoty BER a Q pri dĺžke OV: 95 km, 105 km a 115 km

Dĺžka OV(km)	BER	BER _{min}	BER _{max}	Q ² (dB)
95	7.5159 ⁻¹⁴	5.8209 ⁻¹⁵	8.7016 ⁻¹³	17.369
105	1.4462 ⁻⁵	6.2035 ⁻⁶	3.2586 ⁻⁵	12.427
115	9.1415 ⁻³	6.8273 ⁻³	1.2116 ⁻²	7.4576

So vzrastajúcou bitovou rýchlosťou a dĺžkou optického vlákna dochádza na prijímacej strane k zhoršovaniu BER a Q-faktora. Na Obr.11 môžeme vidieť závislosť Q-faktora od dĺžky optického vlákna a od bitovej rýchlosti. Pri bitovej rýchlosti 20 Gbit.s⁻¹ a vyššej je zrejme, že kvalita linky je nedostačujúca a hodnota BER nevyhovujúca. V našom navrhnutom systéme sme zvyšovali bitovú rýchlosť od 10 Gbit.s⁻¹ do 40 Gbit.s⁻¹ s inkrementom 10 so zámerom pozorovať závislosť Q-faktora od dĺžky OV.



Obr.11 Vzťah Q-faktora a vzdialenosti pri menenej bitovej rýchlosti

C. Aplikácia EDFA do DWDM systému na diaľkovej linke

V predošlej simulácii pri danej bitovej rýchlosti nebolo možné dosiahnuť väčšie preklenovacie vzdialenosti než 105 km až 115 km. Z tohto dôvodu je potrebné použiť optické zosilňovače typu IN-Line, ktoré sa priebežne zapájajú do optickej trasy. Najpoužívanejší IN-Line je EDFA. Nami využívaný EDFA zosilňovač mal nastavené nasledovné parametre: dĺžka erbiom dopovaného optického vlákna bola 14 m (najlepší zisk podľa Obr.8) pričom vlnová dĺžka lasera bola 980 nm s pumpovacím výkonom 4 mW. Na vytvorenie diaľkovej optickej linky bola vytvorená optická slučka. Táto optická slučka obsahovala EDFA s pumpovacím zdrojom a optické vlákno s dĺžkou 95 km, ktoré zodpovedalo štandardu ITU-T G.652.D. V Tab.2 môžeme vidieť výsledné hodnoty s inkrementom 5. Cieľom tejto simulácie je demonštrácia BER na vzdialenosti väčšie než 3200 km pri rýchlosti 10 Gbit.s⁻¹. Pri vzdialenosti 2375 km dosahovala BER na výstupe hodnotu 1,6492⁻²⁰. So zvyšujúcou sa vzdialenosťou na 3325 km sa BER dostala na hodnotu 6,4325⁻¹¹, čo je ešte akceptovateľná hodnota pre optické prenosy. Najväčšia vzdialenosť, ktorá bola merateľná, bola 4085 km, pri ktorej BER = 2,9118⁻⁵, pričom táto hodnota nie je taktiež vyhovujúca pre optické komunikácie.

Nami vytvorený systém môže byť aplikovaný na diaľkový prenos 3325 km.

Tab.2 Výstupné hodnoty BER a Q na diaľkovej linke

Počet iterácií/km	BER	BER _{min}	BER _{max}	Q ² (dB)
25/2375	1.6492 ⁻²⁰	1.3855 ⁻²⁴	8.1108 ⁻¹⁷	19.284
30/2850	1.5429 ⁻¹³	6.5111 ⁻¹⁶	3.7065 ⁻¹¹	17.255
35/3325	6.4325 ⁻¹¹	1.4581 ⁻¹²	2.1144 ⁻⁹	16.163
40/3800	1.5673 ⁻⁷	1.5975 ⁻⁸	1.3357 ⁻⁶	14.177
43/4085	2.9118 ⁻⁵	5.1401 ⁻⁶	1.5900 ⁻⁴	12.084
45/4275	-	-	-	-

D. Publikované výsledky v danej oblasti výskumu

S. Semmalar... [et al.] realizovali EDFA zosilňovač, na ktorom menili pumpovací výkon pre rôzne dĺžky vlákna EDFA [27]. V článku opísali realizáciu EDFA pre tri rôzne pumpovacie schémy s rôznou dĺžkou optického vlákna (10 m, 50 m a 120 m). Simulačný model, ktorý vytvorili, obsahoval zdroj s vlnovými dĺžkami od 1520 nm do 1618 nm, pumpovací zdroj pracujúci na 980 nm, izolátor a filter. V článku namodelovali EDFA s rozdielnymi pumpovacími schémami tak, aby bolo možné na výstupe zmierniť OSNR a nelineárne efekty v DWDM.

S. Novak... [et al.] skúmali analytický model pre zisk dosiahnutý v EDFA [28]. Ich navrhnutý analytický model bol použitý na skúmanie vstupného signálu EDFA v závislosti od vlnovej dĺžky. Zistili, že vstupný pumpovací modulačný signál sa zvyšuje s výkonom signálu (t. j. zvyšuje sa na maximum a potom klesá, keď EDFA je už hlboko nasýtený).

P. Schiopu... [et al.] analyzovali zisk voči vstupnému výkonu EDFA [29]. Na počítanie vstupného výkonu a zisku použili metódu známu ako *Runge-Kutta*. V práci porovnávali teoretické výsledky s experimentálnymi hodnotami zisku voči vstupnému pumpovaciemu výkonu. Tiež prezentovali analytickú metódu na označenie EDFA zisku ako funkcie vstupného pumpovacieho výkonu.

A. Goel... [et al.] realizovali EDFA, v ktorom použili pumpovanie na vlnových dĺžkach 980 nm a 1480 nm [30]. Zvyšovali počet kanálov v danom DWDM systéme, pričom na výstupe potrebovali dosiahnuť konštantný zisk v celej šírke použitého pásma. V práci navrhujú širokopásmové EDFA pracujúce v pásmach C a L s využitím jazyka VHDL-AMS. Ich návrh používa dve pumpovacie schémy, ktoré poskytujú priemerný výkon -16 dBm na šírku pásma 80 nm.

G. Bobrov... [et al.] realizovali WDM so zámerom opísať fyzikálne správanie EDFA [31]. Realizovali štvorkanálový systém s EDFA, umiestneným ako IN-Line, so zámerom vyhodnocovania ASE. Výsledky, ktoré dosiahli v simuláciách, následne porovnávali s reálne nameranými hodnotami z laboratória, pričom poukázali na nutnosť realizácie v simulačnom prostredí. V závere konštatujú, že zosilnenie závisí od parametrov ako signálový výkon, vlnová dĺžka, dĺžka OV a konfigurácia pumpovacieho lasera.

V. REALIZÁCIA DWDM PRE POTLAČENIE JAVOV XPM A SPM

A. Oplyňovanie nelineárneho javu XPM

Na realizáciu javu XPM bol vytvorený štvorkanálový DWDM systém. Cieľom simulácií bolo potlačiť jav XPM menením disperzie v OV a nerovnomerným rozdelením optického výkonu v susedných kanáloch. Optická slučka s OV, EDFA zosilňovačom a kompenzátorom disperzie sa realizovala v následnej konfigurácii: Výstupný výkon EDFA


boostru sa nastaví na 9 dBm (7,943 mW) a OV za zosilňovačom na dĺžku 100 km so stratami 0,33 dB.km⁻¹. Ani v tejto topológii nie sú brané do úvahy SBS a PMD. Za OV je umiestnený IN-Line zosilňovač EDFA, ktorý má nastavený zisk na 20 dB s NF = 4,5. Nasleduje OV s dĺžkou 100 km s merným útlmom 0,33 dB.km⁻¹ a na záver je umiestnený kompenzátor a zosilňovač. Jednotlivé prijímacie jednotky sú vytvorené tak, aby filtrovali iba požadovaný signál.

Prvá simulácia bola urobená so zámerom zmeny spektra od 193,025 THz do 193,175 THz s inkrementom 0,05 THz (nerovnomerné vysielačie výkony -10 dBm, -30 dBm, -10 dBm, -30 dBm). V druhej simulácii sme vytvorili optickú slučku, kde sme menili disperziu s inkrementom 1 od 0 ps/nm/km do 4 ps/nm/km na rozdielne výkony (Obr. 12 vpravo). Výsledné hodnoty BER a Q-faktora pri frekvencii 193,075 THz sú v Tab.3.

Tab.3 BER pri zmene disperzie pre 193,075 THz (-10 dBm, -30 dBm, -10 dBm, -30 dBm)

Iterácia	Disperzia [ps/nm/km]	BER	Q-faktor
1	4	2.78829·10 ⁻²⁷	10.8897
2	3	1.82561·10 ⁻²⁰	9.45166
3	2	2.49807·10 ⁻¹¹	6.77286
4	1	0.0003541	3.36911
5	0	0.0222751	2


Na Obr.12 vpravo je zelenou farbou znázornená krivka pri hodnote disperzie 0 ps/nm/km, modrou krivkou je znázornené spektrum pri hodnote disperzie 1 ps/nm/km a červenou krivkou je znázornené spektrum pri hodnote 4 ps/nm/km. Z výsledných hodnôt v Tab. 3 môžeme potvrdiť, že s poklesom disperzie sa hodnota BER zvyšuje. Optický kanál na frekvencii 193,075 THz bude akceptovaný pre hodnoty disperzie 4, 3 a 2. Vďaka rôznym hodnotám vstupných výkonov môžeme čiastočne potlačiť jav XPM na jeho výstupe.



Obr.12 Výstupne spektrum pri zmene disperzie pre výkony -10 dBm, -30 dBm, -10 dBm, -30 dBm

Druhá simulácia bola aplikovaná na rovnakú schému, avšak zmenili sme vysielačie výkony všetkých štyroch kanálov. Na Obr.13 vpravo môžeme vidieť, aký vplyv má zmena vysielačích výkonov na XPM. Výsledné hodnoty BER a Q-faktora pre frekvenciu 193,075 THz pri vysielačích výkonoch -10 dBm, -20 dBm, -30 dBm a -40 dBm sú v Tab.4. Z výsledkov daných simulácií môžeme konštatovať, že pri vhodnej voľbe vysielačích výkonov a vhodnej voľbe disperzie môžeme čiastočne potlačiť nelineárny jav XPM. Pri porovnaní Tab.3 a Tab.4 je zjavné, že zlepšenie BER môžeme dosahovať

vhodnou voľbou vysielacích výkonov v susedných kanáloch. Linka je akceptovaná pre hodnoty disperzie 4, 3, 2 a 1.



Obr.13 Výstupné spektrum pri zmene disperzie pre výkony -10 dBm, -20 dBm, -30 dBm, -40 dBm

Tab.4 BER pri zmene disperzie pre 193,075 THz (-10 dBm, -20 dBm, -30 dBm, -40 dBm)


Iterácia	Disperzia [ps/nm/km]	BER	Q-faktor
1	4	$1.10 \cdot 10^{-40}$	13.6235
2	3	$2.01306 \cdot 10^{-28}$	11.2943
3	2	$5.17325 \cdot 10^{-16}$	8.01867
4	1	$1.16095 \cdot 10^{-17}$	5.12306
5	0	0.0227501	2

B. Oplyvňovanie nelineárneho javu SPM

Na skúmanie SPM sú vytvorené dve simulácie. V prvej simulácii dochádza k zmene disperzie v OV a v druhej k zmene výkonu EDFA, pričom systém je hodnotený na základe výstupných spektier. Vysielacia jednotka bola tvorená štyrmi základnými blokmi: laser, modulátor, blok kódovania a zdroj dát. V tomto prípade zdroj dát generuje bitovú rýchlosť 2,5 Gbit.s⁻¹, ktorá vstupuje do bloku kódovania (logický signál). V tomto bloku sa vybral typ kódovania, v našom prípade NRZ, a dáta vstupujú do modulátora (elektrický signál). Laser, ktorý je na začiatku blokovej schémy, je typu CW a má nastavený výkon na 13 dBm pri vlnovej dĺžke 1545 nm (194,04043 THz). Optický signál vystupujúci z CW lasera vstupuje do modulátora. Nami navrhnutý modulátor využíval moduláciu typu „MachZehnder“. Z modulátora vystupuje optický signál, ktorý by v prípade väčšieho množstva kanálov vstupoval ešte do multiplexoru. V prvej navrhutej topológii sme menili disperziu v OV. Vytvorili sme optickú slučku, do ktorej sme umiestnili OV s dĺžkou 90 km, s útlmom 0,33 dB.km⁻¹ (slučku sme opakovali 8-krát).


So zámerom skúmať jav SPM sme v OV menili disperziu (0, 5 ps/nm/km a 15 ps/nm/km). Za OV sme umiestnili EDFA s výkonom 15 mW, ktorý zosilňoval signál aj s vytvorenou (nakumulovanou) disperziou. Pri tejto topológii sme nebrali do úvahy PMD ani SBS. V prípade väčšieho množstva kanálov by sa ešte pred prijímacou jednotkou nachádzal demultiplexor. Optický signál vstupuje do PIN, ktorá je nastavená na konkrétnu vlnovú dĺžku. Vo všetkých simuláciách bol použitý „Besselov“ filter na výstupe.

Na Obr. 14 je znázornené výkonové spektrum s menenou disperziou. Zelenou krivkou je znázornená nulová disperzia, červenou krivkou disperzia s hodnotou 5 ps/nm/km a hnedou krivkou je znázornená disperzia s hodnotou 15 ps/nm/km.



Obr.14 Výkonové spektrum na 194.04 THz s rozdielnou disperziou na ovplyvňovanie SPM

Z daného spektra je možné pozorovať, aký vplyv má disperzia vo vlákne na daný jav a ako je zobrazené spektrum signálu po prekonaní vzdialenosti 720 km (8 × EDFA, 90 km OV). V danom spektre vidíme, že zhoršenie je spôsobené kombináciou disperzie a vysielaného optického výkonu. Znížením vysielacích výkonov CW a vhodnou voľbou disperzie možno zmierniť daný jav. Druhá simulácia je tvorená so zámerom zmeniť výkon EDFA v optickej slučke. Vo vysielacej časti je zvýšená bitová rýchlosť na 10 Gbit.s⁻¹ a v optickej slučke je použité OV s dĺžkou 50 km s disperziou 0,4 ps/nm/km. Centrálna frekvencia je posunutá na 193 THz a výsledné spektrum je vykreslené na Obr. 15. Optická slučka sa opakuje dvakrát pri zmene výstupného výkonu EDFA (zelená krivka – 10 dBm, hnedá krivka – 15 dBm a červená krivka – 17,5 dBm).



Obr.15 Výkonové spektrum na 193 THz pri zmene výkonu EDFA na ovplyvňovanie SPM

C. Publikované výsledky v oblasti nelineárnych javov typu XPM a SPM

Lee... [et al.] navrhli metódu na redukciu XPM s časovým oneskorením a zmenou vysielacích výkonov v DWDM systéme [32]. Realizovali dvanásťkanalový DWDM s vytvorenou optickou slučkou, v ktorej bol umiestnený ako

IN-Line EDFA a OV (100 km) s rýchlosťou 10 Gbit.s⁻¹. Realizovali tri simulácie na pozorovanie javu XPM. V prvej topológii nechali rovnaký rozstup 0,4 nm s rovnakým výkonom. V druhej simulácii menili len časové oneskorenie a v tretej kanálový rozstup (0,625 nm a 0,35 nm). Výsledné hodnoty autori porovnávali ako funkcie výkonu a vzdialenosti k hodnote Q-faktora.

Guesmi... [et al.] vytvorili vysokorýchlostné fázovo modulované WDM systémy [33]. Realizovali systém, v ktorom použili jeden CW laser a WDM Nyquistove kanály. Vysokokapacitné prenosy poukazujú na zmenu XPM pri rôznych hodnotách DGD (Differential Group Delay). Výstup systému je hodnotený ako počet kanálov v pomere k výstupnému výkonu pri rôznych hodnotách DGD.

Anamika... [et al.] realizovali WDM s využitím Ramanovho zosilňovača [34]. Použili DPSK, pričom menili bitovú rýchlosť a tvar impulzov. V článku definujú, že pri nižšej bitovej rýchlosti v danom systéme bude väčšia citlivosť XPM presluchu. V závere vytvorili 40 Gbit.s⁻¹ systém s RZ-DPSK, ktorý vykazuje najlepšie hodnoty XPM.

Udalovs... [et al.] navrhli osemkanálový systém, na ktorom pozorovali jav SPM [35]. Realizovali systém UDWDM pri rozstupe 12,5 GHz pri bitových rýchlostiach 10 Gbit.s⁻¹ a 40 Gbit.s⁻¹ s tromi typmi modulácií. Keďže sa snažili preukázať nelineárny jav SPM, daný systém nebol realizovaný na diaľkové spoje (60 km). Rozhodovaciu úroveň pre BER mali nastavenú na 10⁻⁶ a porovnali jednotlivé modulačné formáty s daným systémom pri danej bitovej rýchlosti.

Ivaniga... [et al.] navrhli osem a šesťkanálový systém so zámerom ovplyvňovať jav SPM [36]. Vo vysielačej jednotke boli vytvorené bloky kódovania typu NRZ a Miller. Tieto kódy boli vytvorené v programe „Matlab“ a následne boli implementované do programového prostredia „OptSim“ od spoločnosti RSoft a použité v realizovanom DWDM systéme. Daný systém poukázal na výhody použitia NRZ pri rozstupe medzi kanálmi 25 GHz a 50 GHz. Pomocou daných simulácií bolo poukázané na jav SPM v optickom komunikačnom systéme a ako lineárne narastá BER v súvisi s vysielačím výkonom.

Nain... [et al.] prezentovali SPM na jednej optickej linke [37]. Snažili sa o elimináciu javu zmenšením bitovej rýchlosti na 5 Gbit.s⁻¹. V závere definujú, že v ich navrhnutom systéme pri zvyšovaní dátovej rýchlosti bude jitter narastať, zatiaľ čo pri XPM a FWM bude klesať. Systémy na pozorovanie javov SPM, XPM a FWM boli taktiež vytvorené v programovom prostredí „OptSim“.

Ivaniga... [et al.] opísali matematické rovnice používané v AWG rozbočovačoch [38]. AWG multiplex bol použitý pri realizácii dvojkanálového DWDM. V optickej časti bolo využité vlákno, na ktorom bola menená disperzia s inkrementom 10 ps/nm/km. Diagramy oka boli hodnotené pred a po ovplyvňovaní daného javu. Na základe daných hodnôt bol systém rozšírený o viac kanálov.

Miziya... [et al.] navrhli plne optický komunikačný systém zameraný na vyšetrovanie a analýzu disperznej kompenzovanej linky s dĺžkou OV 100 km na 1550 nm [39]. Simulácie

opakovali pri rôznych hodnotách zisku EDFA a taktiež pri rôznych modulačných formátoch, pričom použili vlákno DCF. Preukázali, že pri použití zosilňovača umiestneného ako „booster“ sa vplyv nelineárnych efektov zvyšuje.

Ivaniga... [et al.] realizovali dvojkanálový DWDM s rozstupom 50 GHz [40]. Cieľom daného príspevku bolo ovplyvňovanie javu SPM s EDFA, ktorý bol umiestnený ako IN-Line. V článku sa menil optický výkon (-80 dBm, 0, 80 dBm) v jednotlivých vysielačích kanáloch a taktiež výkon EDFA (-80 dBm, 0, 80 dBm). Článok poukazuje na vhodnú konfiguráciu zapojenia EDFA ako IN-Line zosilňovača.

VI. ZÁVER

Cieľom prvej časti príspevku bolo vhodné nastavenie parametrov EDFA. V správnej konfigurácii EDFA možno aplikovať tento zosilňovač na diaľkové spoje. Veľmi dôležitý parameter je vysielač výkon. Avšak s vyšším vysielačím výkonom dochádza k vzniku nelineárneho javu SPM. Na základe vytvorenej schémy DWDM bolo možné určiť optimálne parametre: vysielač výkon, NF alebo dĺžku vlákna dopovaného erbiom. EDFA sa používajú na priebežné zosilnenie signálov v optickej trase po cca 95 km – 105 km (Obr.10). Na základe daných simulácií bola následne vytvorená optická slučka so zámerom prekonania maximálnej prekľenuťnej vzdialenosti s akceptovateľnou BER na výstupe. Dokázali sme vytvoriť topológiu na 3325 km, kde dochádzalo k regenerácii optického signálu každých 95 km. V danom systéme sme zvyšovali bitovú rýchlosť, avšak na úkor vzdialenosti. Systém sme považovali za akceptovateľný pokiaľ neklesol pod hodnotu 10⁻¹².

V druhej časti príspevku sme realizovali systémy pre potlačenie javov SPM a XPM. V prípade SPM bolo potrebné vhodne voliť vysielačie výkony a OV s disperziou. Z meraných spektier je zrejmé, že pri znižovaní vysielačieho výkonu môžeme čiastočne potláčať tento jav na výstupe. Avšak pri znižovaní vysielačích výkonov dochádza k zmenšovaniu dosiahnuteľnej vzdialenosti optickej linky, a teda k nutnosti použiť väčší počet zosilňovačov v optickej trase. Aby sme mohli čiastočne eliminovať SPM, je v podstate potrebné vysielať na nižších výkonových úrovniach alebo voliť OV s vyššou efektívnou oblasťou. Treba poznamenať, že v OV s menšou disperziou majú interkanálové nelinearity oveľa väčší dopad ako v OV s väčšou disperziou. Na mieru XPM vplyva vzájomná polarizácia kanálov, nelineárny koeficient OV, rozstup kanálov a disperzia. XPM sme čiastočne eliminovali znížením vysielačích výkonov (resp. vhodnou konfiguráciou vysielačích výkonov), čím sme ale skrátili maximálnu prekľenuťnú vzdialenosť kvôli ASE. XPM môžeme potláčať zväčšením rozstupov a OV s veľkou disperziou. Pri návrhu systému by XPM a FWM nemali prekročiť hodnotu 0,5 dB straty signálu. V prípade našich odsimulovaných hodnôt v programovom prostredí „OptSim“ by presnosť merania nemala prekročiť hodnotu ±10 % pri daných podmienkach.

VII. LITERATÚRA

- [1] K. Grobe, M. Eiselt, “Wavelength Division Multiplexing: A Practical Engineering Guide“, ISBN: 978-0-470-62302-2, 2013, 432 pp.

- [2] P. Ivaniga, "Hodnocení chybovosti ve vysokorychlostních digitálních sítích", ISBN 978-80-8070-771-2, 97 pp.
- [3] J. M. Senior, "Optical Fiber Communications, Principle and Practice, third edition," ISBN: 978-0-13-032681-2, 2009, 1127pp.
- [4] P. Ivaniga, L. Mikuš, "Measuring of Block Error Rates in High-Speed Digital Networks", *Advances in Electrical and Electronic Engineering*, vol. 5, 2011, pp. 35-36.
- [5] F. M. Madan, K. Kikuchi, "Design theory of long-distance WDM dispersion-managed transmission system", *Journal of Lightwave Technology*, vol. 17, no. 8, Aug. 1999, pp. 1326-1335.
- [6] A. Abduallev, J. Turán, "Survey of the Problems and Solutions of Arrayed Waveguide Gratings Used in the Optical Networks", *Acta Electrotechnica et Informatica*, vol. 14, no. 3, 2014, pp. 49-53, doi: 10.15546/aei-2014-0029.
- [7] P. Ivaniga, "Evaluation of quality in the broadband networks", *Proceedings of Int.I AMSE*, vol. 01, 1996, ISBN: 80-214-0768-9, pp. 213-215.
- [8] R. Ramaswami, K. Sivarajan, G. Saseki, "Optical Networks: A Practical Perspective, 3rd Edition", ISBN: 978-0-123-74092-2, 2009, 928 pp.
- [9] G. P. Agrawal, "Fiber-Optic Communication Systems. 3rd edition", ISBN: 0-471-21571-b, 2002, 576 pp.
- [10] J. You, N. C. Panoiu, "Calculation of Bit Error Rates in Optical Systems With Silicon Photonic Wires," *IEEE Journal of Quantum Electronics*, vol. 51, no. 4, 2015, pp. 1-8, doi: 10.1109/JQE.2015.2398516.
- [11] P. Ivaniga, L. Mikuš, "The relationship between G.826 Error Performance Objectives and Equivalent BER", *Journal of Information, Control and Management Systems*, vol. 5, no.1, 2007 pp.39 – 45.
- [12] G. P. Agrawal, "Nonlinear Fiber Optics-4th edition", ISBN: 978-0-12-395821-1, 2007, 546 pp.
- [13] P. Ivaniga, J. Smieško, "The relationship between Q - factor and the error rate in optical networks", *International Journal of Science Commerce and Humanities*, vol. 2, no. 3, 2014, pp. 96-102.
- [14] S. V. Kartalopoulos, "Optical Bit Error Rate: An Estimation Methodology," ISBN: 978-0-471-61545-3, 2004, 291 pp.
- [15] M. Drozdová, L. Mikuš, P. Paluch, "Komunikačné technológie 1", ISBN 978-80-554-0835-4, 279 pp.
- [16] P. Ivaniga, "Informační sítě I", 1 vyd. Žilina, Žilinská univerzita, 1997, ISBN 80-7100-375-1, 98 pp.
- [17] K. Miziya, S. K. Sudheer, A. C. Kuriakose, "Characterization of an optical communication system utilizing dispersion compensating fiber and nonlinear optical effects", *Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT)*, 2013, pp. 1-6, doi: 10.1109/ICCCNT.2013.6726479.
- [18] P. Ivaniga, L. Mikuš, "Measuring of block error rates in optical transport networks", *Journal of Information, Control and Management Systems*, vol. 4, no. 2, 2006, pp. 223-230.
- [19] L. Mikuš, "Hodnocení chybovosti v páteřních sítích", *Elektrorevue*, vol. 12, no. 2, 2010, pp.1-6.
- [20] J. Papán, P. Segeč, M. Drozdová, L. Mikuš, M. Moravčík and J. Hrabovský, "The IPFRR mechanism inspired by BIER algorithm," 2016 International Conference on Emerging eLearning Technologies and Applications (ICETA), Vysoké Tatry, 2016, pp. 257-262.
- [21] T. Ivaniga, P. Ivaniga, "Comparison of the Optical Amplifiers EDFA and SOA Based on the BER and Q-Factor in C-Band," *Advances in Optical Technologies*, vol. 2017, 2017, ID 9053582, pp.1-9, doi.org/10.1155/2017/9053582.
- [22] P. Ivaniga, T. Ivaniga, "10 Gbps optical line using EDFA for long distance lines" *Przeglad Elektrotechniczny*, vol. 93, no.3, 2017, pp. 193-196, doi:10.15199/48.2017.03.45.
- [23] T. Ivaniga, P. Ivaniga, J. Turan, L. Ovsenik, "Analysis of possibilities of increasing the spanned distance using EDFA and DRA in DWDM system ", *Communications-Scientific Letters of the University of Žilina*, vol. 19, no. 3, 2017, pp. 88-95.
- [24] P. Ivaniga, T. Ivaniga, "Comparison of DPSK and RZ-DPSK Modulations in Optical Channel with Speed of 10Gbps", *Journal of Information and Organizational Sciences*, vol. 41, no. 2, 2017, pp. 185-196.
- [25] T. Liu, I. B. Djordjevic, "Signal Constellation Design for Cross-Phase Modulation Dominated Channels", *IEEE Photonics Journal*, vol. 7, no. 4, 2015 pp. 1-4, doi: 10.1109/JPHOT.2015.2453880.
- [26] A. Galtarossa, R. C. Menyuk, "Polarization Mode Dispersion (Optical and Fiber Communications Reports)", ISBN: 978-1441920041, 2010, 296 pp.
- [27] S. Semmalar, S. Malarkkan, "Output Signal Power Analysis in Erbium-Doped Fiber Amplifier with Pump Power and Length Variation Using Various Pumping Techniques", *International Scholarly Research Notices*, vol. 2013, ID 312707, pp. 1-6, dx.doi.org/10.1155/2013/312707.
- [28] S. Novak, A. Moesele, "Analytic model for gain modulation in EDFAs", *Journal of Lightwave Technology*, vol. 20, no. 6, 2002, pp. 975-985.
- [29] P. Schiopu, F. Vasile, "The EDFA performance with gain versus pump power," *Proceedings of the 27th IEEE International Semiconductor Conference (CAS '04)*, October 2004, pp. 241-244.
- [30] A. Goel, R. S. Mishra, "Design of broadband erbium-doped fiber amplifier using very high-speed integrated circuit hardware description language for next-generation optical network", *Optical Engineering*, vol. 50, no. 1, 2011, pp. 1-6.
- [31] G. Ivanovs, V. Bobrovs, S. Olonkins, A. Alsevska, L. Gegere, R. Parts, P. Gavars, G. Lauks, "Application of the erbium-doped fiber amplifier (EDFA) in wavelength division multiplexing (WDM) transmission systems", *International Journal of Physical Sciences*, vol 9, no. 5, 2014, pp. 91-101, doi: 10.5897/IJPS2013.4066.
- [32] Y. Lee, S. Lee, E. Kim and J. Park, "Chirp Reduction by SPM and XPM Cancellation in DWDM Optical Transmission Systems", *COIN-NGNCON 2006 - The Joint International Conference on Optical Internet and Next Generation Network*, Jeju, 2006, pp. 422-424. doi: 10.1109/COINNGNCON.2006.4454666
- [33] L. Guesmi, A. Hraghi, M. Menif, "Polarization mode dispersion monitoring in the presence of XPM effect for high speed WDM communication systems", *18th International Conference on Transparent Optical Networks (ICTON)*, Trento, 2016, pp. 1-4, doi: 10.1109/ICTON.2016.7550486
- [34] V. P. Anamika, "SPM and XPM induced crosstalk for DPSK signals in WDM-pumped Distributed Raman amplifier", *1st International Conference on Recent Advances in Information Technology (RAIT)*, Dhanbad, 2012, pp. 857-860, doi: 10.1109/RAIT.2012.6194537.
- [35] A. Udalcovs, V. Bobrovs, J. Porins, "Evaluation of SPM-induced optical signal distortions in ultra-dense mixed-WDM system", *The First International Conference on Future Generation Communication Technologies*, 2012, pp. 180-184, doi: 10.1109/FGCT.2012.6476590
- [36] T. Ivaniga, E. Ovsenik, J. Turán, "Influence of Self-Phase Modulation on 8 and 16-Channel DWDM System with NRZ and Miller Coding ", *Carpathian Journal of Electronic and Computer Engineering*, ISSN: 1844-9689, vol.8, no.1, 2015, pp.17-22.
- [37] H. Nain, U. Jadon, V. Mishra, "Performance investigation of Kerr effects on to WDM fiber optical networks", *IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)*, 2016, pp. 2018-2022, doi: 10.1109/RTEICT.2016.7808193.
- [38] T. Ivaniga, J. Turan, L. Ovsenik, "Verification of the SPM Impact in DWDM System Using AWG Multiplexer / Demultiplexer", *Acta Electrotechnica et Infotmatica*, vol. 17, no. 1, 2017, pp.17-22, doi :10.15546/aei-2017-0003
- [39] K. Miziya, S. K. Sudheer, A. C. Kuriakose, "Characterization of an optical communication system utilizing dispersion compensating fiber and nonlinear optical effects," *Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT)*, 2013, pp. 1-6, doi: 10.1109/ICCCNT.2013.6726479.
- [40] T. Ivaniga, L. Ovsenik, J. Turán, "Investigation of SPM in WDM system with EDFA", *Carpathian Journal of Electronic and Computer Engineering*, vol. 9, no. 2, 2016, pp. 07-12.

Automatické spracovanie akustických dát pre systémy automatického rozpoznania reči

Tomáš Koctúr

*Dept. of Electronics and Multimedia Communications
FEI TU of Košice
Košice, Slovak Republic
tomas.koctur@tuke.sk*

Jozef Juhár

*Dept. of Electronics and Multimedia Communications
FEI TU of Košice
Košice, Slovak Republic
jozef.juhar@tuke.sk*

Abstract—Tento článok sa zaoberá modernými metódami pre automatickú tvorbu akustických korpusov pre systémy automatického rozpoznania reči. Súčasťou tejto publikácie je komplexný prehľad problematiky automatického spracovania akustických dát pre systémy automatického rozpoznania reči ako sú čiastočne-dohľadové a bez-dohľadové systémy na tvorbu akustických korpusov, ktoré využívajú rozpoznávač reči na nepresný prepis rečových nahrávok. Túto prácu je možné rozdeliť do častí, ktoré vznikli na základe implementácie navrhnutých metód a ich experimentálneho overovania. Jedna z nich sa zaoberá návrhom a implementáciou bez-dohľadového systému s dvomi nezávislými systémami rozpoznania reči, kde je experimentálne dokázaná nezávislosť systémov. Tento systém je doplnený o filtráciu na báze miery dôveryhodnosti a dĺžky výstupných slovných hypotéz. Ďalšia časť pojednáva o využití neuronových sietí na klasifikáciu chybných slov vo forme N-gramov, ktoré majú pevnú dĺžku. V experimentoch boli skúmané rôzne nastavenia systému, ako sú nastavenia neuronovej siete alebo rôzne druhy príznakových vektorov.

Index Terms—Automatické rozpoznanie reči, akustické modely, čiastočne-dohľadové tréningovanie, bez-dohľadové tréningovanie, neuronové siete, klasifikácia

Abstract—This paper focus on novel methods for automatic speech corpora building for automatic speech recognition systems. This paper contains the complex overview of state-of-the-art solutions for automatic speech data processing for automatic speech recognition systems such as lightly-supervised and unsupervised speech corpora generation, which uses speech recognisers for inaccurate speech transcription. The main part of this thesis may be divided into sections which are supported by implementation and experimental testing of proposed unsupervised speech corpus generation system. The first one deal with proposal and implementation of the unsupervised system with two speech recognizer at its core, where complementarity of each recognizer was examined. This system was amended with filtration based on confidence measure score and minimum output hypothesis length constraint. The last section uses the neural network for correct word hypothesis classification. The main difference is that words are classified as N-grams with a fixed length. In this section, different systems settings and feature vectors were examined and evaluated.

Index Terms—Automatic speech recognition, acoustic models, lightly supervised, unsupervised, neural networks, classification

I. ÚVOD

V súčasnosti sa prikladá veľký dôraz na zlepšovanie kvality a zvyšovanie robustnosti automatického rozpoznania reči. Tento článok sa zaoberá modernými metódami automatického

spracovania akustických dát, ktoré sa využívajú najmä v oblasti automatického rozpoznania reči. Pre tréningovanie akustických modelov rozpoznávač reči sú potrebné tzv. akustické, resp. rečové korpusy, ktoré obsahujú zvukový záznam reči a presný textový prepis. Takéto prepísané akustické dáta sú veľmi cenným materiálom, pričom na natréningovanie kvalitného akustického modelu sú potrebné stovky až tisícky hodín. V praxi sa ukázalo, že kvalitný prepis nahrávky môže skúsenému anotátorovi trvať 5-20 minút pracovného času, preto tvorba akustických korpusov je finančne aj časovo náročná. Treba aj poukázať na fakt, že aj človek spraví chybu preto korpusy nie sú stopercentne presné, ale blížia sa k tomuto číslu [1].

Neskôr sa na tvorbu, resp. rozšírenie rečových korpusov začali využívať funkčné systémy ARR, ktorých slovná chybivosť sa pohybovala na úrovni niekoľkých desiatok percent. Čiastočne-dohľadové (z. angl. Lightly-supervised) systémy na tvorbu akustických korpusov, resp. modelov využívali texty, ktoré obsahujú aj zvukový záznam ako sú napríklad audioknihy, prepisy prednášok, prejavov alebo televízne titulky. Čiastočne-dohľadový systém za pomoci jazykového modelu interpolovaného s malým modelom natréningovaným z textu nahrávky rozpoznáva nahrávku. Prienik textu nahrávky a rozpoznávaného textu rozpoznávačom reči tvoria akustický korpus. Ostatné dáta nie sú použité v korpuse. Tieto metodiky si vyžadujú aj manuálnu prácu človeka, hlavne v oblasti predspracovania textov úpravy formátu, taktiež množstvo dát s prepismi je obmedzené [2], [3], [4], [5].

Na druhú stranu bez-dohľadové (z. angl. Unsupervised) systémy na tvorbu rečových korpusov nevyžadujú takého ľudské úsilie. Ich cieľom je využívať akékoľvek rečové nahrávky bez textových prepisov. Využívajú rozpoznávač reči na nahrávky pričom sa snažia vyradiť všetky časti nahrávky, ktoré sú veľmi pravdepodobne nesprávne rozpoznané. Na dosiahnutie tohto cieľu sú využívané rôzne miery filtrácie výstupných hypotéz. Bez-dohľadové systémy sú založené buď na inkrementálnych metódach, ktoré tie isté nahrávky opakovane rozpoznávajú a vylepšujú svoj akustický model alebo na metódach, ktoré vyhadzujú veľké množstvá dát a už sa k nahrávkam nevracajú a používajú nové. Na odstránenie neistoty v rozpoznávaných hypotézach sa osvedčila filtrácia na báze miery dôveryhodnosti [6], [7], [8].

V tomto článku bola pozornosť venovaná hlavne bez-

dohľadovým systémom na tvorbu akustických korpusov založených na koncepte dvoch nezávislých systémov rozpoznania reči, kde bola experimentálne skúmaná nezávislosť týchto systémov a navrhnutá nová metóda dosiahnutia nezávislosti. V navrhnutom a implementovanom systéme bol navrhnutý vlastný algoritmus zarovňavania hypotéz na vyradenie veľkej časti hypotéz, ktoré nekorelovali medzi sebou. V oblasti filtrácie slov, ktoré nie sú pravdepodobne správne rozpoznané bola skúmaná možnosť použitia minimálnej miery dôveryhodnosti. Systém bol doplnený aj o optimalizáciu kvalitatívnych parametrov akustického korpusu v oblasti dĺžky slovných hypotéz [9], [10], [11], [12].

V experimentálnej časti bolo skúmané využitie umelých neurónových sietí v procese filtrácie slov v hypotézach, ktoré sú pravdepodobne nesprávne rozpoznané. [13], [14], [15], [16].

II. NÁVRH A IMPLEMENTÁCIA SYSTÉMU NA TVORBU BEZ-DOHĽADOVÉHO REČOVÉHO KORPUSU

Základom systému na tvorbu bez-dohľadových rečových korpusov je koncept popísaný v [17]. Tento systém je zložený zo štyroch základných blokov ako je to znázornené na Obr. 1. Vstupné nahrávky bez dostupného prepisu sú segmentované na menšie úseky reči a následne rozpoznané dvomi nezávislými systémami ARR. Je podstatné aby oba rozpoznávače boli nezávislé, čo podľa autorov konceptu má viesť k minimalizácii toho, že oba systémy ARR spravia rovnakú chybu. Nezávislosť rozpoznávačov sa dá dosiahnuť použitím akustických modelov natrénovaných z odlišných rečových korpusov. Výstupné hypotézy rozpoznávačov sú navzájom zarovnané a ich prienik reprezentuje prepis časti nahrávky, ktorý je možné vložiť do rečového korpusu.

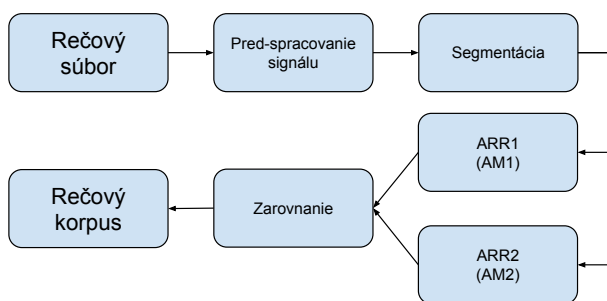


Fig. 1. Bloková schéma systému na tvorbu bez-dohľadových rečových korpusov s dvomi systémami ARR.

Tento koncept minimalizuje množstvo chýb vo výslednom korpusu a slovách, na ktorých sa oba systémy ARR nezhodli vyhadzuje. V konečnom dôsledku takýto systém môže vyhodíť množstvo rečových dát a do korpusu sa dostávajú len tie, o ktorých si je bez-dohľadový systém istý. Redukcia chyby v tomto koncepte je značná, ale množstvo chýb vo výslednom korpusu je nezanedbateľné. Tento systém je potrebné doplniť o ďalší blok filtrácie výstupných zarovnaných hypotéz. Cieľom je na základe informácií z dekodovacieho procesu ARR zistiť, či slovo je rozpoznané správne alebo nesprávne.

V systémoch na tvorbu bez-dohľadových rečových korpusov sa najčastejšie používa filtrácia na základe miery dôveryhodnosti. Doplnením o takúto filtráciu je možné minimalizovať množstvo chýb vo výslednom korpusu. Zvyšovaním nastavenia minimálnej miery dôveryhodnosti sa na jednej strane znižuje chyba, ale na druhej strane sa zvyšuje množstvo vyradených dát.

A. Základné bloky navrhnutého systému

Systém bol implementovaný ako zreťazenie viacerých blokov zo schémy zobrazenej na Obr. 2. Na zreťazenie viacerých blokov pozostávajúcich z programov a nástrojov bol použitý skriptovací jazyk Bash v prostredí OS Debian. Rečové

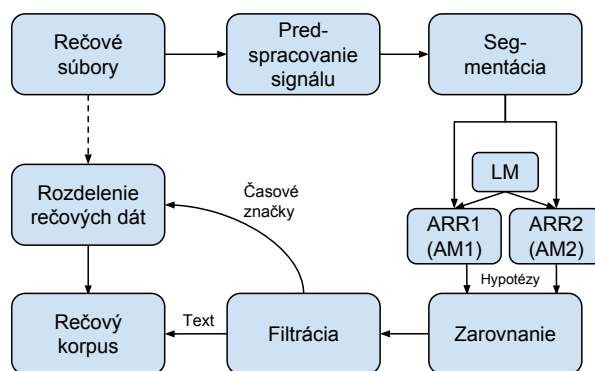


Fig. 2. Bloková schéma systému na tvorbu bez-dohľadových akustických korpusov bez učiteľa s dvomi systémami ARR a filtráciou na báze miery dôveryhodnosti.

nahrávky bez textového prepisu, sú pred-spracované za účelom prípadnej zmeny audio kódeku. Rozpoznávače reči v jadre systému vyžadujú kódek PCM L16 so vzorkovacou frekvenciou 16kHz. Na zmenu kódeku je použitý nástroj FFmpeg [18] a na pod-vzorkovanie nástroj SoX [19]. Nadvzorkovanie nie je žiaduce keďže nahrávky s nižšou vzorkovacou by neboli dobre rozpoznané systémami ARR. V prípade potreby spracovania dát z nižšou vzorkovacou frekvenciou ako 16 kHz by bolo potrebné namiesto nadvzorkovania vytvoriť akustické modely natrénované z akustického korpusu s takouto vzorkovacou frekvenciou.

B. Akustické modely pre nezávislosť hypotéz dvoch systémov ARR

Podmienkou funkčnosti prezentovaného systému je nezávislosť systémov rozpoznania reči. Tú je možné dosiahnuť dvomi rozdielnymi akustickými modelmi v systémoch ARR. Tie by mali znížiť vzájomnú koreláciu chyby. Práve táto vlastnosť je základom fungovania tohto konceptu.

Na tento účel bol použitý rozpoznávač reči s veľkým slovníkom (z angl. Large Vocabulary Continuous Speech Recognizer) Julius [20]. Natrénované boli 5 stavové ľavo-pravé akustické modely s neemitujúcimi stavmi na koncoch modelov. Príznakové vektory pozostávali zo štandardných 39 MFCC koeficientov, delta a delta-delta koeficientov. Tieto trifónové, kontextovo závislé akustické modely sú založené

na 32 Gaussových zmesiach. Trénovanie bolo realizované v prostredí nástroja HTK [21].

Na zaistenie nezávislosti systémov boli natréňované dva fonémové akustické modely. Prvý bol natréňovaný z 349 hodín manuálne anotovaných rečových nahrávok súdnych pojednávanií a zasadanií Národnej rady Slovenskej republiky [22]. Druhý akustický model bol natréňovaný z rečovej databázy 330 hodín manuálne anotovaných záznamov televíznych správ a epizód relácie zameranej na súdne pojednávania. Tento korpus obsahuje značnú mieru rečovej spontánnosti [23], [24].

1) *Štruktúra rečového korpusu pre AM1*: Prvý akustický model bol natréňovaný z korpusov APD a Parlament. Korpus APD pozostáva 250 hodín nahrávok predovšetkým čítaného textu. Obsahuje 250 rečníkov s vyrovnaným objemom nahrávok mužov a žien a rozdeľuje sa na APD1 a APD2 korpus. APD1 pozostáva zo 120 hodín nahrávok čítaných rozsudkov Slovenských súdov nahrávaných v nahrávacom štúdiu. Z dôvodu ochrany osobných údajov sú citlivé údaje v korpuse odstránené a následne nahradené náhodne generovanými.

Korpus APD2 je zložený zo 130 hodín dobre foneticky obsiahnutých viet. Bol nahratý čítaním novinových článkov a textov z internetu. Narozdiel od APD1 bol nahratý v priestoroch kancelárií a konferenčných miestností.

Parlamentný korpus obsahuje 96 hodín záznamov z rokovaní Národnej rady Slovenskej republiky. V korpuse sú nahrávky spontánnej a čítanej reči 142 rečníkov, pričom pomer mužských rečníkov ku ženským je približne 9:1. Tento pomer vyplýval z vtedajšieho zloženia poslancov Národnej rady a členov vlády Slovenskej republiky [25].

2) *Štruktúra rečového korpusu pre AM2*: Akustický model AM2 bol natréňovaný z množiny dát Broadcast News a televíznej relácie Súdna sieň. Televízna relácia súdna sieň obsahuje zinscenované súdne pojednávania amatérskymi, polo-profesionálnymi a profesionálnymi hercami. Nahrávky boli anotované a celkovo obsahovali 80 hodín reči [26].

Broadcast news korpus je korpusom vytvoreným z nahrávok spravodajských relácií. Relácie v celkovom objeme 250 hodín boli manuálne anotované [26].

C. Dosiahnutie nezávislosti dvoch ARR systémov

Podmienkou fungovania navrhnutého systému s dvomi ARR systémami je ich vzájomnej nekorelácie. Koncept je postavený na úvahe, že pravdepodobnosť vykonania rovnakej chyby v hypotézach dvoch nezávislých ARR je minimálna [17]. Na overenie tejto úvahy boli vykonané experimenty. Boli natréňované trifónové akustické modely z korpusov, ktoré boli uvedené v predošlej podkapitole. Prvý akustický model bol natréňovaný z korpusov APD1, APD2 a Parlament a druhý z Broadcast news a Súdna sieň. Nezávislosť bola docieľená rozdelením trénovacích dát.

V druhom experimente bola nezávislosť docieľená zmenou základnej rečovej jednoty v akustických modeloch. Jeden akustický model používal fonémy (trifónový model) a druhý akustický model používal grafémy (trigrafémový model) ako základnú rečovú jednotku. Narozdiel od prvého experimentu boli oba modely natréňované z rovnakých rečových korpusov

(APD1, APD2, Parlament, Broadcast news, Súdna sieň). Jediný rozdiel v korpusoch bol grafémový resp. fonetický prepis textov k nahrávkam. Výsledky experimentu sú popísané v k podkapitole II-F.

D. Zarovnanie hypotéz

Ako bolo spomenuté vyššie, každá nahrávka po segmentácii je rozpoznávaná dvomi ARR systémami, ktoré produkujú dve nezávislé hypotézy. Ich prienik, by mal zaručovať odstránenie značnej miery neistoty. Ide v podstate o triviálnu úlohu nájdenia prieniku sekvencií slov v hypotézach. Na jej vyriešenie je potrebné prihliadať na to, že slová alebo množina slov v rozpoznávanom segmente sa môžu v hypotézach opakovať. Tak isto môžu byť slová v hypotéze na inom mieste, alebo môže dekodér do hypotézy vložiť aj slovo, ktoré nebolo vyslovené alebo naopak niektoré slová môžu v hypotéze chýbať.

Na vyriešenie týchto problémov bol implementovaný vlastný algoritmus zarovnania. V prvom kroku je potrebné ošetriť vložené, resp. chýbajúce slová v hypotézach. Preto je hypotéza, ktorá ma menší počet slov určená ako referenčná. Následne sa každé slovo v referenčnej hypotéze vyhľadáva v druhej hypotéze. Zvolením kratšej hypotézy ako referenčnej pri vyhľadávaní je možné detegovať vložené slová (nadbytočné) a zachovať postupnosť slov.

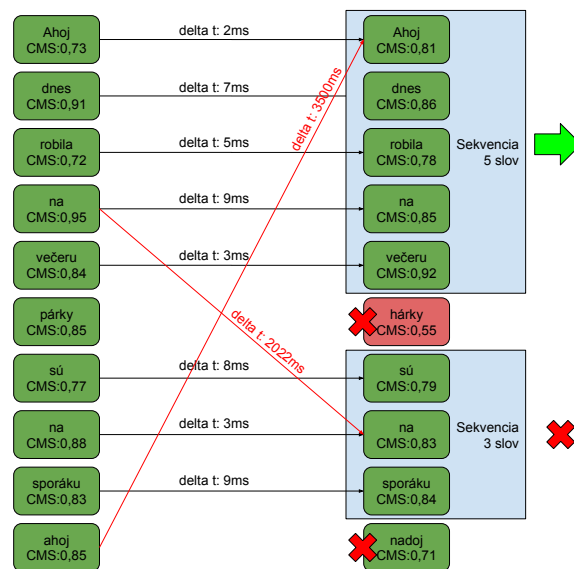


Fig. 3. Metóda filtrovania a zarovnania podľa stanovených parametrov. Červené obdĺžniky predstavujú slová, ktoré nespĺňajú podmienku minimálnej miery dôveryhodnosti (CMS). Šípky znamenajú nájdenie zhody, čierne s posunutím času v norme a červené mimo stanovenej hladiny. Červené krížiky znamenajú nespĺnenie podmienky zarovnania alebo minimálneho počtu za sebou idúcich slov.

Problematika opakujúcich slov, respektíve ich pozície v hypotéze je riešiteľná tak, že v prípade nájdenia slova alebo slov je porovnávaný aj čas ich vyslovenia v nahrávke. Tento čas počíta dekodér na svojom výstupe. Časy jednotlivých slov sa medzi hypotézami líšia, čo je prirodzený fakt, keď že časy sú vyrátané z použitia akustického modelu v sieti

dekodéra. Nakoľko akustické modely v jednotlivých ARR nie sú rovnaké to spôsobuje odchýlku časov. V experimentoch boli pozorované odchýlky rádovo do 15 milisekúnd, čo reprezentuje dostatočne malú hodnotu na spoľahlivé zarovnanie slov dvoch hypotéz v prezentovanom algoritme. V prípade, že pri vyhľadávaní slova bolo nájdených viacej slov, tak je vybrané len to slovo, ktoré spadá do časových hraníc odchýlky +/- 20ms. V prípade, že je nájdené slovo, ktoré však nespadá do časových hraníc, tak je považované za nenájdené.

Výstupom zarovnania sú slová alebo sekvencie za sebou idúcich slov. Jednoslovné alebo dvojslovné sekvencie nemusia byť využiteľné pre tvorbu rečových korpusov. Je vhodné podmieniť minimálnu dĺžku výstupnej sekvencie. V nasledujúcom experimente bola táto hodnota nastavená na 4.

E. Filtrácia na báze miery dôveryhodnosti

Najčastejšie používaným spôsobom filtrácie v systémoch tvorby rečových korpusov bez učiteľa je filtrácia založená na báze minimálnej miery dôveryhodnosti (z. angl. Confidence Measure Score, CMS). Jedná sa o empiricky alebo experimentálne overené nastavenie minimálnej miery dôveryhodnosti. Slovo ktoré má vyššiu mieru je považované za správne. V praxi sa tiež používa filtrovanie na báze miery dôveryhodnosti aj na nižších jednotkách reči ako sú slová. Môžu sa filtrovať fonémy/grafémy alebo aj stavy jednotlivé stavy HMM.

Julius vypočítava CMS z posteriorných pravdepodobností pričom jeho hodnoty sú na intervale 0 až 1, kde 1 je vysoko pravdepodobné, že slovo je rozpoznané správne [27]. V navrhnutom systéme boli nastavované rôzne minimálne úrovne CMS. Pomocou zarovnania dvoch hypotéz a filtrovania pomocou CMS vznikajú na výstupe sekvencie, ktoré v prípade splnenia podmienky o minimálnej dĺžke slov vstupujú priamo do korpusu.

F. Evaluácia nezávislosti dvoch ARR systémov s použitím filtrácie na báze CMS

Na otestovanie nezávislosti dvoch systémov pomocou dvoch dvojíc akustických modelov popísaných v podkapitole II-C bola použitá nová množina dát, ktorá nebola obsiahnutá v žiadnom z korpusov použitých na natrénovanie. Použité boli nahrávky Televíznych novín televízie Markíza, ktoré obsahujú reč nahrávanú v štúdiu profesionálnymi moderátormi a reč nahrávanú v exteriéroch s redaktormi a respondentmi. V štúdiu boli použité kravatové mikrofóny a v exteriéri boli použité ručné mikrofóny. V nahrávkach sa veľmi často vyskytujú ruchy v pozadí alebo sú ruchy a zvuky pridávané zámerné na doplnenie deja. Štúdiová reč je predpripravená a čítaná, pričom v exteriéroch je reč čiastočne pripravená, ale aj často spontánna miestami nespisovná.

20 hodín nahrávok bolo prepísaných profesionálnymi anotátormi za účelom získania informácie o chybovosti vo výslednom korpuse. Pri experimentoch boli postupne nastavené úrovne minimálneho CMS na 0; 0,2; 0,4; 0,5; 0,6; 0,65; 0,75. Na Obr. 4 sú znázornené výsledky chybovosti pre grafémový a fonémový model (oranžová krivka) a pre dva




Fig. 4. Závislosť slovnej chybovosti WER od nastavenia minimálnej miery CMS pre jednotlivé kombinácie modelov. Fonémová dvojica (modrá) a grafémový a fonémový model (oranžová).




Fig. 5. Závislosť účinnosti od nastavenia minimálnej miery CMS pre jednotlivé kombinácie modelov. Fonémová dvojica (modrá) a grafémový a fonémový model (oranžová).

fonémové modely (modrá krivka) pre jednotlivé nastavenia minimálnej úrovne CMS. Z výsledkov je zrejmé, že obe možnosti použitia akustickým modelov v dvoch systémoch ARR sú použiteľné na vytváranie rečových korpusov bez učiteľa. WER nadobúda hodnoty od 8,05% do 1,21% pre kombináciu grafémového a fonémového modelu. Fonémové modely natrénované z rozdielnych rečových korpusov dosiahli WER od 5,97% do 1,39%.

Zvyšovaním nastavenia minimálnej miery CMS sa zásadne znižuje WER. Pri nastavení minimálnej miery CMS na 0,4 a viac majú obe nastavenia podobné WER. Pri nižšom nastavení má grafémový a fonémový model horšie WER.

Vyššie nastavenie minimálneho CMS má za následok redukciiu dát na výstupe bloku filtrácie. Ako je na možné vidieť na Obr. 5 obe kombinácie akustických modelov majú podobné podiel rečových dát na výstupe filtrácie. Opäť nastáva rozdiel vo výsledkoch pri nastavení minimálneho CMS pod 0,4, kde grafémovo fonémová kombinácia akustických modelov má vyšší podiel rečových dát na výstupe filtračného bloku. Toto zlepšenie prináša aj pri takýchto nastaveniach minimálnej miery CMS má grafémovo fonémová kombinácia omnoho vyššie WER ako bolo poukázané na Obr. 4 [24].

G. Optimalizácia dĺžky viet v rečovom korpuse

V rámci optimalizácie kvality rečového korpuse je vhodné aby vety neboli príliš krátke. Obzvlášť ak má byť rečový korpus použitý na tréningovanie trifónových modelov. V experimente s databázou popísanou v podkapitole II-F a dvomi fonémovými modelmi v oboch systémoch ARR natrénovanými z rozdielnych rečových korpusov bol skúmaný vplyv dĺžky minimálnej dĺžky výstupnej sekvencie slov. Slová boli zarovňované a filtrované na základe toho či:

- boli zarovnané s dodržaním časových hraníc
- spĺňali minimálnu hodnotu CMS
- minimálna dĺžka za sebou idúcich slov bola 3, 4, 5 alebo 6.

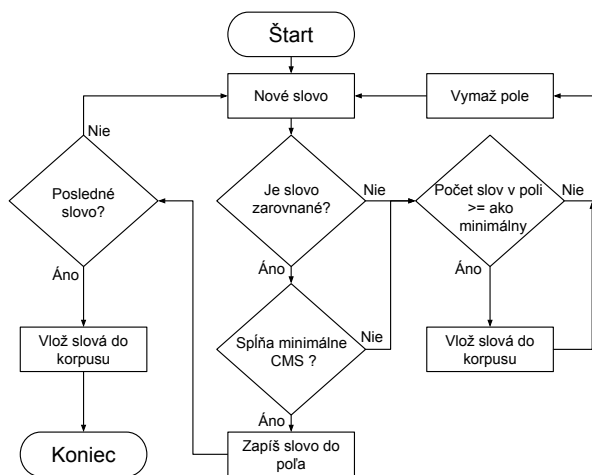


Fig. 6. Vývojový diagram filtrovania na báze minimálnej miery CMS s podmienkami minimálnej dĺžky viet výstupných zarovnaných hypotéz.

Lepšiu ilustráciu procesov zobrazuje vývojový diagram zarovnania a filtrácie. Logický sled krokov na dosiahnutie cieľa je zobrazený na Obr. 6.




Fig. 7. Vplyv minimálnej dĺžky slov na účinnosť systému, pre jednotlivé nastavenia minimálneho CMS.

Testované boli minimálne dĺžky slov nastavené na 3, 4, 5 a 6. Minimálne CMS bolo nastavené ako v experimente v podkapitole II-F.




Fig. 8. Vplyv minimálnej dĺžky slov na slovnú chybovosť WER, pre jednotlivé nastavenia minimálneho CMS.

Nastavovanie minimálnej dĺžky slovných sekvencií vo výslednom korpuse môže byť vnímané ako technické alebo kvalitatívne nastavenie rečového korpuse. Empiricky môžeme odhadovať, že zvyšovaním minimálnej dĺžky slovných sekvencií sa môže znižovať množstvo slov na výstupe systému, teda jeho účinnosť. Tento empirický odhad sa potvrdil vo výsledkoch, ktoré je možné vidieť na Obr. 7.

Neočakávaným výsledkom vyplývajúcim z tohto experimentu je to, že zvyšovaním nastavenia minimálnej sekvencie slov sa znižuje WER ako je možné vidieť na Obr. 8.

Záverom tohto experimentu je fakt, že zvyšovaním minimálnej sekvencie slov na výstupe filtrácie:

- sa mení technické vlastnosti rečového korpuse,
- znižuje sa WER,
- znižuje sa účinnosť systému.

III. FILTRÁCIA NA BÁZE KLASIFIKÁCIE N-GRAMOV POMOCOU NEURÓNŮVÝCH SIETÍ

Hypotézy na výstupe zarovnania dvomi systémami ARR majú rôznu slovnú dĺžku a preto by príznakové vektory by mali rôznu dĺžku čo je neprípustné a táto problematika bola riešená autorom v [28]. Riešením rôznych dĺžok slovných sekvencií môže byť klasifikovanie po prekrývajúcej sa častiach. Viac slovných prekrývajúce sa n-tice budú ďalej nazývané N-gramy. N-gramy boli generované po zarovnaní hypotéz dvoch fonémových systémov ARR s rozdielnymi tréningovými korpusmi na rovnako ako v predošlých experimentoch. Hypotézy boli zarovnané podobne ako v predošlých experimentoch. Podmienkou zarovnania boli blízke časové hranice slova minimálna dĺžka zarovnanej sekvencie slov bola 3. Na CMS sa neprihliadalo. Z vetných sekvencií boli vytvorené 2, 3, 4, 5 a 6-gramy tak ako je to zobrazené na Obr. 9.

Na klasifikovanie správnosti, resp. nesprávnosti N-gramu bola použitá umelá neurónová sieť. Na natrénovanie neurónovej siete bolo potrebné vytvoriť tréningovú množinu pre každý dĺžku (řád) N-gramov. Podľa teórie o klasifikácii pomocou neurónových sietí je vhodné mať k dispozícii minimálne 1000 tréningových vzoriek pre každú výstupnú triedu, pričom každá trieda musí mať rovnaký počet vzoriek




Fig. 12. Graf zobrazuje rozptyl hodnôt CMS oboch ARR vypočítaného ako priemer hodnôt CMS jednotlivých slov v 6-grame. Červené sú triedy 0 a zelené sú triedy 1.




Fig. 13. Graf zobrazuje histogram hodnôt logaritmu pravdepodobností 6-gramu vypočítaných z jazykového modelu. Modré stĺpce reprezentujú triedu 0 a červené reprezentujú triedu 1.

Na základe analýzy vstupných dát bolo vytvorených 18 príznakových vektorov (ďalej PV), z ktorých bolo vybraných najlepších 6, ktoré boli bližšie analyzované:

- PV11 pozostávajúci z:
 - priemernej hodnoty CMS z ARR1 jednotlivých slov N-gramu,
 - priemernej hodnoty CMS z ARR2 jednotlivých slov N-gramu,
 - priemernej hodnoty akustického skóre z ARR1 jednotlivých slov N-gramu,
 - priemernej hodnoty akustického skóre z ARR2 jednotlivých slov N-gramu,
 - pravdepodobnosti vypočítanej z LM pre celý N-gram.
- PV12 pozostávajúci z:

- priemernej hodnoty CMS z ARR1 jednotlivých slov N-gramu,
- priemernej hodnoty CMS z ARR2 jednotlivých slov N-gramu,
- pravdepodobnosti vypočítanej z LM pre celý N-gram.
- PV13 pozostávajúci z:
 - priemernej hodnoty CMS z ARR1 jednotlivých slov N-gramu,
 - priemernej hodnoty CMS z ARR2 jednotlivých slov N-gramu.
- PV14 pozostávajúci z:
 - vektoru hodnôt CMS oboch ARR predstavujúci priemer CMS jednotlivých slov v N-grame,
 - vektoru hodnôt CMS oboch ARR predstavujúci absolútnu hodnotu rozdielu CMS jednotlivých slov v N-grame.
- PV15 pozostávajúci z:
 - vektoru hodnôt CMS oboch ARR predstavujúci priemer CMS jednotlivých slov v N-grame zoradeného vzostupne,
 - vektoru hodnôt CMS oboch ARR predstavujúci absolútnu hodnotu rozdielu CMS jednotlivých slov v N-grame zoradeného vzostupne.
- PV17 pozostávajúci z:
 - vektoru hodnôt CMS oboch ARR predstavujúci priemer CMS jednotlivých slov v N-grame,
 - vektoru hodnôt CMS oboch ARR predstavujúci absolútnu hodnotu rozdielu CMS jednotlivých slov v N-grame,
 - pravdepodobnosti vypočítanej z LM pre celý N-gram.

Celkovo 18 navrhnutých príznakových vektorov pre 5 rôznych dĺžok N-gramov a 6 nastavení počtu skrytých neurónov v jednej skrytej vrstve. Celkovo bolo otestovaných 540 kombinácií týchto parametrov na získanie najlepšej kombinácie. Na získanie relevantného výsledku klasifikácie neurónovej siete je potrebné zopakovať tréning a evaluáciu viac krát z dôvodu náhodného generovania váh a prahov pri inicializácii neurónovej siete. Aj pri týchto experimentoch bolo každé nastavenie natrénované a otestované 100 krát a následne sa vytvoril priemer výsledkov.

B. Klasifikácia N-gramov a filtrácia výsledkov

Pri prvotných testoch bolo zistené, že presnosť klasifikácie na evaluačnej množine sa pohybuje v rozmedzí cca 67,1%-87,4%. Takáto miera reprezentuje neakceptovateľnú mieru klasifikácie rečových dát, ktoré sa majú stať rečovým korpusom. Avšak pri pohľade na grafy vstupných dát na Obr. 11, 12, 13, ktoré sú klasifikované pomocou ANN môžeme považovať toto rozmedzie za prijateľné.

Na zvýšenie presnosti klasifikácie je možné využiť aktívne hodnoty výstupnej vrstvy neurónovej siete. V nej je vypočítaná príslušnosť k triede v rozsahu 0-1 pre vstupujúci

príznačový vektor. Tieto hodnoty môžeme nazvať pravdepodobnosťou príslušnosti k triede 1. Ak výstupy nadobúdajú hodnoty v okolí hodnoty 0,5, tak to znamená že neurónová sieť nevie s istotou určiť správnu triedu a pre pridelenie k správnej triede rozhodne väčšie číslo.

Na poukázanie rozloženia hodnôt výstupov neurónovej siete jednotlivých tried, bola natrénovaná neurónová sieť s jednou skrytou vrstvou s 10000 skrytými neurónmi na skrytej vrstve ako vstupné dáta boli použité 6-gramy a príznačový vektor bol použitý PV17 definovaný vyššie. Presnosť klasifikácie na evaluačnej množine TedX so 400 rovnomerne rozloženými vzorkami dosahovala presne 71%. Na grafe na Obr. 14 je zobrazený histogram rozloženia výstupných hodnôt pre triedu 0 (modrá) a pre triedu 1 (červená). V histograme je možné vidieť prekrývanie hodnôt pre jednotlivé triedy najmä v oblasti okolo 0,5. Najmenšie prekrývanie je v oblastiach okolo hodnôt 0 a 1.




Fig. 14. Histogram rozloženia výstupných hodnôt neurónovej siete pre jednotlivé triedy. Modrá reprezentuje príslušnosť k triede 0 a červená príslušnosť k triede 1.

Zvýšenie presnosti klasifikácie je možné docieľiť vyradením výstupných dát, ktoré sú v okolí hodnôt 0,5. Tým pádom bude redukované množstvo dát na výstupe, čiže sa znižuje účinnosť systému. V úlohe tvorby rečových korpusov bez učiteľa sa ráta s redukciami dát o ktorých systém nevie s vysokou pravdepodobnosťou, že sú správne. Aj v predošlých experimentoch boli redukované aj o viac ako 99%.

V nasledujúcich experimentoch boli výstupné dáta filtrované pomocou 5 nastavení dolnej a hornej hranice výstupných hodnôt a to nasledovne:

- žiadne hranice.
- dolná 0,4 a horná 0,6 (Filter 1 - F1),
- dolná 0,3 a horná 0,7 (Filter 2 - F2),
- dolná 0,2 a horná 0,8 (Filter 3 - F3),
- dolná 0,1 a horná 0,9 (Filter 4 - F4).;

Bloková schéma navrhnutého a implementovaného systému je zobrazená na Obr. 15.

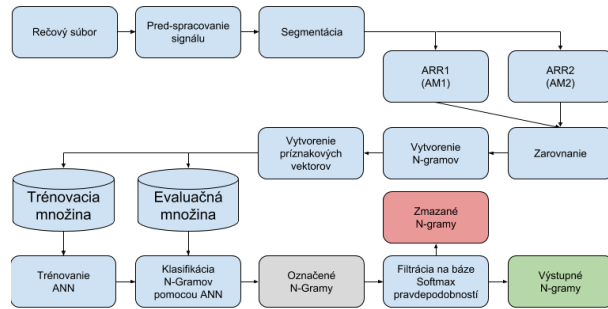


Fig. 15. Bloková schéma navrhnutého systému na báze ANN s filtráciou výstupných dát.

C. Objektívne miery

Na vyhodnocovanie kvality klasifikátorov sa najčastejšie využíva miera správnej klasifikácie v percentách, ktorá je vyrátaná ako:

$$\eta = \frac{Y_{1,1} + Y_{0,0}}{N} * 100 \quad (1)$$

, kde $Y_{i,j}$ reprezentuje vzorku patriacu k i -tej triede klasifikovanú ako do triedy j a N je počet všetkých vzoriek. Taktiež sa používa aj opačná hodnota pre mieru nesprávnej klasifikácie (z angl. Misclassification).

Pre účely bezdohľadového systému na tvorbu akustických korpusov nie je podstatný údaj ako dobre vie klasifikovať všetky triedy, keďže výsledkom systému majú byť iba N-gramy v triede 1, čiže správne N-gramy. To ako vie klasifikátor klasifikovať triedu 0 je nepodstatné. Preto je vhodnejšie ako presnosť klasifikácie použiť mieru presnosti klasifikácie pre triedu 1 (z angl. True Positive Rate, skr. TPR). Zvykne sa označovať aj ako miera správnej detekcie udalostí. Výpočet TPR v percentách pre klasifikátor s dvomi triedami je nasledovný:

$$TRP = \frac{Y_{1,1}}{Y_{1,1} + Y_{1,0}} * 100 \quad (2)$$

, kde $Y_{i,j}$ reprezentuje vzorku patriacu k i -tej triede klasifikovanú ako do triedy j a N je počet všetkých vzoriek.

Podstatným faktorom systému na tvorbu rečových korpusov bez učiteľa je aj údaj o tom koľko vstupných rečových dát je označených ako správne N-gramy, čiže podiel koľko dát vstupuje do výsledného korpusu k vstupným dátam bez prepisu. Tento podiel je možné nazvať ako účinnosť systému a vypočítava sa podľa vzorca:

$$\eta = \frac{Y_{1,1} + Y_{1,0}}{N} * 100 \quad (3)$$

, kde $Y_{i,j}$ reprezentuje vzorku patriacu k i -tej triede klasifikovanú ako do triedy j a N je počet všetkých vzoriek. Táto miera zohľadňuje iba početnosť výskytu triedy 1 (správny N-gram), beh ohľadu na jeho správnosť.

D. Analýza experimentálnych výsledkov

V predchádzajúcej podkapitole III-B bolo napísané, že presnosť klasifikácie dosahuje 67,1%-87,4%. To platí pre všetky

príznakové vektory a všetky nastavenia okrem príznakového vektoru PV4. PV4 pozostáva iba z akustického skóre jednotlivých slov v N-grame pre ARR1 a taktiež pre ARR2. Ako je možné vidieť na Obr. 11 nie je možné určiť rozhodovaciu úroveň pre dáta v tomto príznakovom vektore. Výsledky klasifikácie sú na úrovni náhodného generátora pre dve triedy čiže okolo 50%. Výsledky tohto príznakového vektora sú zobrazené na Obr. 16. Dĺžka N-gramu ani nastavenie počtu skrytých neurónov na skrytej vrstve skoro vôbec nezlepšuje presnosť klasifikácie. Ani pri použití filtra výstupných dát nie sú dosiahnuté uspokojivé výsledky.

Navyše bolo zistené, že pri použití príznakových vektorov, kde popri CMS alebo pravdepodobnosti jazykového modelu bolo použité akustické skóre, sú dosiahnuté mierne horšie výsledky oproti verziám príznakových vektorov, ktoré akustické skóre nepoužívajú. Experimentálne bolo zistené, že použitie akustického skóre v príznakových vektoroch zhoršuje výsledky a nie je vhodné ho používať.




Fig. 16. Výsledky presnosti klasifikácie pri použití príznakového vektora PV4 pre rôzne nastavenia skrytých neurónov a dĺžky N-gramov.

Prvým sledovaným parametrom v experimentoch bola miera správnej detekcie, TRP a účinnosť systému v závislosti od nastavenia počtu skrytých neurónov na jednej skrytej vrstve, pre jednotlivé dĺžky N-gramov bez filtrovania výsledkov. Ako je možné vidieť na Obr. 17 zvyšovaním počtu skrytých neurónov sa znižuje TPR pre všetky N-gramy, čo je negatívny fakt. Z výsledkov vyplýva, že je vhodnejšie nastaviť počet skrytých neurónov na 50 pre dosiahnutie vyššej presnosti klasifikácie triedy 1. Na druhej strane z výsledkov zobrazených na grafe na Obr. 18 je možné vidieť opačný trend. Zvyšovaním počtu skrytých neurónov sa zvyšuje účinnosť systému, čo je naopak pozitívny fakt. Pre konkrétnu aplikáciu je vhodné nastaviť počet skrytých neurónov tak aby bol systém optimalizovaný pre konkrétny požadovaný kvalitatívny parameter. V prípade, že TPR je dostatočne vysoká a je žiadané zvýšiť množstvo výstupných dát je vhodné počet skrytých neurónov zvýšiť. V prípade, že je miera klasifikácie triedy 1 nižšia tak je vhodné znížiť počet skrytých neurónov na skrytej vrstve.

Druhým podstatným parametrom je vplyv dĺžky N-gramu na TPR a účinnosť systému. Výsledky boli porovnávané s




Fig. 17. Graf závislosti TPR od počtu skrytých neurónov pre jednotlivé dĺžky N-gramu bez použitia filtra výstupných hodnôt.

50 skrytými neurónmi v skrytej vrstve. Z grafu na Obr. 19 je možné vidieť, že väčšie N-gramy, 5-gram a 6-gram majú vyššiu mieru správnej detekcie TPR. Taktiež 5-gramy a 6-gramy majú lepšiu účinnosť ako menšie N-gramy ako je možné vidieť na Obr. 20. Horšiu účinnosť dosiahol len PV13, ktorý pozostával len z dvoch priemerných hodnôt CMS, kde 2-gram dosiahol najvyššiu účinnosť.




Fig. 18. Graf závislosti účinnosti od počtu skrytých neurónov pre jednotlivé dĺžky N-gramu bez použitia filtra výstupných hodnôt.

Výsledné hodnoty TPR pre jednotlivé príznakové vektory a rôzne nastavenia systému, nie sú postačujúce na automatickú tvorbu rečových korpusov. Ako bolo spomenuté vyššie, navrhnutý systém filtruje výstupné dáta klasifikované neurónovou sieťou. Pri evaluácii neurónovej siete boli výstupné hodnoty ANN filtrované štyrmi rôznymi nastaveniami filtrov v každom opakovaní experimentu. Najprv bola vyrátaná TPR a účinnosť pre výsledky bez filtra a potom postupne pre všetky 4 nastavenia dolnej a hornej hranice.

Z histogramu na Obr. 14 výstupných hodnôt je zrejmé, že filtrovanie značne ovplyvní účinnosť systému negatívnym smerom. Pri analýze prekrývania výstupných hodnôt jednotlivých tried je zrejmé, že sa filtráciou odstráni veľká časť




Fig. 19. Graf závislosti TPR od dĺžky N-gramu pre jednotlivé sledované príznakové vektory.




Fig. 21. Graf závislosti TPR od dĺžky N-gramu pre jednotlivé nastavenia filtrov výstupných hodnôt ANN.




Fig. 20. Graf závislosti účinnosti od dĺžky N-gramu pre jednotlivé sledované príznakové vektory.




Fig. 22. Graf závislosti účinnosti od dĺžky N-gramu pre jednotlivé nastavenia filtrov výstupných hodnôt ANN.

chyb. V pri porovnaní prekrývania jednotlivých tried je možné vidieť, že nastáva väčšie prekrývanie v oblasti do 0,5, čiže prekrývanie triedy 0, čo je pozitívny fakt lebo táto časť pravdepodobností nie je pre fungovanie systému potrebná. Inými slovami presnosť klasifikácie pre triedu 1 je lepšia ako pre triedu 0.

Nastavením filtra tak, že vynecháva väčšiu časť výsledkov je dosiahnutá lepšia TPR ako je to zobrazené na Obr. 21. Väčšie N-gramy majú lepšiu TPR pričom nastavenie filtra 4 pri 6-grame a príznakovom vektore PV13 dosahuje 100% správnosť klasifikácie triedy 1. Aj 5-gram dosiahol veľmi vysokú presnosť až 99,3% s použitím 50 skrytých neurónov. Pri použití filtra 4 na 6-gramy s použitím 50 skrytých neurónov dosiahol 5 zo 6 sledovaných príznakových vektorov bezchybné TPR jedine PV15 dosiahol 99,4%.

Použitie filtra výsledkov klasifikácie má za následok značnú redukciu dát ako je to zobrazené v grafe na Obr. 22. Stop-percentné TPR pre PV12, má za následok zníženie účinnosti na 0,32%. Mierne absolútne zvýšenie účinnosti je možné dosiahnuť zvýšením počtu skrytých neurónov na 10000, čím je dosiahnutá účinnosť 0,37%.

Najlepšie výsledky tohto experimentu dosahuje príznakový vektor PV12 pozostávajúci z priemernej hodnoty CMS jednotlivých slov v N-grame pre ARR1 a priemer pre ARR2 spolu s hodnotou pravdepodobnosti vypočítanej z jazykového modelu. Najlepšie nastavenie systému bolo pre PV12 pre 6-gramy s 10000 skrytými neurónmi v skrytej vrstve. Toto nastavenie dosiahlo TPR 100% a účinnosť 0,37%.

IV. ZÁVER

Táto práca sa zaoberá návrhmi a implementáciami metód riešenia problematiky automatického spracovania rečových dát pre systémy rozpoznávania reči. Práca je založená na metodike riešenia problematiky tvorby akustických korpusov pomocou dvoch nezávislých systémov automatického rozpoznania reči, kde bol navrhnutý vlastný algoritmu zarovnávanie slovných hypotéz.

V prvej časti bol experimentálne overený koncept dosiahnutia nezávislosti dvoch rečových dekodérov na základe rozdielných základných jednotiek reči pomocou grafém a foném. Ako filtrácia v tejto časti práce bola použitá filtrácia na báze miery dôveryhodnosti slov, kde boli experimentálne

overená funkčnosť tejto metódy. Táto metóda bola porovnaná s navrhnutou metódou premenlivej minimálnej miery dôveryhodnosti, pričom tieto metódy boli navzájom porovnané a bolo zistené, že premenlivá miera zlepšuje účinnosť systému. V tejto časti práce bola vyšetrená možnosť obmedzenia systému o minimálnu dĺžku výstupných slovných hypotéz v korpuse, ktorá ovplyvňuje kvalitatívne vlastnosti korpusu, pričom bolo zistené, že priamo znižuje slovnú chybovosť v korpuse.

V druhej časti bola vyvinutá nová metodika filtrácie s využitím klasifikátor na báze neurónových sietí. Narozdiel od predošlej časti boli hypotézy rozdelené na prekrývajúce sa časti, N-gramy o rôznych dĺžkach, ktoré je možné jednoduchšie klasifikovať. V táto metodika bola doplnená o filtráciu výsledkov klasifikácie N-gramov, ktorá redukoval dáta s ktorými mala neurónov sieť problém a boli pravdepodobne nesprávne klasifikované čo spôsobilo veľmi presnú klasifikáciu správnych N-gramov.

Výsledkom vyššie uvedených experimentov je súbor odporúčaní pre tvorbu systémov na automatické spracovanie rečových dát s cieľom tvorby špecifických akustických korpusov bez ľudského zásahu. S využitím takýchto dát je možné zlepšovať kvalitu a robustnosť systémov automatického rozpoznania reči.

ACKNOWLEDGMENT

Táto práca vznikla vďaka podpore Agentúry na podporu výskumu a vývoja realizáciou výskumných projektov APVV-15-0517 a APVV SK-TW-2017-0005 a vďaka podpore MŠVVaŠ SR realizáciou projektu VEGA 1/0511/17.

REFERENCES

- [1] M. Rusko, J. Juhár, M. Trnka, J. Staš, S. Darjaa, D. Hládek, R. Sabo, M. Pleva, M. Ritomský, and M. Lojka, "Slovak automatic dictation system for judicial domain," in *Human Language Technology Challenges for Computer Science and Linguistics*, pp. 16–27, Springer, 2014.
- [2] L. Lamel, J.-L. Gauvain, and G. Adda, "Lightly supervised acoustic model training," in *ASR2000-Automatic Speech Recognition: Challenges for the new Millennium ISCA Tutorial and Research Workshop (ITRW)*, 2000.
- [3] L. Lamel, J.-L. Gauvain, and G. Adda, "Lightly supervised and unsupervised acoustic model training," *Computer Speech & Language*, vol. 16, no. 1, pp. 115–129, 2002.
- [4] N. Braunschweiler, M. J. Gales, and S. Buchholz, "Lightly supervised recognition for automatic alignment of large coherent speech recordings," in *INTERSPEECH*, pp. 2222–2225, 2010.
- [5] P. Mihajlik and A. Balog, "Lightly supervised acoustic model training for imprecisely and asynchronously transcribed speech," in *Speech Technology and Human-Computer Dialogue (SpeD), 2013 7th Conference on*, pp. 1–5, IEEE, 2013.
- [6] J. Löff, C. Gollan, and H. Ney, "Cross-language bootstrapping for unsupervised acoustic model training: rapid development of a polish speech recognition system," in *Interspeech*, pp. 88–91, 2009.
- [7] N. T. Vu, F. Kraus, and T. Schultz, "Rapid building of an asr system for under-resourced languages based on multilingual unsupervised training," in *Interspeech*, pp. 3145–3148, Citeseer, 2011.
- [8] J. Ma and S. Matsoukas, "Unsupervised training on a large amount of arabic broadcast news data," in *Acoustics, Speech and Signal Processing, 2007. ICASSP 2007. IEEE International Conference on*, vol. 2, pp. II–349, IEEE, 2007.
- [9] S. Novotney, R. Schwartz, and J. Ma, "Unsupervised acoustic and language model training with small amounts of labelled data," in *Acoustics, Speech and Signal Processing, 2009. ICASSP 2009. IEEE International Conference on*, pp. 4297–4300, IEEE, 2009.
- [10] F. Wessel and H. Ney, "Unsupervised training of acoustic models for large vocabulary continuous speech recognition," *Speech and Audio Processing, IEEE Transactions on*, vol. 13, no. 1, pp. 23–31, 2005.
- [11] C. Gollan, S. Hahn, R. Schlüter, and H. Ney, "An improved method for unsupervised training of lvcsr systems," in *INTERSPEECH*, pp. 2101–2104, 2007.
- [12] T. Fraga-Silva, J.-L. Gauvain, and L. Lamel, "Lattice-based unsupervised acoustic model training," in *Acoustics, Speech and Signal Processing (ICASSP), 2011 IEEE International Conference on*, pp. 4656–4659, IEEE, 2011.
- [13] X. Huang, A. Acero, H.-W. Hon, and R. Foreword By-Reddy, *Spoken language processing: A guide to theory, algorithm, and system development*. Prentice Hall PTR, 2001.
- [14] J. J. a kol., *Rečové technológie v telekomunikáciách a informačných systémoch*. Equilibria, Košice, 2011.
- [15] M. Papco, *Robustné metódy automatického rozpoznávania plynulej reči*. PhD thesis, dissertation thesis, Technical University of Košice (Robust Methods of Continuous Speech Recognition), 2010. 118 p.[In Slovak], 2010.
- [16] L. R. Rabiner, "A tutorial on hidden markov models and selected applications in speech recognition," *Proceedings of the IEEE*, vol. 77, no. 2, pp. 257–286, 1989.
- [17] H. Cucu, A. Buzo, and C. Burileanu, "Unsupervised acoustic model training using multiple seed asr systems," in *Proc. Int. Workshop on Spoken Language Technologies for Under-resourced Languages (SLTU), St. Petersburg, Russia*, pp. 124–130, 2014.
- [18] FFmpeg Developers, "ffmpeg tool (version 7:3.2.10-1)," 2018.
- [19] Chris Bagwell, "Sox sound exchange (version v14.4.0)," 2018.
- [20] A. Lee and T. Kawahara, "Julius - large vocabulary csr engine (version 4.3.1)," 2018.
- [21] S. Young, G. Evermann, M. Gales, T. Hain, D. Kershaw, X. Liu, G. Moore, J. Odell, D. Ollason, D. Povey, et al., "The htk book," *Cambridge university engineering department*, vol. 3, p. 175, 2002.
- [22] M. Rusko, J. Juhár, M. Trnka, J. Staš, S. Darjaa, D. Hládek, R. Sabo, M. Pleva, M. Ritomský, and S. Ondáš, "Advances in the slovak judicial domain dictation system," in *Language and Technology Conference*, pp. 55–67, Springer, 2013.
- [23] T. Kočtúr, J. Staš, and J. Juhár, "Unsupervised acoustic corpora building based on variable confidence measure thresholding," in *ELMAR, 2016 International Symposium*, pp. 31–34, IEEE, 2016.
- [24] T. Kočtúr, P. Vizslay, J. Staš, M. Lojka, and J. Juhár, "Unsupervised speech transcription and alignment based on two complementary asr systems," in *Radioelektronika (RADIOELEKTRONIKA), 2016 26th International Conference*, pp. 358–362, IEEE, 2016.
- [25] M. Rusko, J. Juhár, M. Trnka, J. Staš, S. Darjaa, D. Hládek, R. Sabo, M. Pleva, M. Ritomský, and M. Lojka, "Slovak automatic dictation system for judicial domain," in *Language and Technology Conference*, pp. 16–27, Springer, 2011.
- [26] P. Vizslay, J. Stas, T. Kočtúr, M. Lojka, and J. Juhár, "An extension of the slovak broadcast news corpus based on semi-automatic annotation," in *LREC*, 2016.
- [27] A. Lee, K. Shikano, and T. Kawahara, "Real-time word confidence scoring using local posterior probabilities on tree trellis search," in *Acoustics, Speech, and Signal Processing, 2004. Proceedings.(ICASSP'04). IEEE International Conference on*, vol. 1, pp. I–793, IEEE, 2004.
- [28] T. Kočtúr, "Neural network error classification in dual asr unsupervised acoustic corpora building," in *Proceedings from Conference - 17th Scientific Conference of Young Researchers*, pp. 172–173, 2017.
- [29] W. F. Schmidt, M. A. Kraaijveld, and R. P. Duin, "Feedforward neural networks with random weights," in *Pattern Recognition, 1992. Vol. II. Conference B: Pattern Recognition Methodology and Systems, Proceedings., 11th IAPR International Conference on*, pp. 1–4, IEEE, 1992.
- [30] J. Staš, D. Hládek, P. Vizslay, and T. Kočtúr, "Tedxsk and jumpsk: A new slovak speech recognition dedicated corpus," *Journal of Linguistics/Jazykovedný časopis*, vol. 68, no. 2, pp. 346–354, 2017.
- [31] V. Vapnik and R. Izmailov, "Knowledge transfer in svm and neural networks," *Annals of Mathematics and Artificial Intelligence*, vol. 81, no. 1-2, pp. 3–19, 2017.
- [32] K. Sfikas, T. Theoharis, and I. Pratikakis, "Exploiting the panorama representation for convolutional neural network classification and retrieval," in *Eurographics Workshop on 3D Object Retrieval*, 2017.

Fuzzy riadenie DC-DC meniča

Ing. Martin Lešo

Katedra elektrotechniky a mechatroniky
Technická univerzita v Košiciach
Košice, Slovakia
martin.leso@tuke.sk

Doc. Ing. Jaroslava Žilková, PhD.

Katedra elektrotechniky a mechatroniky
Technická univerzita v Košiciach
Košice, Slovakia
jaroslava.zilkova@tuke.sk

Abstrakt— Článok sa zaoberá možnosťou použitia fuzzy regulátora pre reguláciu výstupného napätia nepriameho jednosmerného znižovacieho meniča s mäkkým spínaním. Hlavnou výhodou fuzzy riadenia je možnosť riadiť nelineárne systémy bez nutnosti poznať ich matematický model a schopnosť pracovať aj s nepresnými údajmi. V rámci článku sú prezentované simulačné výsledky predkladaného riešenia a ich porovnanie voči navrhutej PI regulácii, z ktorých možno usudzovať, že oba typy regulácií zabezpečujú stabilnú reguláciu výstupného napätia meniča, pričom fuzzy regulátor preukázal zlepšené dynamické vlastnosti meniča v prípade jeho náhleho zaťaženia. Nakoľko jednou z nevýhod fuzzy riadenia je jeho značná výpočtová náročnosť, v rámci článku je predkladaná metóda pre aplikovanie fuzzy regulátora vo forme vyhľadávacej tabuľky, čím je možné výrazne zredukovať potrebný výpočtový výkon fuzzy regulátora. V závere článku je tiež uvedená metóda pre zredukovanie počtu vstupov pre fuzzy regulátor, čím je možné zjednodušiť a urýchliť výpočet fuzzy regulátora.

Keywords—DC-DC menič napätia, fuzzy riadenie, fuzzy regulátor s jedným vstupom

Abstract—The paper deals with usage of a fuzzy logic controller for control of an output voltage of buck converter with soft switching. An ability to control nonlinear systems without knowing their mathematical models, and an ability to work with inaccurate data are the main advantages of fuzzy logic control. In the paper, the simulation results of the fuzzy solution and their comparison with the previous PI controller are presented. The results suggest that both types of controllers provide stable control of the output voltage of the converter. Additionally, the fuzzy controller shows improved dynamic properties of the DC-DC converter in case of its sudden load. One of the disadvantages of fuzzy control is its high computational demand, so the article also deals with an approximation of the fuzzy controller with a look up table, which can significantly reduce computational demand of the fuzzy controller. The last chapter of the article is aimed to a method to reduce the number of inputs for the fuzzy controller which simplified computing process of the fuzzy controller.

Keywords—DC-DC converter, fuzzy control, single input fuzzy controller

I. ÚVOD

DC-DC meniče sú často využívané v rôznych elektronických zariadeniach v komerčných aj priemyselných zariadeniach za účelom premeny jednosmerného napätia na inú úroveň. V posledných desaťročiach sa kladie zvýšená

pozornosť na zvýšenie účinnosti DC-DC meničov. Jednou možnosťou ako zvýšiť účinnosť DC-DC meničov je navrhnutie obvodov pre mäkké spínanie tranzistorov meničov za účelom minimalizovania ich spínacích strát, čím je umožnené zvýšiť spínanú frekvenciu tranzistorov meniča a tým zároveň aj zmenšiť váhu, objem a tým aj výrobnú cenu DC-DC meničov. Takéto meniče sú tiež nasadzované v prípadoch, ktoré požadujú vysokú stabilitu výstupného napätia pri zmenách záťaže a vstupného napájacieho napätia. To je hlavná požiadavka pri vývoji pokročilých metód riadenia pri vývoji DC-DC meničov. Na riešenie tejto problematiky bolo predkladaných mnoho rôznych riadiacich stratégií, pričom každá z nich poskytuje určité výhody a nevýhody vyplývajúce z princípu ich činnosti [1].

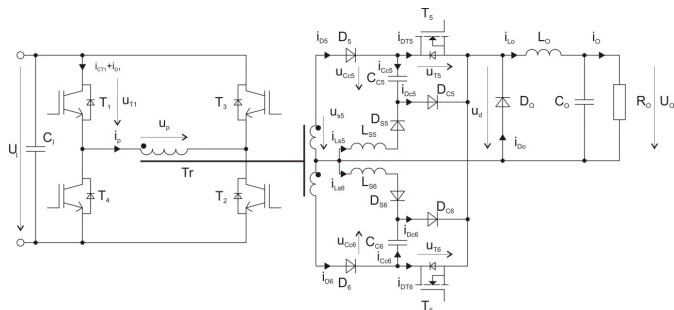
Všeobecne sa pre riadenie a reguláciu výstupného napätia meničov používajú napätové alebo prúdové metódy riadenia. K výhodám takýchto riešení je možné priradiť stálu spínanú frekvenciu meničov a nulovú regulačnú odchýlku požadovaného napätia. Naopak, k ich nevýhodám je možné zaradiť ich horšiu odozvu na skokové zmeny záťaže a vstupného napätia [2, 6]. K odstráneniu týchto nedostatkov sú vyvíjané kľzavé metódy riadenia, ktoré sú stabilnejšie pri zmenách záťaže a parametrov meniča. Ich hlavnou nevýhodou je však ich variabilná spínaná frekvencia počas zmien záťaže a vstupného napätia meniča, čo vedie k problémom pri dimenzovaní filtrov meničov. Nedostatky súčasne používaných metód riadenia vedú k vývoju pokročilejších metód riadenia ako je prediktívne riadenie, či k implementácii metód umelej inteligencie v riadení [3, 7].

Jednou z najrozšírenejších metód umelej inteligencie v riadiacich systémoch je teória fuzzy množín, ktorá je uplatnená v rôznych fuzzy systémoch. Fuzzy systémy poskytujú metodiku pre reprezentáciu, spracovanie a implementovanie znalostí pre riadenie dynamických systémov. Teória fuzzy množín je jednou z často používaných metód v oblasti umelej inteligencie pre riadenie rôznych nelineárnych systémov a bola úspešne aplikovaná aj v oblasti výkonovej elektroniky. Jednou z hlavných predností fuzzy riadenia je jeho schopnosť práce s nepresnými vstupnými údajmi, ako aj možnosť návrhu regulátora, ak nie je známy matematický model regulovaného systému. Fuzzy riadenie je vhodné predovšetkým pre aplikáciu pre nelineárne systémy a vyznačuje sa vysokou toleranciou na zmeny parametrov systému [3, 8].

Fuzzy PI regulácia FLC (Fuzzy LogicControl) je jednou s najčastejšie aplikovaných foriem fuzzy logiky v riadení. Doteraz bolo navrhnutých mnoho rôznych typov regulátorov na báze fuzzy logiky, ktoré používali rôzne spracovania vstupov a výstupov [8]. Z hľadiska použitia si doteraz našli najväčšie uplatnenie fuzzy PI regulátory, ktoré ako vstupy využívajú regulačnú odchýlku e a jej deriváciu Δe .

II. DC-DC MENIČ


Vnútroňá štruktúra navrhnutého simulačného modelu meniča je zobrazená na obr. 1. Navrhnutý menič pozostáva z mostíkového striedača, vysokofrekvenčného transformátora, riadeného usmerňovača, výstupného LC filtra a bezstratovej odľahčovacej siete. Striedač je zostavený zo štyroch IGBT tranzistorov T_1-T_4 , ktoré vytvárajú vysokofrekvenčný napätový signál, ktorý je cez transformátor prenášaný do riadeného usmerňovača. Usmerňovač je tvorený tranzistormi T_5 a T_6 s diódami D_5, D_6 , ktoré sú pripojené na výstupný LC filter tvorený indukčnosťou L_o a kapacitou C_o za účelom vyhladenia výstupného prúdu a napätia meniča. Odľahčovacia sieť je tvorená diódami $D_{S5}, D_{C5}, D_{S6}, D_{C6}$, kondenzátormi C_{C5}, C_{C6} a indukčnosťami L_{S5}, L_{S6} , ktoré minimalizujú vypínacie straty tranzistorov usmerňovača [9].



Obr. 1 Schéma zapojenia meniča

III. SIMULAČNÝ MODEL MENIČA

Pre navrhnutý menič bol v programe MATLAB Simulink zostavený simulačný model meniča s reguláciou výstupného prúdu a napätia, ktorého štruktúra je zobrazená na Obr. 2 [1].



Obr. 2 Celková simulačná schéma meniča

Simulačný model pozostáva z viacerých blokov. V ľavej časti simulačného modelu sú umiestnené regulátory prúdu a napätia, ktoré regulujú prúd, resp. napätie na základe nastavených referenčných hodnôt i_{ref} a u_{ref} a nameraných hodnôt v meniči i_{LO} a u_L , pričom i_{LO} predstavuje vyhladzovací prúd indukčnosti a u_L predstavuje napätie na výstupe LC filtra. V strednej časti modelu je zobrazený prepínač, ktorý na

základe hodnoty rozdielu výstupov prúdového a napätového regulátora prepne požadovaný výstup regulátora pre generovanie PWM, ktorá je tvorená porovnávaním referenčného signálu s výstupom regulátora. Referenčný signál je synchronizovaný so spínacími impulzmi tranzistorov striedača, pričom pre T_5 je tento signál posunutý o polovicu periódy. Vstupy do DC-DC meniča predstavujú impulzy pre spínanie tranzistorov usmerňovača. Výstup meniča je pripojený na variabilnú odporovú záťaž, čím vieme otestovať správanie sa regulátora pri zmene záťaže. Pre tvorbu subsystému "DC-DC menič" (Obr. 1) bol použitý zásuvný modul programu MATLAB Simscape s knižnicou SimPowerSystem [10].


IV. NÁVRH FUZZY REGULÁTOR NAPÄTIA

Všeobecný postup návrhu fuzzy regulátorov je možné nájsť napr. v [11], pričom na obr. 3 je znázornená nami navrhnutá štruktúra fuzzy PI regulátora výstupného napätia pre jeho simuláciu v programe Simulink, pričom ako vstupy do regulátora sú privádzané dve veličiny, regulačná odchýlka $e(1)$ a zmena regulačnej odchýlky $\Delta e(2)$.

$$e(k) = u_{ref}(k) - u_L(k) \quad (1)$$

$$\Delta e(k) = e(k) - e(k-1) \quad (2)$$

Regulačná odchýlka predstavuje rozdiel medzi požadovanou hodnotou u_{L*} a aktuálnou hodnotou napätia na výstupe meniča. Táto hodnota je spracovaná blokom podľa Obr. 3 a), ktorý obsahuje filtráciu výstupnej hodnoty filtrom prvého rádu s malou časovou konštantou a priemerovaním hodnoty posledných štyroch vzoriek. Zmena regulačnej odchýlky Δe je následne prepočítavaná ako rozdiel súčasnej a predchádzajúcej vzorky. Oba vstupy sú normalizované tak, aby boli ohraničené v intervale $\{-1, 1\}$. Výstupom FLC regulátora je normalizovaná hodnota prírastku striedy Δu . Požadovaná hodnota striedy tranzistorov usmerňovača je vypočítavaná ako suma prírastkov požadovanej striedy vypočítanej FLC regulátorom, pričom maximálna veľkosť striedy je nastavená na 0,85.




Obr. 3 Štruktúra FLC regulátora

Navrhnutý fuzzy regulátor používa fuzzy systém Mamdaniho typu pre inferenciu pravidiel s max-min kompozičnými pravidlami inferencie.

Rozmiestnenie vstupných fuzzy množín v rámci univerza je zobrazené na Obr. 4 a Obr. 5., pričom bol zvolený ich trojuholníkový, resp. lichobežníkový tvar z dôvodu rýchlosti výpočtu. Tento typ rozmiestnenia fuzzy množín bol zvolený preto, že sa jedná o štandardne aplikovanú techniku počiatočného rozmiestnenia množín, ktorá sa osvedčila pri riadení rôznych systémov [8].


Označenie jednotlivých fuzzy množín vychádza zo štandardnej anglickej terminológie, pričom NL

(NegativeLarge) označuje veľkú zápornú regulačnú odchýlku, *NS* (NegativeSmall) označuje malú zápornú regulačnú odchýlku, *Z* (Zero) označuje nulovú regulačnú odchýlku, *PS* (PositiveSmall) označuje malú kladnú regulačnú odchýlku a *PL* (PositiveLarge) označuje veľkú kladnú regulačnú odchýlku.




Obr. 4 Rozmiestnenie fuzzy množín pre e

Počas ladenia FLC regulátora bol upravený tvar funkcie príslušnosti *Z* (Obr. 5) pre vstup Δe na lichobežníkový tvar s cieľom zníženia citlivosti regulátora na drobné oscilácie a šum meraného výstupného napätia meniča.



Obr. 5 Rozmiestnenie fuzzy množín pre Δe

Na Obr. 6 je znázornené rozloženie funkcií príslušnosti pre výstup fuzzy regulátora napätia. Označovanie množín je obdobné ako pri vstupných množinách.



Obr. 6 Rozmiestnenie fuzzy množín pre Δu


Riadenie meniča prebieha na základe súboru pravidiel, ktoré je možné odvodiť na základe pozorovania riadených veličín na meniči alebo ich môže formulovať osoba, ktorá pozná dynamické vlastnosti danej sústavy. Pravidlá pre riadenie meniča boli navrhnuté na základe všeobecnej znalosti regulovanej sústavy, pričom bol definovaný súbor 25 pravidiel, ktoré predstavujú všetky možné kombinácie vstupných fuzzy množín za použitia logického súčinu, ktoré sú zapísané v pravdivostnej tabuľke (Tab. 1), pričom pravidlá v

pravdivostnej tabuľke sú volené tak, aby výstup fuzzy systému bol rovnaký pre kladné aj záporné hodnoty fuzzy množín.

Tab. 1 Pravidlá pre zostavenie fuzzy regulátora

$\Delta e \backslash e$	<i>Nm</i>	<i>Ns</i>	<i>Z</i>	<i>Ps</i>	<i>Pm</i>
<i>Nm</i>	<i>Nm</i>	<i>Nm</i>	<i>Ns</i>	<i>Ns</i>	<i>Z</i>
<i>Ns</i>	<i>Nm</i>	<i>Ns</i>	<i>Ns</i>	<i>Z</i>	<i>Ps</i>
<i>Z</i>	<i>Ns</i>	<i>Ns</i>	<i>Z</i>	<i>Ps</i>	<i>Ps</i>
<i>Ps</i>	<i>Ns</i>	<i>Z</i>	<i>Ps</i>	<i>Ps</i>	<i>Pm</i>
<i>Pm</i>	<i>Z</i>	<i>Ps</i>	<i>Ps</i>	<i>Pm</i>	<i>Pm</i>

Pre navrhnutý fuzzy regulátor bola použitá metóda implikácie min a agregácia metóda max. Na Obr. 7 je znázornený povrch navrhnutého fuzzy systému, pre celý rozsah univerza.




Obr. 7 Rozmiestnenie fuzzy množín pre Δu


V. SIMULAČNÉ VÝSLEDKY

Celková simulačná schéma meniča je zobrazená na obr. 1, pričom pri spúšťaní bola záťaž nastavená na 10 Ω , a následne bolo simulované skratovanie meniča s hodnotou impedancie 0,01 Ω . Pri spúšťaní meniča pracoval fuzzy regulátor napätia, pričom pri skratovaní meniča rozhodovacia logika prešla na prúdový PI regulátor. Po odstránení skratu opäť prebral regulačnú úlohu výstupného napätia FLC regulátor napätia. Vstupné napätie meniča bolo nastavené na 325 V, spínacia frekvencia bola nastavená na 100 KHz a výstupné napätie bolo testované pre hodnoty 20V a 45V.

V rámci simulácie pri požadovanom napätí 40V bolo vykonané porovnanie PI regulátora s FLC regulátorom. Simulačné výsledky potvrdzujú zlepšenie prechodovej charakteristiky meniča pri jeho skratovaní, ako aj pri odpojení skratkovacieho rezistora. Po spustení dosiahol FLC regulátor požadovanú hodnotu rýchlejšie, pri skratovaní výstupu meniča prebral úlohu prúdový regulátor pre oba prípady správne a po odpojení skratkovacieho rezistora dosiahol požadovanú hodnotu napätia rýchlejšie opäť FLC regulátor (Obr. 8) [1, 4]. Na Obr. 9 je zobrazený detail priebehu z obr. 8 pri dosahovaní požadovanej hodnoty po odpojení skratkovacieho rezistora.



Obr. 8 Odozva na zmenu záťaže meniča pri požadovanom napätí 40V



Obr. 9 Odozva na zmenu záťaže meniča pri požadovanom napätí 40V - detail

VI. REGULÁCIA NAPÄTIA MENIČA FLC LUT REGULÁTOROM

Výpočtová a pamäťová náročnosť fuzzy systémov závisí od rôznych faktorov:

- počet vstupných/výstupných fuzzy množín, typ funkcií príslušnosti,
- typ fuzzy systému (Mamdani, Sugeno),
- počet pravidiel, komplexnosť pravidiel (použitie váhy, použitie viacerých logických operácií v rámci pravidiel),
- algoritmus pre defuzifikáciu.

Vo všeobecnosti je možné tvrdiť, že výpočtová náročnosť fuzzy systémov je vysoká, čo vedie v mnohých prípadoch k použitiu vyhľadávacích tabuliek (Look Up Table - LUT). Pod pojmom vyhľadávacia tabuľka rozumieme sériu čísel, ktoré nahrádzajú výpočet funkcií pomocou indexovania prvku v poli. Pomocou tohto postupu vieme urýchliť výpočtový čas fuzzy regulátora, pričom za negatívum môžeme považovať zvýšenú požiadavku na pamäť procesora [12-16].

Pre urýchlenie výpočtu fuzzy systému a aplikácií LUT máme dve rôzne možnosti, a to aproximáciu fuzzy systému ako celku, alebo použitie LUT pre priradenie stupňa príslušnosti pre jednotlivé funkcie príslušnosti. V rámci pokračovania článku bude ďalej opísaná prvá možnosť. Spôsob vytvorenia LUT pre fuzzy systém je uvedený v [1].

A. Interpoláčné algoritmy pre LUT

Pre určenie výstupu LUT regulátora existuje niekoľko typov algoritmov, pričom v prípade keď sú vstupné dáta pre tvorbu 2D tabuľky rozmiestnené lineárne sú štandardne používané tri typy algoritmov:

- 2D algoritmus najbližšieho bodu (nearest neighbour algorithm)
- 2D Lineárna interpolácia (Bilinear)
- 2D Kubická interpolácia (Bicubic)

Každý z týchto algoritmov potrebuje určiť relatívny index v tabuľke pre obe dimenzie. Uvažujme, že e predstavuje aktuálnu regulačnú odchýlku, de aktuálnu zmenu regulačnej odchýlky, res_e veľkosť tabuľky pre univerzume, a res_de veľkosť tabuľky pre univerzum de . Potom relatívny index i_e a i_de môžeme vyjadriť podľa (5) a (6).


$$e_unierzum \in \langle e_min, e_max \rangle \quad (3)$$

$$de_unierzum \in \langle de_min, de_max \rangle \quad (4)$$


$$i_e = \frac{e + abs(e_min)}{abs(e_min) + abs(e_max)} (res_e - 1) \quad (5)$$

$$i_de = \frac{de + abs(de_min)}{abs(de_min) + abs(de_max)} (res_de - 1) \quad (6)$$

Určenie relatívnych indexov je graficky znázornené na Obr. 10. Pre určenie výslednej aproximovanej hodnoty na základe LUT môžeme použiť jeden z vyššie zmienených algoritmov. 2D algoritmus najbližšieho bodu (Obr. 11 a)) určí výslednú hodnotu zaokrúhlením indexov i_e a i_de na najbližšiu celú hodnotu. Tento algoritmus je najjednoduchší na výpočet ale zároveň dosahuje najmenšiu presnosť aproximácie LUT.




Obr. 10 určenie relatívnych indexov pre LUT



Obr. 11 2D interpoláčné algoritmy, a) 2D algoritmus najbližšieho bodu, b) 2D lineárna interpolácia, c) 2D kubická interpolácia

Algoritmus pre 2D lineárnu interpoláciu (Obr. 11 b)) je jeden z najčastejšie používaných algoritmov pre 2D

interpoláciu, pre jeho dobré aproximačné schopnosti a rýchly výpočet. Výstupná hodnota algoritmu je vypočítavaná ako vážený priemer jeho štyroch najbližších bodov, podľa Obr. 12.




Obr. 12 Princíp 2D lineárnej interpolácie

Algoritmus 2D bikubickej interpolácie (Obr. 11 c)), ktorý počíta výstup na základe šestnástich najbližších bodov vo vyhľadávacej tabuľke, dosahuje najlepšie aproximačné výsledky. Jeho nevýhodou je komplikovanejší spôsob výpočtu.


B. Vplyv veľkosti a algoritmu interpolácie na presnosť aproximácie FLC

Na Obr. 13 je znázornená presnosť aproximácie fuzzy systému interpolovaním bodov LUT s algoritmom najbližšieho bodu, pričom boli testované rôzne veľkosti LUT tabuľky, pričom každá tabuľka mala rovnaký počet stĺpcov aj riadkov. Z grafu vyplýva, že presnosť aproximácie narastá s veľkosťou LUT tabuľky, pričom zväčšovanie LUT má malý vplyv na zvýšenie presnosti pre tabuľky väčšej veľkosti.



Obr. 13 Presnosť aproximácie LUT pri interpolácii pomocou najbližšieho bodu


Na Obr. 14 je znázornená presnosť aproximácie fuzzy systému interpolovaním bodov LUT s algoritmom pre lineárnu interpoláciu bodov, pričom boli testované rôzne veľkosti LUT tabuľky, pričom každá tabuľka mala rovnaký počet stĺpcov aj riadkov. Z grafu vyplýva, že postačujúcu veľkosť LUT môžeme odhadnúť na veľkosť niekoľkých stoviek údajov.




Obr. 14 Presnosť aproximácie LUT pri lineárnej interpolácii bodov

C. Simulácia LUT FLC ako regulátor napätia pre DC-DC menič

Pre otestovanie vplyvu nepresnosti jednotlivých aproximovaných LUT fuzzy regulátorov, sme ako prvú zvolili LUT o veľkosti 10x10, z dôvodu, že podľa Obr. 14 by mala pri tejto by mal LUT regulátor dosahovať obdobné výsledky ako pôvodný fuzzy regulátor (pri lineárnej aproximácii). Simulácia meniča bola nastavená obdobne ako v ako v kap V. Výsledný priebeh fuzzy PID regulácie napätia je zobrazený na Obr. 8. Na Obr. 15 je zobrazený priebeh výstupného napätia meniča, pričom môžeme tvrdiť, že daný LUT regulátor s lineárnou interpoláciou dostatočne aproximuje fuzzy PID regulátor napätia (Obr.8). Naproti tomu LUT regulátor s interpoláciou podľa najbližšieho bodu dosiahol požadovanú hodnotu oneskorene, a na výstupe dosahuje trvalejšie oscilácie.




Obr. 15 Simulácia LUT 10x10 s lineárnou interpoláciou




Obr. 16 Simulácia LUT 10x10 s interpoláciou podľa najbližšieho bodu

V ďalšom pokračovaní analýzy bol testovaný LUT regulátor s vyhľadavacou tabuľkou o veľkosti 40x40 s algoritmom interpolácie podľa najbližšieho bodu. Výsledný simulovaný priebeh výstupného napätia je zobrazený na Obr. 17, pričom môžeme usudzovať, že je podobný priebehu s použitím fuzzy PID regulátora(Obr.8) .



Obr. 17 Simulácia LUT 40x40 s interpoláciou podľa najbližšieho bodu

V prípade použitia algoritmu interpolácie podľa najbližšieho bodu je problematické dosiahnuť presne požadovanú hodnotu napätia, čo je možné pozorovať na Obr. 18, kde je zobrazený detail priebehu z Obr. 17.




Obr. 18 Simulácia LUT 40x40 s interpoláciou podľa najbližšieho bodu - detail

VII. REGULÁCIA NAPÄTIA MENIČA ZJEDNODUŠENÝM FLC REGULÁTOROM

Pre mnohé FLC sú ako vstupné premenné pri regulácii používané: regulačná odchýlka e a zmena regulačnej odchýlky Δe pre rozličné systémy. Ako výstup pre FLC je zvyčajne použitý akčný zásah u alebo zmena akčného zásahu Δu . V takomto prípade je tabuľka pravidiel definovaná v 2D priestore. Pre väčšinu navrhnutých FLC týmto spôsobom platí, že pravdivostná tabuľka je symetrická podľa diagonály tabuľky a výstup fuzzy systému je úmerný vzdialenosti od hlavnej diagonály v normalizovanom priestore vstupov. Na základe týchto tvrdení, je možné odvodiť novú premennú d (absolútna vzdialenosť vstupov e a Δe od hlavnej diagonály), ktorá je vyznačená na Obr. 19. Túto premennú môžeme použiť ako jediný vstup pre FLC, pričom v rámci ďalšieho textu bude FLC s jedným vstupom označovaný ako SFLC (single-input FLC). Takto navrhnutý regulátor je výpočtovo rýchlejší z dôvodu výrazného zredukovania počtu pravidiel

ako aj zredukovania počtu vstupných fuzzy množín. V prípade aproximácie SFLC pomocou LUT tabuľky môžeme výrazne zredukovať pamäťové nároky kladené na LUT (prechádzame z 2D do 1D veľkosti tabuľky) spolu so zjednodušením interpolačných algoritmov. Z dôvodu zníženia počtu vstupov a redukcie počtu pravidiel môžeme v takoríšenie považovať za výhodu optimalizácierealizácie regulátora. V [16] je zároveň dokázané že SFLC je stabilný podľa Popovho kritéria stability.



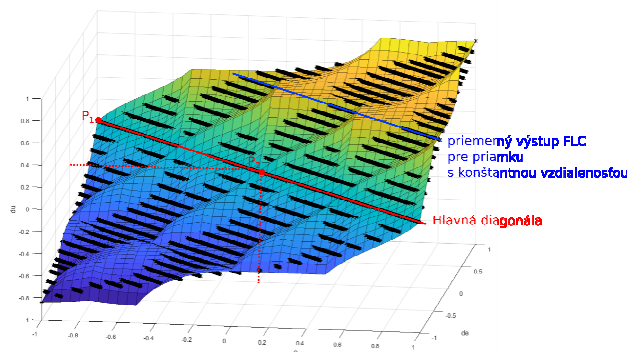
Obr. 19 SFLC odvodenie d

Spôsob odvodenia vzdialenosti d je uvedený v [1]. Na výpočet vzdialenosti bodu regulácie $P_r(e, \Delta e)$ od hlavnej diagonály povrchu originálneho FLC môžeme použiť(7), pričom po dosadení konštánt pre určenú krivku hlavnej diagonály dostávame(8), čo predstavuje nenáročný vzorec pre výpočet. Pre výpočet FLC môžeme zaviesť novú premennú, vzdialenosť od nulovej diagonály d_s (signeddistance). Táto premenná vyjadruje okrem vzdialenosti bodu od nulovej diagonály aj znamienko, ktoré určuje, či sa nachádzame v kladnej alebo zápornej časti povrchu FLC.

$$d_s = \frac{k + me - \Delta e}{\sqrt{1 + m^2}} \dots\dots\dots m = -1, k = 0 \quad (7)$$


$$d_s = \frac{e - \Delta e}{\sqrt{2}} \quad (8)$$

Pre aproximáciu pôvodného povrchu FLC môžeme použiť vzdialenosť d_s podľa Obr. 20.




Obr. 20 Určenie nulovej diagonály pre SFLC

Potom výstup 1D LUT môže byť znázornený podľa obr. 21, kde je znázornená závislosť výstupu duv závislosti d_s pre kladnú časť povrchu originálne FLC.



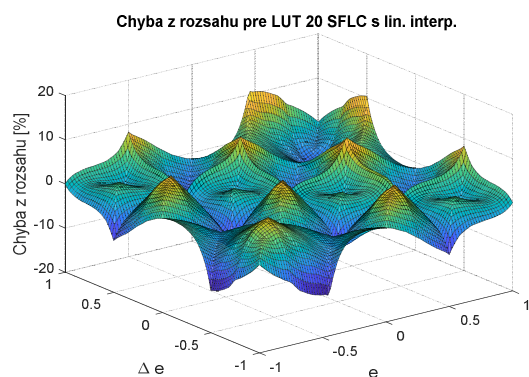
Obr. 21 Výstup LUT SFLC vzhľadom na d

Na Obr. 22 je zobrazený výsledný povrch LUT SFLC regulátora s veľkosťou LUT 20 s použitím interpolácie podľa najbližšieho bodu .



Obr. 22 Povrch LUT20 SFLC s lineárnou interpoláciou


Na Obr. 23 je zobrazené veľkosti chýb aproximácie SFLC LUT oproti pôvodnému FLC regulátoru s dvoma vstupnými množinami, pričom môžeme konštatovať, že priemerná chyba LUT SFLC regulátora predstavuje 0%.



Obr. 23 Chyba z rozsahu pre LUT20 SFLC s lineárnou interpoláciou


A. Simulačné výsledky LUT SFLC

Pre overenie možnosti náhrady originálneho FLC za LUT SFLC sme vykonali totožnú simuláciu z kap. V pre SFLC regulátor s LUT 20. S použitím interpolácie podľa najbližšieho bodu vznikala trvalá regulačná odchýlka (Obr.24).



Obr. 24 Simulácia LUT SFLC20 s interpoláciou podľa najbližšieho bodu

Pri použití lineárnej interpolácie dosiahol LUT SFLC rovnaké výsledky ako pôvodný regulátor (Obr.8.).




Obr. 25 Simulácia LUT SFLC20 s lineárnou interpoláciou

VIII. POROVNANIE VÝPOČTOVEJ RÝCHLOSTI NAVRHNUTÝCH REGULAČNÝCH RIEŠENÍ

Na Obr. 26 je zobrazená rýchlosť výpočtu jednotlivých regulačných štruktúr v programe Matlab, pričom na meranie rýchlosti jednotlivých funkcií pre výpočet regulačného zásahu sú používané funkcie *tic()* a *toc()*. Obr. 26 potvrdzuje, že výpočet fuzzy systému, a tým aj celého FLC je zdĺhavý. Vďaka použitiu LUT regulátorov je možnosť tento výpočet významne urýchliť, pričom LUT SFLC regulátory vykazovali ešte rýchlejšie prepočty.

V závere grafu sú tiež uvedené rýchlosti výpočtov Mamdani a Sugeno fuzzy systémov s piatimi pravidlami a jednou vstupnou množinou. Z Obr. 26 vyplýva, že redukovaním počtu vstupov pre FLC je možné významne urýchliť jeho výpočet.



Obr. 26 Porovnanie rýchlosti prepočtu regulačných štruktúr v Matlabe

IX. ZÁVER

V rámci tohto článku je preukázaná verifikácia nami predkladaného FLC regulátora pre výstupné napätia nepriameho DC-DC meniča s mäkkým spínaním a jeho vzájomné porovnanie s klasickou PI reguláciou, pri prvotnom zapnutí meniča, a tiež pri jeho zaťažení. Ako zaťaženie meniča bolo zvolené jeho skratovanie, pri ktorom dochádza k prepnutiu na prúdový regulátor. Takýto test bol zvolený z dôvodu, že je ho možné považovať za najhoršiu možnosť, ktorá sa môže počas zmeny zaťaženia meniča vyskytnúť. Pomocou simulačných testov sme preukázali opodstatnenosť použitia fuzzy regulácie, ktorá preukazovala zvýšenú stabilitu, zrýchlenie prechodových dejov meniča, menšie prekmity výstupného napätia oproti pôvodne navrhutej PI regulácii.

Druhá časť článku bola venovaná možnosti optimalizácie výpočtu FLC. Za prvú možnosť môžeme považovať vytvorenie 2D LUT tabuľky, ktorá dokáže aproximovať povrch FLC. Takéto riešenie vedie k významnému urýchleniu výpočtu za cenu zvýšenia pamäťovej náročnosti regulátora a straty fuzzy informácie. Ako druhá možnosť sa javí zredukovanie počtu vstupov regulátora, čo však nie je možné aplikovať pre všetky FLC regulátory. V prípade, ak je možné použiť SFLC, pripadá do úvahy použitie 1D fuzzy systému ako regulátora, alebo aproximovanie povrchu 2D fuzzy systému do LUT, čím sa docielí minimálna výpočtová náročnosť regulačnej slučky a nízke pamäťové nároky na mikro počítač.

ACKNOWLEDGMENT

Túto prácu podporila Vedecká grantová agentúra Ministerstva školstva, vedy, výskumu a športu Slovenskej republiky a Slovenskej akadémie vied grantom VEGA 1/0187/18a grant FEI-2017-40.

REFERENCES

- [1] M. Lešo, „Fuzzy riadenie DC-DC meniča“, dizertačná práca, KEM, TUKE, Košice, Slovensko, 2018.
- [2] M. Lešo, J. Žilková, M. Pástor, "Control Methods of DC-DC converters", *Elektrotechnické listy*, ročník 1, číslo 1, str. 1-4, 2016.
- [3] M. Lešo, J. Žilková, M. Pástor, "Advanced Control Methods of DC-DC converters", *Elektrotechnické listy*, ročník 1, číslo 2, str. 1-4, 2016.
- [4] M. Lešo, J. Žilková, M. Pástor, J. Dudrik: "Fuzzy Logic Control of Soft - Switching DC - DC Converter ", *Elektronikair Elektrotechnika*, ročník 22, číslo 5, str. 3-7, 2016.
- [5] LipingGuo, J.Y. Hung, R.M. Nelms: "Evaluation of DSP-Based PID and Fuzzy Controllers for DC-DC Converters", *IEEE Transactions on Industrial Electronics*, ročník 56, číslo 6, str. 2237-2248, 2009.
- [6] S. Manikala, "Voltage-Mode, Current-Mode (and Hysteretic Control)", *MicroSemi Technical note*, 2012.
- [7] Sujata Verma, S.K. Singh, Rao, A.G. – "Overview of control Techniques for DC-DC converters", v *Journal of Engineering Research*, Roč. 2, č. 8, str. 18-21, 2013, ISSN 2278 – 9472.
- [8] Vas P.: *Artificial-Intelligence-Based Electrical Machines and Drives*, Oxford Press, New York, 1999.
- [9] J. Dudrik, M. Bodor and M. Pástor, "Soft-Switching Full-Bridge PWM DC-DC Converter With Controlled Output Rectifier and Secondary Energy Recovery Turn-Off Snubber," v *IEEE Transactions on Power Electronics*, roč. 29, č. 8, str. 4116-4125, 2014.
- [10] Bodor, M.: *Výkonový DC/DC menič s mäkkým spínaním*. Dizertačná práca. Košice: TU v Košiciach, Fakulta elektrotechniky a informatiky, 2012. 112 s.
- [11] Modrlák, O.: *Fuzzy řízení a regulace*, 2002.
- [12] I. Kecskes, "Lookup Table Based Fuzzy Controller Implementation in Low-power Microcontrollers of Hexapod Robot Szabad", *Conference: 3rd International Conference & Workshop Mechatronics in Practice and Education – MECHEDU*, 2015.
- [13] Jinwook Kim, Yoon-Gu Kim, and Jinung An: A Fuzzy Obstacle Avoidance Controller Using a Lookup-Table Sharing Method and Its Applications for Mobile Robots, *IJARS* 2011, Vol. 8, No 5, pp. 39-48
- [14] Sobhan, P.V.S: Look Up Table Based Fuzzy Logic Controller for Unmanned Autonomous Underwater Vehicle, *Advances in Computing, Control, & Telecommunication Technologies*, 2009, pp. 497-501, ISBN: 978-1-4244-5321-4, DOI: 10.1109/ACT.2009.128
- [15] Bai Yanhong; Zhao Zhijuan; Sun Zhiyi; Quan, Long: A Linear Interpolation Fuzzy Controller for a Boiler Pressure Control System, *6th IFAC Symposium on Mechatronic Systems, MECH 2013*, pp. 650-654, Hangzhou, China, 2013, doi: 10.3182/20130410-3-CN-2034.00070
- [16] Byung-Jae Choi, Seong-Woo Kwak and Byung Kook Kim, "Design and stability analysis of single-input fuzzy logic controller, in *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 30, no. 2, pp. 303-309, Apr 2000.

Analýza názorov v konverzačnom obsahu so zameraním na slovníkový prístup

Martin Mikula

Katedra kybernetiky a umelej inteligencie, Technická univerzita v Košiciach, Košice, Slovensko

Kristína Machová

Katedra kybernetiky a umelej inteligencie, Technická univerzita v Košiciach, Košice, Slovensko

Abstrakt—Klasifikácia názorov je v súčasnosti veľmi populárna disciplína, lebo dokáže poskytnúť veľmi cenné informácie o názoroch a postojoch ľudí diskutujúcich na internete. Dizertačná práca sa zaoberá automatickou klasifikáciou názorov pomocou slovníkového prístupu a riešením niekoľkých problémov spojených s touto metódou. V rámci práce boli vytvorené dva datasety použité na testovanie a porovnávanie navrhnutých riešení. Zároveň boli vygenerované dva slovníky, ktoré boli implementované do slovníkového prístupu na klasifikáciu názorov. Slovníkový prístup bol ďalej vylepšený pridaním algoritmu na identifikáciu tém, ktorá zvýšila presnosť klasifikácie. Na vyriešenie problémov, ktoré sa počas prípravy slovníka a experimentov ukázali, boli implementované nasledujúce algoritmy: kombinovaný prístup a anotovanie slovníka pomocou evolučného algoritmu. Kombinovaný prístup mal za úlohu klasifikovať príspevky, ktoré nebolo možné klasifikovať pomocou samotného slovníka, lebo neobsahovali slová zo slovníka. Kombinovaný prístup dopĺňa slovníkovú metódu ďalšou metódou strojového učenia kvôli zvýšeniu presnosti klasifikácie názorov. Uvedený prístup nakoniec klasifikoval viac ako 99% príspevkov a dosiahol zlepšenie výsledkov oproti samostatnému slovníkovému prístupu. Táto práca je súčasne venovaná možnosti nahradenia manuálneho spôsobu anotovania evolučným algoritmom. Ako implementácia evolučného algoritmu bola zvolená metóda optimalizácie pomocou roja častíc (Particle Swarm optimization - PSO). PSO bola nastavená tak, aby hľadala vhodné hodnoty polarít pre slová v slovníku. Výsledky dokazujú, že PSO bola schopná nájsť vhodnejšie hodnoty polarít ako človek, a teda zlepšiť dosiahnuté výsledky.

Opinion classification is very popular nowadays because it is able to explore useful information about opinions and attitudes of the people who discuss on the internet. Presented dissertation thesis is focused on the automatic classification using a dictionary approach and solving several problems linked with this method. Two datasets were created in this work and they were used to evaluate and to compare designed solutions. At the same time, two dictionaries were generated which were implemented into the dictionary approach for the opinion classification. A topic identification was added to improve the classification performance of the dictionary approach. A topic identification finally increased the classification performance. To solve additional problems with the dictionary approach the following algorithms were implemented: a combined approach and a dictionary annotation based on evolutionary computation. The combined approach was used to classify reviews which were not classified by dictionary approach because they did not contain words from the dictionary. The combined approach joins the dictionary approach and machine learning method to classify reviews which do not contain words from the dictionary. The proposed approach was able to classify more than 99% reviews and it achieved better results in comparison with dictionary approach. This work also focuses on a possibility to replace a human annotator by the evolutionary computation.

Particle Swarm Optimization was selected as the evolutionary computation algorithm. It was designed to find suitable values of polarity for words in the dictionary. The results show, that PSO was able to find more suitable values of polarity than the human and it increased the classification performance.

I. ÚVOD

Sociálne médiá sa stávajú stále silnejším zdrojom informácií, ktoré vznikajú neustálou interakciou medzi ľuďmi. Tí medzi sebou komunikujú, zdieľajú svoje názory a emócie, alebo hodnotia produkty a služby. Už aj firmy pochopili, že tieto dáta majú veľký potenciál, a preto sa stále častejšie venujú ich analýze. Znalosti získané zo zozbieraných dát môžu významne ovplyvniť správanie kupujúcich a predávajúcich. Firma takto môže získať informácie, či sa jej zákazníkom produkt páčil alebo nepáčil, čo by na jej produkte zmenili alebo pridali a množstvo ďalších dôležitých informácií. Vďaka tomu sa do popredia dostávajú disciplíny ako analýza názorov a sentimentu. Analýza sentimentu sa zameriava na identifikáciu a zatriedenie ľudských názorov, emócií a postojov voči konkrétnemu objektu, ktorým môžu byť produkty a služby, ďalší ľudia alebo udalosti.

Na analýzu názorov sa v súčasnosti používajú dva hlavné prístupy: metódy založené na strojovom učení a metódy založené na slovníkoch. Metódy strojového učenia využívajú na klasifikáciu známe algoritmy ako napríklad Naïvný Bayesov klasifikátor, metódu podporných vektorov, metódu maximálnej entropie, alebo k-najbližších susedov na to, aby príspevky zaradili do pozitívnej alebo negatívnej triedy. V posledných rokoch sa do popredia začali dostávať neuronové siete, ktoré tiež dosahujú dobré výsledky v oblasti analýzy sentimentu. Metódy založené na slovníkoch používajú dostupné slovníky obsahujúce názorové slová. Tieto slová vyjadrujú pozitívny alebo negatívny postoj voči analyzovanému subjektu a používajú sa na to, aby príspevku priradili polaritu. Nevýhodou týchto metód je fakt, že všetky vyžadujú na vstupe nejakú externú znalosť. V prípade strojového učenia sa vyžaduje anotovaná množina príspevkov a v prípade slovníkového prístupu je potrebné vytvoriť a anotovať dostatočne kvalitný slovník.

Tvorba externých znalostí ale nie je jednoduchá. Zozbieranie a hlavne anotovanie dostatočne veľkej vzorky príspevkov, ktorá by mohla poslúžiť na učenie algoritmov strojového učenia, je zložité a časovo náročné. Tento problém sa môže zvýrazniť, keď naučený klasifikátor pracuje

vo viacerých doménach a je potrebné ho adaptívne prispôbovať meniacim sa podmienkam. Podobne je na tom aj tvorba slovníkov, ktorých v minoritných jazykoch veľa nie je. Minoritné jazyky sú jazyky, ktoré nie sú štandardne používané na analýzu sentimentu ako napríklad slovenčina, čeština a pod. V týchto jazykoch je zbieranie a anotovanie vhodných slov jednak časovo náročné, a tiež to zaberá ľudské zdroje, ktoré sa tomuto procesu musia venovať.

Predkladaná dizertačná práca sa venuje vytvoreniu a použitiu slovníkového prístupu na analýzu sentimentu v slovenskom jazyku. Vytvorili sme dataset príspevkov, ktoré boli zozbierané z rôznych webových stránok a manuálne anotované. Spolu s datasetom sme vytvorili aj slovník názorových slov, ktorý bol použitý na klasifikáciu príspevkov do pozitívnej a negatívnej triedy. V rámci zlepšovania výsledkov klasifikácie boli do algoritmu na klasifikáciu názorov pridané funkcie spracovania negácie, spracovania intenzifikácie a funkcia indetifikácie tém, ktoré prispeli k zvýšeniu presnosti a návratnosti. Zároveň sme sa venovali problému, keď nebolo možné niektoré príspevky anotovať z dôvodu, že neobsahovali slová zo slovníka. Tento problém bol vyriešený kombinovaným prístupom, ktorý spája slovníkový prístup s metódou strojového učenia. Pre zjednodušenie adaptácie v slovenskom jazyku sme testovali možnosti nahradenia manuálnej formy anotovania evolučným algoritmom. Evolučný algoritmus reprezentovaný metódou Particle Swarm Optimization sa ukázal ako vhodná náhrada, keďže bol schopný nájsť lepšie hodnoty polarizácie pre slová v slovníku ako človek.

Táto práca je rozdelená do nasledujúcich sekcií.

Sekcia II popisuje metódy, ktoré sa na analýzu sentimentu používajú a zároveň poskytuje čitateľovi prehľad o najčastejšie používaných metódach. Sekcia III je zameraná na vysvetlenie základnej myšlienky ako optimalizácia pomocou roja častíc funguje. V sekcii IV je popísaná analýza názorov pomocou rôznych foriem slovníkového prístupu.

II. METÓDY POUŽÍVANÉ NA ANALÝZU SENTIMENTU

Proces analýzy sentimentu nie je jednoduchá vec. Preto sa na jeho analýzu používajú rôzne druhy metód. Tieto metódy by sa dali rozdeliť do niekoľkých skupín. Jedno z možných delení je na metódy založené na strojovom učení a metódy používané pri spracovaní prirodzeného jazyka. Toto delenie však nie je najvhodnejšie, keďže niektoré metódy strojového učenia sa používajú v rámci spracovania prirodzeného jazyka. Ďalším možným spôsobom, ako rozdeliť metódy je na metódy strojového učenia a metódy založené na slovníkovom prístupe. Tento spôsob delenia je veľmi často používaný vo vedeckých prácach Mejova [21], Pang a Lee [29] a iných. Metódy strojového učenia by sme mohli ešte ďalej rozdeliť na prístupy, ktoré využívajú kontrolované učenie a na prístupy, ktoré využívajú nekontrolované učenie [19]. V práci Koncz a Paralič [18] bolo zavedené delenie na exogénne a endogénne metódy. Tento druh delenia vychádza z pohľadu na rozdielnosť údajov vstupujúcich do analýzy sentimentu a tvorbu modelov. Pri endogénnych metódach je sentiment určený pomocou algoritmu alebo anotovanej vzorky údajov a

žiadne ďalšie údaje by pri tvorbe modelu nemali byť použité. Naopak pri exogénnych metódach sa sentiment určuje na základe algoritmu, vzorky údajov a ďalších externých znalostí napr. slovníky. K tomuto typu delenia má blízko aj rozdelenie na metódy založené na znalostiach, štatistické metódy a hybridné metódy. Metódy založené na znalostiach, podobne ako exogénne metódy, využívajú nejakú formu externých znalostí, ktoré môžu byť aplikované v procese analýzy sentimentu. V prípade štatistických metód naopak nie sú potrebné žiadne iné informácie ako anotovaná množina vstupných dát. Hybridné metódy kombinujú oba predchádzajúce typy metód na analýzu sentimentu.

A. Metódy založené na slovníkoch

Metódy založené na slovníkoch používajú na analýzu textu názorové slová. Sú to slová, ktoré sú typickými nositeľmi názoru a sú uložené v slovníkoch. V závislosti na type slovníka môžu slová v slovníku obsahovať aj dodatočné informácie, ktoré môžu zvýšiť presnosť klasifikácie. Slovníky teda obsahujú atribúty ako napr. polarita, subjektivita, sila polarizácie, alebo prepojenia na ďalšie slová a synsety. Tieto slová následne pomáhajú určiť kontextuálnu subjektivitu analyzovaného textu.

1) *Metódy generovania slovníkov:* Existujú tri rôzne spôsoby generovania slovníkov. Prvým spôsobom je generovanie slovníkov **manuálnym spôsobom**. Pri takomto generovaní sa často využívajú už existujúce slovníky. Väčšinou sa prekladajú slovníky z iných jazykov. V ďalšom kroku sa tieto slovníky spoja do jedného. Odstránia sa duplicitné záznamy a rozšíri sa o synonymá poprípade opozitá. Takto vytvorený slovník bol použitý aj v práci Taboada a kol. [32]. Slovník obsahoval hlavne prídavné mená, ktoré dopĺňali ďalšie slovné druhy ako podstatné mená, príslovky a slovesá. Výhodou takéhoto generovania slovníkov je, že všetky slová v slovníku majú pozitívnu alebo negatívnu polaritu, a teda sú relevantné pre analýzu sentimentu. Nie je teda potrebná ich následná kontrola. Veľkou nevýhodou takéhoto generovania slovníkov je časová náročnosť v prípadoch, že chceme vytvoriť dostatočne veľký a kvalitný slovník. Zredukovať časovú náročnosť na tri týždne pri generovaní slovníka obsahujúceho cez 10 tisíc slov sa podarilo v práci Mohammad a Turney [24]. Autori použili na anotovanie slovníka platformu nazývanú Mechanical Turkovia, ktorú ponúka Amazon. V prácach [16], [17] sú prezentované prístupy anotovania slovníka pomocou najlepších najhorších škálovania (Best–Worst Scaling) označovaného aj ako škálovanie maximálneho rozdielu (Maximum Difference Scaling). V týchto prípadoch mali anotátori zoradiť štvorice sentimentálnych slov podľa nasledujúcich pokynov: od najpozitívnejšieho po najmenej pozitívne a od najnegatívnejšieho po najmenej negatívne. Tieto štvorice boli anotované pomocou crowdsourcingovej platformy CrowdFlower.

Túto nevýhodu sa snažia kompenzovať ďalšie dva prístupy k vytváraniu slovníkov. Jedným z nich je **semi-automatizovaný spôsob**. Tiež na svoje fungovanie využíva už existujúce slovníky ako je WordNet alebo SentiWordNet. Semi-automatizované metódy začínajú generovanie slovníkov malým

počtom silno pozitívnych a silno negatívnych slov - *seed words*. K týmto slovám sú vyhľadávané ďalšie slová na základe paradigmatických vzťahov (synonymá, antonymá). Takýto slovník je následne manuálne skontrolovaný a sú z neho odstránené nepotrebné slová. Potom sú zvyšné slová ohodnotené podľa polaritu a sily polaritu.

Tretou možnosťou generovania slovníkov je **automatické generovanie**. Využíva sa na to najmä asociácia. Opäť sa začína s malým počtom silne polaritných slov. Ďalšie slová sa vyhľadávajú v už existujúcich slovníkoch pomocou vzájomných vzťahov. Skóre pre novozískané slovo je vypočítané na základe jeho vzdialenosti od pôvodného slova alebo slov. Táto hodnota sa často počíta pomocou Turney-ho metódy vzájomnej informácie. Medzi výhody takto generovaných slovníkov patrí okrem časovej úspory aj to, že často dokážu nájsť slová, ktoré by sa za iných okolností do slovníka nedostali.

Vygenerované slovníky je následne možné použiť na identifikáciu orientácie príspevkov. Väčšinou sa pri tom jedná o použitie rôznych jazykových pravidiel. Práca v tejto skupine metód zvyčajne dosahujú slabšie výsledky v porovnaní s metódami strojového učenia.

Benamara a kol. [4] predstavili tri skórovacie metódy, ktoré kombinovali spojenie prísloviok a prídavných mien. Použili *variabilné skórovanie* (variable scoring) pre prídavné mená, *skórovanie priority prídavných mien* (adjective priority scoring) pre určenie relevantnosti prídavných mien k príslovkám a *prvotné skórovanie prísloviok* (adverb first scoring) pre určenie relevantnosti prísloviok k prídavným menám. Experiment bol vykonaný na skupine 200 správ z BBC anotovaných 10 ľuďmi. Skórovanie priority prídavných mien bolo označené ako najlepšie, z čoho vyplýva, že najdôležitejšie pre analýzu názorov sú práve prídavné mená.

Analýzou sily polaritu pomocou násobenia prídavných mien a prísloviok sa zaoberali v práci Lu a kol. [20]. Prezentovaný prístup určuje silu polaritu príspevku na základe síl polarit vyjadrených pomocou prídavných mien a prísloviok. Sila prídavných mien bola vypočítaná na základe progresívnych relačných pravidiel a analýzy liniek. Celkovo bolo vybratých 3 497 prídavných mien a 100 prísloviok na reprezentáciu pravidiel. Sila prísloviok bola vypočítaná v rozmedzí -1 až +1. Dosiagnutá presnosť dosahovala 71.7%.

Taboada a kol. [32] využili manuálne vygenerovaný slovník na klasifikáciu orientácie rôznych príspevkov. Ich prístup využíval pozitívne a negatívne slová, slová meniace intenzitu polaritu (intenzifikátory) a slová otáčajúce polaritu (negátory). Pri vytváraní slovníka sledovali aj vplyv intenzifikátorov a negátorov na zisťovanie polaritu príspevku. Svoj slovník ďalej porovnávali s inými slovníkmi ako General Inquirer, MPQA Subjectivity lexicon, SentiWordNet, Macquarie Semantic Orientation Lexicon. Tieto slovníky testovali na vzorkách hodnotení z webovej služby Epinions.com a pre porovnanie výsledkov slúžili ako vzorka údaje z práce Pang a Lee [29]. Autormi prezentovaný prístup a slovník dosiahli najlepšie výsledky v porovnaní s ostatnými slovníkmi.

Vplyvu negátorov a intenzifikátorov je venovaná aj práca Kennedy a Inkpen [14]. Tí porovnávali výsledky dvoch metód,

ktoré pri analyzovaní textu použili slovník obsahujúci aj negátory a intenzifikátory a slovník bez týchto slov. V prípade prvej metódy použili na porovnanie počty pozitívnych a negatívnych slov. Druhá metóda využívala algoritmus strojového učenia, a to konkrétne algoritmus podporných vektorov (SVM – Support Vector Machines). V oboch prípadoch sa ukázalo použitie týchto slov meniacich polaritu (shifters) ako lepšie riešenie a malo vplyv na zvýšenie presnosti.

Možnostiam práce s doménovo závislými termami sa venujú aj Hu a Li [11]. Tieto termy sa viažu na konkrétnu doménu a na ich orientáciu má vplyv aj kontext, v ktorom sú použité. Pre každé topikové slovo boli vytvorené dva popisné modely (pozitívny a negatívny). Tieto modely vytvárali rozdiely, ktoré boli použité na klasifikáciu sentimentu. Klasifikácia bola vykonávaná na základe pravdepodobnostného modelu. Autori svoj prístup otestovali na vzorke údajov z práce [29] a aj korpuse čínskych recenzií produktov zo stránok ZOL a IT168. V práci dosiahli presnosť porovnateľnú s ostatnými prácami využívajúcimi slovníkové metódy.

B. Metódy založené na strojovom učení

Na analýzu názorov je tiež možné použiť metódy založené na strojovom učení. Cieľom týchto metód je klasifikácia dokumentov, alebo ich častí, do názorových tried podľa názorovej orientácie. Pod metódami strojového učenia sa myslí vytvorenie alebo použitie algoritmu, ktorý optimalizuje svoj výkon použitím existujúcich dát alebo predchádzajúcej skúsenosti.

Jednými z prvých, ktorí na klasifikáciu sentimentu použili metódy strojového učenia boli Pang a Lee [28]. Autori použili NB, Maximálnu entropiu a SVM na binárnu klasifikáciu recenzií filmov zo stránky IMDB.com. Najlepšie výsledky (najvyššiu presnosť) dosiahol SVM klasifikátor s použitím unigramov. Vo svojej práci uvažovali nad tým, že analýza vzájomných odkazov medzi príspevkami by mohla zvýšiť presnosť klasifikácie.

Metódu podporných vektorov použili vo svojej práci aj Abbasi a kol. [1]. Klasifikátor bol testovaný na troch vzorkách údajov. Prvý dataset obsahoval hodnotenia digitálnych kamier zo stránky Epinions.com, ktoré boli hodnotené od 1 do 5 hviezdíček. Druhý dataset obsahoval hodnotenia áut zo stránky Edmunds.com. Tretou vzorkou bola vzorka z práce Pang a Lee [28], ktorá slúžila na porovnanie výsledkov. Najlepšia presnosť (89.65%) na porovnávačej vzorke bola dosiahnutá práve autormi navrhovanou metódou.

V práci Bai [2] bol predstavený Markov-Blanket (MB) klasifikátor. Ten bol porovnávaný s NB klasifikátorom, SVM, perceptrónom a metódou podmienených náhodných polí (conditional random fields). MB zisťoval podmienené pravdepodobnosti medzi slovami a vytváral Markov-Blanket – orientovaný acyklický graf sentimentálnych slov. Následne autor použil Tabu vyhľadávacie rozšírenie MB modelu umožňujúce použitie tradičných vyhľadávacích metód za asistencie adaptívnej pamäte, ktoré vytvorilo slovník v závislosti na získanom sentimente. Použitím Tabu vyhľadávania bolo do slovníka vybratých 35 relevantných slov. Tento prístup dosiahol 78.08% presnosť na datasete [28], 92.7% presnosť na datasete [29]

a 73.21% presnosť na vlastnej vzorke údajov, obsahujúcej 600 online správ od Infonic. Najlepšie výsledky spomedzi klasických klasifikátorov dosiahla metóda SVM pri použití všetkých atribútov.

Použitiu metód strojového učenia v českom jazyku je venovaná práca Habernal a kol. [10]. Autori použili rôzne metódy predspracovania (úprava na základný tvar, POS tagovanie, úprava preklepov a gramatických chýb), experimentovali s piatimi rôznymi možnosťami výberu atribútov (vzájomná informácia, informačný zisk, chí-kvadrát, pravdepodobnostný rozsah a relevantné skóre) a dvomi klasifikátormi (SVM a maximálna entropia). Klasifikátory boli testované na 3 testovacích množinách. Prvá obsahovala príspevky zo sociálnej siete Facebook.com. Dataset obsahoval 2 589 pozitívnych, 5 174 neutrálnych, 1 991 negatívnych a 248 bipolárnych príspevkov. Najlepšie výsledky dosiahla maximálna entropia (69%) za použitia unigramov, bigramov, POS tagovania, emoticon a charakterových n-gramov. Ďalšie dve množiny obsahovali recenzie filmov (csfd.cz) a recenzie produktov (mall.cz). Pre tieto datasety bola použitá metóda maximálnej entropie. Táto metóda dosiahla najlepšie výsledky (okolo 75% na recenziách produktov a okolo 78% na recenziách filmov) v prípadoch, keď ako atribúty bola použitá kombinácia unigramov a bigramov.

C. Hybridné metódy pre analýzu sentimentu

Hybridné metódy využívajú na analýzu sentimentu rôzne kombinácie rôznych metód. Sindhwani a Melville [31] vytvorili kombináciu nekontrolovaného a semi-kontrolovaného učenia. Metóda nekontrolovaného učenia využíva slovník 2 986 slov hodnotených človekom. Ako semi-kontrolované učenie použili dokument-slovo bipartitnú grafovú reprezentáciu dát. Vzhľadom na riedke dáta použili regularizovanú metódu najmenších štvorcov (RLS – Regularized Least Squares) ako klasifikačný algoritmus. Predchádzajúce znalosti vložili do modelu pomocou lexikálnej RLS. Tento prístup bol otestovaný na troch datasetoch (Pang a Lee [28], lotus blogy a politické blogy) za použitia 10-násobnej krížovej validácie. Autormi vytvorený prístup porovnali s tromi klasickými metódami a dosiahol najlepšie výsledky.

Ortigosa a kol. [27] prezentovali klasifikáciu a detekciu zmeny sentimentu na množine dát získaných zo sociálnej siete Facebook.com. Autori použili slovníkový prístup a metódy strojového učenia. Vytvorili lexikón sentimentálnych slov založený na španielskom frameworku Linguistic Inquiry and Word Count (LIWC)¹ a vyhľadanie slangových slov. Na vyhodnotenie lexikónu použili rozhodovací strom C4.5, NB a SVM, ktoré klasifikovali 3 000 statusov (pozitívnych, neutrálnych a negatívnych). Klasifikátory dosiahli nasledujúce presnosti: C4.5 dosiahol 83.17%, NB dosiahol 83.13% a SVM dosiahol 83.27%.

V rámci SemEval workshopu bolo predstavených niekoľko prístupov, ktoré kombinujú slovníkový prístup a metódy strojového učenia. Tieto metódy využívajú jeden alebo viacero

slovníkov a výsledky analýzy textu pomocou týchto slovníkov tvoria súčasť vstupných atribútov použitých v prípade strojového učenia. V práci Mohammad a kol. [25] bolo použitých 5 existujúcich slovníkov (NRC slovník, MPQA lexikón, Bing a Liu lexikón a dva automaticky generované lexikóny) pre analýzu sentimentu. Z každého slovníka bolo vybratých niekoľko metrick (pozitívne a negatívne priemerné skóre, pozitívne a negatívne maximálne skóre, počet pozitívnych a negatívnych slov), ktoré boli použité ako súčasť vstupných atribútov pri učení modelu pomocou SVM. V práci Günter a Furrer [8] bol použitý SentiWordNet. Hodnoty jednotlivých slov zo slovníka a celková hodnota polarizácie príspevku získaná slovníkovou analýzou boli pridané ako dodatočné atribúty pre klasifikátor založený na stochastickom klesaní gradientu. AFINN-111 bol použitý ako súčasť klasifikátora v práci Proisl a kol. [30]. Kombinácia všetkých spomenutých slovníkov bola tiež aplikovaná v práci Miura a kol. [23].

D. Evolučné algoritmy v oblasti dolovania v textoch

Evolučné algoritmy sa svojou podstatou môžu uplatniť v dvoch kategóriách úloh v rámci dolovania v textoch a sentiment analýzy. Prvou je vytváranie nových atribútov pre jednotlivé klasifikátory používajúce metódy strojového učenia [7]. Tieto nové atribúty vznikajú kombinovaním už existujúcich atribútov tak, aby dosahovali lepšie výsledky. Druhý typ úloh, na ktoré sú evolučné algoritmy vhodné, a kde sa používajú, je selekcia vhodných, alebo najužitočnejších atribútov, ktoré sú použité pri vytváraní klasifikačných modelov pomocou metód strojového učenia [9], [3].

Evolučné algoritmy boli použité vo viacerých prácach venovaných dolovaniu z textov. V práci Escalante a kol. [7] autori použili genetické programovanie na úlohu klasifikácie textov. Zamerali sa na vytvorenie novej formy váhovania termov, ktorá by mohla zvýšiť presnosť klasifikácie textov. Genetický algoritmus sa učil ako spolu kombinovať už existujúce techniky váhovania slov a snažil sa vybrať tie techniky, ktoré boli najefektívnejšie.

PSO bola aplikovaná na vyhľadanie najužitočnejších atribútov v prácach Gupta a kol. [9] a Basari a kol. [3]. V práci Gupta a kol. boli atribúty vyselektované pomocou PSO použité ako vstupné atribúty do frameworku založeného na metóde podmienených náhodných polí. V práci Basari a kol. boli vyhľadávané najužitočnejšie atribúty, ktoré následne poskytovali vstupy pre metódu podporných vektorov.

III. ZÁKLADNÁ MYŠLIENKA PSO

Optimalizácia pomocou roja častíc (PSO - Particle Swarm Optimization) patrí k metódam prehľadávania priestoru, ktorá je podobná genetickým algoritmom (GA). Podobnosť s GA je založená na náhodnej inicializácii prvej generácie a následnej aktualizácii každej nasledujúcej generácie. Na rozdiel od genetických algoritmov, PSO nepoužíva genetické operátory. PSO má jednoduchú implementáciu, nemá veľa vstupných parametrov, je však náročnejšie na výkon pamäte a procesora. Jedince pri svojom pohybe zohľadňujú svoj pôvodný smer, svoju doposiaľ najlepšiu pozíciu a najlepšiu pozíciu

¹<http://liwc.wpengine.com/>

najlepšieho jedinca v populácii. Z tohto dôvodu je PSO schopné rýchlejšie konvergovať k optimálnemu riešeniu.

PSO je odvodená od spoločenských biologických systémov (húf rýb alebo krdel' vtákov), v ktorých sa skúma správanie jedincov, ktorí sú súčasťou populácie, ich vzájomné interakcie a interakcie s okolitým prostredím. PSO bola inšpirovaná krdľom vtákov hľadajúceho potravu. Predpokladá sa, že o potrave vedia iba niektoré vtáky, a preto sa ako najlepšia stratégia používa nasledovanie jedinca, ktorý je k potrave najbližšie. Každý jedinec v populácii predstavuje jedného vtáka a má svoju kvalitu (vhodnosť) v rámci prehľadávaného priestoru, ktorá je určená pomocou *fitness funkcie*. Okrem toho má každý jedinec svoju rýchlosť, ktorá zároveň udáva aj smer pohybu jedinca. Jedince sa pohybujú prehľadávaným priestorom, pričom sa snažia nasledovať najlepšieho jedinca v populácii. Hľadanie optimálneho riešenia sa uskutočňuje iteratívne (v generáciách), pričom každá generácia je optimalizovaná pomocou dvoch blízko optimálnych hodnôt:

- najlepšie riešenie pre daného jedinca p_{best} (particle best)
- najlepšie riešenie z celej populácie g_{best} (global best)

Po nájdení najlepších hodnôt p_{best} a g_{best} sa nová pozícia jedinca získa pomocou dvoch krokov:

- 1) zmena rýchlosti
- 2) zmena aktuálnej polohy

V prvom kroku sa upraví aktuálna rýchlosť a smer ak je to potrebné, pre každého jedinca tak, aby sa priblížil svojej najlepšej pozícii p_{best} a najlepšej pozícii celej populácie g_{best} . V druhom kroku sa následne upraví aktuálna poloha jedinca v priestore na základe pôvodnej polohy a novozískanej rýchlosti [13].

Každý jedinec je teda reprezentovaný ako vektor v D -dimenzionálnom priestore. Preto i -ty jedinec môže byť popísaný ako $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ vektor. Rýchlosť i -teho jedinca sa dá interpretovať ako $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ a najlepšia aktuálna pozícia ako $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$. Najlepšieho jedinca označíme ako g a w predstavuje zotrvačnosť. Tento parameter upravuje pomer medzi prehľadávaním v priestore a prehľadávacou schopnosťou jedinca prehľadať najbližšie okolie svojej najlepšej (p_{best}) pozície. Jeho hodnota sa pohybuje v rozmedzí $(0,1)$, pričom na začiatku sa môže zvoliť vyššia hodnota, aby bol prehľadaný väčší priestor. Rýchlosť a aktuálna poloha sú následne upravené pomocou vzťahov 1 a 2:

$$v_{id}^{n+1} = wv_{id}^n + c_1r_1^n(p_{id}^n - x_{id}^n) + c_2r_2^n(p_{gd}^n - x_{id}^n) \quad (1)$$

$$x_{id}^{n+1} = x_{id}^n + v_{id}^{n+1} \quad (2)$$

kde $d = 1, 2, \dots, D$ je počet dimenzií, $i = 1, 2, \dots, N$, je počet jedincov v populácii a $n = 1, 2, \dots$, predstavuje počet iterácií (generácií). Čísla r_1, r_2 predstavujú náhodne vygenerované čísla z intervalu $\langle 0,1 \rangle$ a predchádzajú pádu jedinca do lokálneho optima. Koeficienty c_1 and c_2 sa označujú ako učiace. Tieto koeficienty určujú, ako rýchlo sa bude jedinec

pohybovať vzhľadom k nájdenému extrému [5]. Ukončovacie kritérium môže byť stanovené pomocou minimálnej chyby, alebo kým nie je dosiahnutý maximálny počet generácií. Pri vytváraní PSO je tiež potrebné definovať, čo sa stane s jedincami, ktorí opustia priestor prehľadávania. Môžu sa vrátiť na pôvodnú pozíciu, alebo im náhodne vygenerovať novú pozíciu.

Myšlienkou analýzy trajektórií jednotlivých jedincov v priestore prehľadávania sa vo svojej práci zaoberal Kennedy [15]. Ten nastavil hodnoty p_{best} a g_{best} ako konštanty a sledoval, ako sa v priestore pohybujú jednotlivé jedince. Tieto trajektórie potom vykreslil a dostal histogram pripomínajúci Gaussovú krivku so stredom medzi p_{best} a g_{best} . Na základe toho usúdil, že trajektória jedinca môže byť vypočítaná ako rozdiel medzi p_{best} a g_{best} , a teda tieto hodnoty môžu vplyvať na pohyb jedincov v priestore. Na základe svojich výsledkov formuloval novú PSO metódu nazývanú **Bare-bones PSO**. Táto metóda používa na úpravu polohy jedincov Gaussové rozdelenie $\mathcal{N}(\mu, \sigma)$ so strednou hodnotou μ a rozptylom σ . Nová poloha jedinca je vypočítaná na základe vzťahu 3:

$$x_{id}^{t+1} = \begin{cases} \mathcal{N}(\mu, \sigma), & rand() < 0.5 \\ p_{id}^t, & otherwise \end{cases} \quad (3)$$

kde μ je stred medzi p_{best} a g_{best} a σ je absolútny rozdiel medzi p_{best} a g_{best} . $rand()$ funkcia sa používa na urýchlenie konvergencie k optimálnemu riešeniu tak, že sa aktuálna pozícia nastaví na poslednú známu p_{best} pozíciu.

IV. ANALÝZA NÁZOROV POMOCOU SLOVNÍKOV

Na analýzu názorov v slovesnom jazyku sme vytvorili dva slovníky, ktoré boli najskôr anotované manuálne.

Na generovanie prvého slovníka (tzv. veľkého slovníka) bol použitý anglický slovník dostupný v práci [12]. Pôvodný slovník obsahuje 6 789 sentimentálnych slov. Tie sú rozdelené primárne do dvoch kategórií, 2 006 pozitívnych a 4 783 negatívnych slov. Súčasťou slovníka je aj zoznam 13 slov otáčajúcich polaritu.

Náš slovník bol vytvorený prekladom originálneho slovníka. Každé slovo bolo manuálne preložené do slovenského jazyka a boli k nemu vyhľadané všetky synonymá a antonymá pomocou dostupných slovníkov. Všetky duplicitné slová boli odstránené. Slovenský slovník bol rozširovaný aj v priebehu výskumnej činnosti, kedy boli v textoch nachádzané slová, ktoré sú viac špecifické pre slovenský jazyk. Jedná sa najmä o slangové slová, vulgarizmy a nárečové slová. Súčasná verzia slovníka obsahuje 1 430 slov, z toho je 598 pozitívnych slov, 772 negatívnych slov, 41 intenzifikátorov a 19 negácií. Každému slovu v slovníku boli pridané aj jeho anglické ekvivalenty, ktoré boli získané pomocou tzv. "dvojitého prekladu". Dvojitý preklad je metóda, pri ktorej bolo slovo automaticky preložené zo slovenčiny do anglického jazyka a následne bolo automaticky preložené späť do slovenčiny. Ak malo slovo v slovenčine rovnaký význam pred a po preložení, bol jeho anglický ekvivalent pridaný do slovníka. Týmto sa zabránilo

prípadoch, keď boli pri automatickom preklade nájdené anglické formy slov, ktoré mali celkom odlišný význam, ako pôvodné slovo.

Hlavnou myšlienkou vytvorenia druhého (tzv. malého slovníka) bolo vytvorenie slovníka, ktorý bude síce menší, ale doménovo nezávislý. Problémom prvého slovníka bol výskyt doménovo závislých slov. Doménovo závislé slová sú slová, ktorých význam sa mení na základe kontextu, alebo toho, v akej doméne sa vyskytnú. Príkladom môže byť slovo *dlhý*, ktoré ak je použité v súvislosti s výdržou batérie: "Telefón vydrží na batériu fungovať dlho.", má pozitívny význam. Naopak, ak je použité v kontexte: "Film bol strašne dlhý.", má slovo *dlhý* negatívny význam. Malý slovník bol generovaný na základe analýzy šiestich už existujúcich anglických slovníkov, ktoré boli použité v prácach [12], [32], [6], [26], [24], [33]. Porovnanie jednotlivých slovníkov z pohľadu počtu slov je zobrazené v tabuľke I. Tieto slovníky boli použité na analýzu sentimentu v rôznych oblastiach. Taktiež boli jednotlivé slovníky vytvorené rôznymi spôsobmi, čo by malo zabezpečiť ich rozmanitosť a hlavne pokrytie veľkého množstva termov.

TABLE I
POROVNANIE SLOVNÍKOV, KTORÉ BOLI POUŽITÉ NA VYTVORENIE MALÉHO SLOVNÍKA

Slovník	pozitívne slová	negatívne slová	intenzif.	negácie
Hu and Liu slovník [12]	4 783	2 006	-	13
Taboada Lexicon [32]	2 535	4 039	219	-
SenticNet 4.0 [6]	27 405	22 595	-	-
AFINN [26]	878	1 598	-	-
Sentiment140 [24]	38 312	24 156	-	-
SentiStrength [33]	399	524	28	17

Malý slovník obsahuje 220 slov, z ktorých je 85 pozitívnych a 135 negatívnych. Intenzifikátory a negácie neboli pridané do slovníka z dôvodu, že sa nenachádzali vo všetkých originálnych slovníkoch.

A. Anotovanie slovníkov pomocou PSO

Vzhľadom na to, že manuálny spôsob anotovania sa ukázal ako nedostatočný, bolo implementované a otestované anotovanie pomocou optimalizačných algoritmov. V našom prípade sme použili optimalizáciu pomocou roja častíc (Particle Swarm Optimization - PSO), ktorá je bližšie popísaná v kapitole II-D. Obidva slovníky, veľký aj malý, boli anotované pomocou dvoch verzií PSO. Štandardná PSO metóda predstavuje robustný, jednoduchý, no zároveň efektívny optimalizačný algoritmus, ktorý bol použitý na vyriešenie veľkého množstva optimalizačných úloh. Na druhú stranu, Bare-Bones PSO (BBPSO) je upravená verzia štandardnej PSO, ktorá používa na výpočet polohy častíc Gaussove rozdelenie.

V rámci evolučného procesu predstavuje každý jedinec jednu verziu slovníka, ktorá môže byť potenciálnym riešením. Tento jedinec môže byť reprezentovaný v tvare vektora $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$, kde $x_{ij} \in \{-3, 3\}$, pričom rozsah

je určený rozsahom hodnôt, ktoré chceme slovám priradiť, $i = 1, 2, \dots, N$, kde N predstavuje počet jedincov v populácii a $j = 1, 2, \dots, D$, kde D predstavuje počet slov v slovníku. Veľkosť jedinca (dĺžka vektora) závisí na počte slov v slovníku. Z toho vyplýva, že jedinci reprezentujúci veľký slovník budú mať veľkosť 1 370 a jedinci reprezentujúci malý slovník budú mať veľkosť 220. Z veľkého slovníka boli do úvahy brané iba pozitívne a negatívne slová, keďže anotovanie intenzifikátorov a negácie funguje na inom princípe. Proces, akým boli jednotlivé slovníky anotované je možné vidieť na obrázku 1.

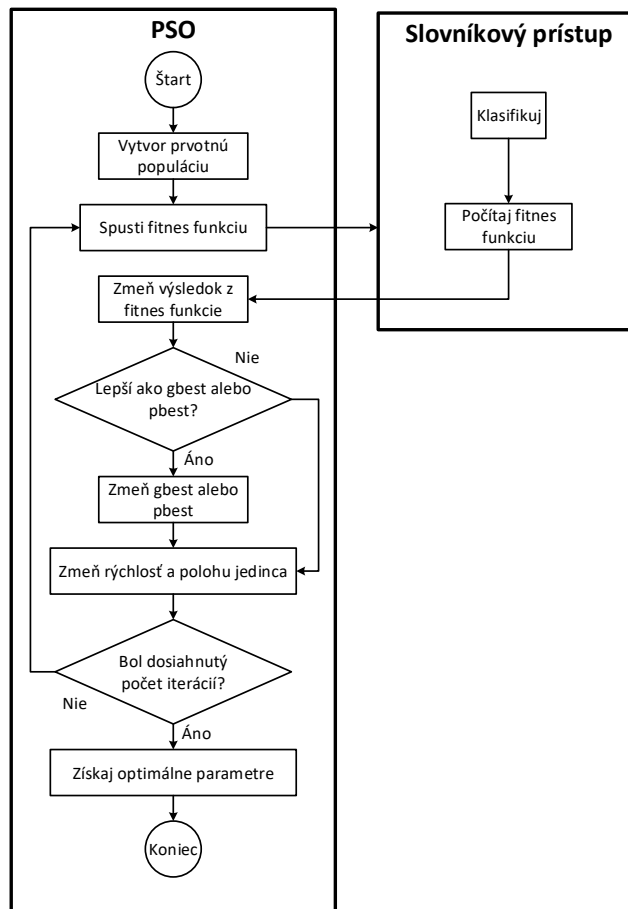


Fig. 1. Celkový pohľad na použitie evolučného algoritmu na anotovanie slovníka

Hlavnou myšlienkou pre použitie PSO je priamo generovať silu polaritu pre každé slovo v slovníku. Preto každý jedinec reprezentuje jedno potenciálne riešenie, ktoré je reprezentované D -dimenzionálnym vektorom. Tento vektor má rovnakú dĺžku ako je počet slov v slovníku. Prvá generácia je vygenerovaná náhodne a na túto prvú generáciu je aplikovaná fitness funkcia, ktorá má za úlohu vypočítať kvalitu tejto populácie. Fitness funkcia vyhodnotí kvalitu každého jedinca a nastaví túto polohu ako počiatočné *pbest*. Najkvalitnejší jedinec z prvej generácie je nastavený ako *gbest*. Následne je vypočítaná nová rýchlosť jedinca na základe jeho predchádzajúcej rýchlosti,

jeho najlepšej polohy a najlepšej polohy v celej populácii podľa vzorca 1. V závislosti na novej rýchlosti je upravená nová poloha jedinca podľa vzorca 2. Celý tento proces sa opakuje, kým nedôjde k naplneniu nastaveného počtu iterácií.

B. Anotovanie slovníkov pomocou BBPSO

Hlavnou myšlienkou pre použitie BBPSO je tiež priamo generovať silu polarity pre každé slovo v slovníku. Na rozdiel od PSO používa táto metóda hodnoty $pbest$ a $gbest$ na výpočet strednej hodnoty a rozptylu, pomocou ktorých je vypočítaná nová poloha jedinca v priestore. BBPSO opäť náhodne vygeneruje prvú generáciu jedincov. Kvalita týchto jedincov je vyhodnotená pomocou fitness funkcie a pre každého jedinca je nastavená $pbest$ poloha. Následne je nastavená aj najlepšia $gbest$ poloha z celej populácie. Na výpočet novej polohy v priestore používa BBPSO Gaussovú distribúciu $\mathcal{N}(\mu, \sigma)$ so strednou hodnotou μ a rozptylom σ . Nová poloha jedinca je vypočítaná na základe vzťahu 3. Stredná hodnota a rozptyl sú vypočítané na základe vzorcov 4 a 5:

$$\mu_{id} = \frac{(gbest_d + pbest_{id})}{2} \quad (4)$$

$$\sigma_{id} = |gbest_d - pbest_{id}| \quad (5)$$

kde $i = 1, 2, \dots, N$, N predstavuje počet jedincov v populácii a $d = 1, 2, \dots, D$, D predstavuje počet slov v slovníku.

Po upravení polohy jedinca je vyhodnotená jeho kvalita a v prípade potreby sú polohy $pbest$ a $gbest$ zmenené. Celý tento proces sa opakuje, kým nedôjde k naplneniu dopredu nastaveného počtu iterácií.

Veľmi dôležitou súčasťou evolučných algoritmov je fitness funkcia. Fitness funkcia slúži na vyhodnocovanie kvality jednotlivých jedincov. Výsledok tejto funkcie hovorí o tom, ako blízko/d'aleko sa aktuálna populácia nachádza od optimálneho riešenia. Fitness funkcia má významný dopad na rýchlosť, akou sa evolučný algoritmus približuje k optimálnemu riešeniu, lebo táto funkcia sa iteratívne vyhodnocuje naprieč všetkými jedincami v populácii. Pri vyberaní vhodnej funkcie je preto nutné zohľadniť viacero faktorov, ako sú napríklad:

noitemsep

- výpočtový čas potrebný na výpočet jedného jedinca
- presnosť, ktorú môže konkrétna funkcia dosiahnuť
- zašumenie a neistota, s ktorou konkrétna funkcia pracuje

C. Analýza názorov použitím slovníkového prístupu

V rámci práce na analýze názorov pomocou slovníkového prístupu v slovenskom jazyku bolo vytvorených a otestovaných niekoľko algoritmov. Tieto algoritmy boli postupne upravované a vylepšované, pričom sme začali od najjednoduchších, ktoré určovali polaritu iba na základe sumovania pozitívnych a negatívnych slov, cez komplexnejšie algoritmy, ktoré implementovali dodatočnú analýzu slov pomocou intenzifikátorov a negácie, alebo poskytovali dodatočné informácie ako napr. analýzu tém, až po najzložitejšie algoritmy, ktoré kombinovali implementáciu viacerých prístupov do jedného.

Ako prvé sme vytvorili algoritmus na klasifikáciu názorov, obsahujúci viacero dodatočných funkcií, ako napríklad intenzifikácia a negácia pozitívnych a negatívnych slov. Algoritmus na klasifikovanie názorov pracuje v niekoľkých krokoch. Najskôr je analyzovaný text rozdelený na vety a na slová. Algoritmus prechádza text slovo po slove a vyhladáva jednotlivé slová v slovníku. Ak sa slovo nachádza v slovníku, sila jeho polarity sa použije na to, aby sa upravila polarita vety a následne celková polarita príspevku. Pred tým ako sa polarita slova použije na zmenu polarity vety, sú na konkrétne slovo aplikované ďalšie funkcie. V algoritme je implementovaná intenzifikácia pomocou percent a switch negácia. Existujú dva typy, implementácie intenzifikácie. Jednou možnosťou je zvyšovanie základnej polarity o jednu minimálnu hodnotu polarity z danej stupnice. Napr. ak máme stupnicu od -3 po 3 s krokom 1, môže byť intenzifikácia implementovaná tak, že pozitívna intenzifikácia bude zvyšovať základnú polaritu slova o +1 a negatívna intenzifikácia bude znižovať základnú polaritu slova o -1. Tento spôsob však nezohľadňuje široké spektrum, v ktorom sú intenzifikátory používané. Preto sme sa rozhodli použiť druhý spôsob intenzifikácie slov pomocou percent. Príkladom tohto použitia môžu byť slová ako *extrémne* a *celkom*. Spojením týchto slov so slovom *dobry* môžeme vidieť, že kombinácia *extrémne dobry* má silnejší pozitívny náboj ako *celkom dobry*. Slová označené ako intenzifikátory teda majú hodnotu polarity od 1.00 do 2.00, kde napr. hodnota 1.50 znamená 50% posilnenie základnej polarity analyzovaného slova. Tento spôsob intenzifikácie umožňuje výraznejšie zvýšenie polarity pri silno polaritných slovách v porovnaní so slovami, ktorých polarita je nižšia. Druhou funkciou, ktorá bola do algoritmu implementovaná, je negácia. Negácia je v tomto prípade reprezentovaná vo forme *switch negácie*. Tento typ negácie priamo otáča polaritu pozitívneho alebo negatívneho slova nachádzajúceho sa bezprostredne za negáciou na opačnú hodnotu s rovnakou silou. Ak sa teda v texte vyskytne dvojnásobná negácia, pôvodná orientácia slova ostane zachovaná. Takto implementovaný algoritmus pre výpočet polarity vety nám umožnil spracovanie takých prípadov, ako je viacnásobná intenzifikácia alebo negácia a intenzifikácia negácie. Výpočet polarity celej vety s prebieha podľa vzorca 6.

$$P_s = \sum P_w \prod P_i \prod P_n \quad (6)$$

kde:

P_s - je polarita vety s

P_w - polarita slova w

$\prod P_i$ - multiplikácia síl polarít všetkých intenzifikátorov pred slovom

$\prod P_n$ - multiplikácia síl polarít všetkých negácií pred slovom

Tento prístup bol otestovaný na datasete zloženom z príspevkov hodnotiacich filmy *Forrest Gump* a *Zelená míľa*. Tento dataset bol manuálne vyhodnotený. Má rozsah 2 749 príspevkov, z toho obsahuje 2 330 pozitívnych príspevkov, iba 241 neutrálnych a 178 negatívnych príspevkov. Celkovo

tento dataset obsahuje 158 519 slov. Dosiahnuté výsledky sú zobrazené v tabuľke II.

TABLE II

DOSIAHNUTÁ PRESNOŠŤ, NÁVRATNOŠŤ A F1-MIERA NA DATASETE OBSAHUJÚCOM PRÍSPEVKY O FILMOCH FORREST GUMP A ZELENÁ MÍL'A

	presnosť	návratnosť	F1-miera
pozitívne príspevky	0.929	0.875	0.901
negatívne príspevky	0.43	0.406	0.417
neutrálne príspevky	0.393	0.644	0.488

Ďalej bol tento prístup otestovaný aj na všeobecnom datasete, ktorý obsahuje 5 242 manuálne anotovaných príspevkov rozdelených do dvoch skupín - pozitívne príspevky a negatívne príspevky. Príspevky v datasete pochádzajú z viacerých webových stránok a reagujú na širokú škálu tém ako napr. knihy, hotely, telefóny, počítače a politika. Celkovo tento dataset obsahuje 155 522 slov. Výsledky sú zobrazené v tabuľke III.

TABLE III

DOSIAHNUTÁ PRESNOŠŤ, NÁVRATNOŠŤ A F1-MIERA NA PRÍSPEVKOCH ZO VŠEOBECNÉHO DATASETU

	presnosť	návratnosť	F1-miera
pozitívne príspevky	0.561	0.802	0.66
negatívne príspevky	0.675	0.396	0.499

Z tabuľky III je možné vidieť, celkom dobrú návratnosť, ktorú sme dosiahli pre pozitívne príspevky. Naopak návratnosť pre negatívne príspevky je dosť nízka, čo mohlo byť spôsobené častejším používaním ironie a sarkazmu.

V ďalšej práci sme sa hlbšie zaoberali spôsobom, akým bola v našom prístupe ku klasifikácii názorov implementovaná negácia. Vo všeobecnosti existujú dva typy negácie, ktoré sa bežne používajú:

- switch negácia (negácia otočením) - priamo otáča polaritu slova na opačnú hodnotu s rovnakou silou
- shift negácia (negácia posunom) - posúva hodnotu sily polaritu smerom k opačnej hodnote o pevne stanovenú sumu

Problémom switch negácie je to, že nie vždy je schopná dostatočne dobre zmeniť polaritu negovaného slova. Vhodným príkladom môže byť spracovanie slovného spojenia *nebol najlepší* pomocou switch negácie. Slovo *najlepší* so silou polarity +3 je negované na opačnú silu polaritu s rovnakou hodnotou \rightarrow (-3). Negáciou tohto slovného spojenia vzniklo slovné spojenie s maximálnou negatívnou polaritou, ktoré môže byť ekvivalentné slovu *najhorší*, ktoré nie je úplne porovnateľné so slovným spojením *nebol najlepší*. Preto sme sa rozhodli implementovať oba typy negácie a porovnať ich navzájom, aby sme overili, ktorý typ je pre náš prístup najvhodnejší. Aby mohli byť jednotlivé typy negácie porovnané, boli vytvorené štyri verzie algoritmu na klasifikovanie názorov.

Prvá verzia používala na získanie polaritu príspevku sumovanie polarít jednotlivých slov vo vete a nebrala do úvahy spracovanie negácie. Táto verzia bola zároveň určená

ako východiskový bod pre ďalšie experimenty. Druhá verzia implementovala switch negáciu.

Do tretej verzie bolo pridané spracovanie negácie pomocou shift negácie. Tento typ negácie posúva silu polaritu negovaného slova o presne stanovenú hodnotu smerom k opačnému pólu polaritu. Experimentálne bol posun v prípade použitia shift negácie stanovený na hodnotu +/-2. Ak sa teda jednalo o negáciu pozitívneho slova, jeho sila polaritu sa posunula o 2 body smerom k negatívnej polarite a ak bola spracovaná negácia negatívneho slova, jeho sila polaritu sa posunula o 2 body smerom k pozitívnej polarite. V prípade, že bolo potrebné spracovať viacnásobnú negáciu, bola hodnota polaritu vždy posunutá o 2 body smerom k opačnému spektru polaritu. Zároveň sa po každom posunutí overovalo, či negácia slova nepresiahla hraničné hodnoty, ktoré boli nastavené v rozmedzí od -3 do 3.

Štvrtá verzia bola vytvorená skombinovaním oboch typov negácie: switch a shift negácie. Spôsob, akým bola negácia aktuálne spracovávaného slova spracovaná, závisel na sile polaritu konkrétneho slova. V prípadoch, že slovo malo základnú silu polaritu +/-1 a +/-2, bola použitá switch negácia. Ak základná sila polaritu aktuálneho slova bola +/-3, bola použitá shift negácia. Pri viacnásobnej negácii záležalo na negovanom slove, či sa viackrát použije switch negácia alebo shift negácia, pričom pri použití shift negácie sa opäť overovali intervaly, do ktorých sa negácia musela zmestiť. Shift negácia bola použitá aj v prípade, že bolo aktuálne slovo intenzifikované. Ak bola sila intenzifikácie väčšia ako 1 (slovo bolo intenzifikované), bola shift negácia použitá bez ohľadu na to, akú silu polaritu malo aktuálne spracovávané slovo.

Tie prístupy boli opäť testované na všeobecnom datasete a získané výsledky sú spísané v tabuľke IV.

TABLE IV

POROVNANIE PRESNOŠTI, NÁVRATNOŠTI A MAKRO F1-MIERY PRI IMPLEMENTÁCIÍ RÔZNYCH SPÔSOBOV NEGÁCIE

prístup	presnosť		návratnosť		makro F1
	poz.	neg.	poz.	neg.	
iba poz. a neg. slová	0.569	0.7	0.821	0.402	0.591
switch negácia	0.57	0.693	0.812	0.41	0.593
shift negácia	0.569	0.697	0.82	0.401	0.59
kombinácia oboch negácií	0.586	0.7	0.847	0.41	0.605

Aj na tomto datasete sa ukázalo, že pridanie switch negácie malo podobný efekt ako v predchádzajúcich experimentoch. Spracovaním negácie pomocou switch negácie sa mierne zlepšili výsledky presnosti pre pozitívne príspevky a návratnosti pre negatívne príspevky. Rovnako sa zhoršila návratnosť pre pozitívne príspevky a presnosť pre negatívne príspevky. Zaujímavé výsledky dosiahlo použitie shift negácie, ktoré malo na celkové výsledky iba minimálny vplyv. Ako najlepšie sa ukázalo riešenie kombinujúce obidva spomenuté typy negácie. Kombinácia switch a shift negácie, tak ako je popísaná v texte, dosiahla výrazne lepšie výsledky pri klasifikácii pozitívnych príspevkov, pričom si zachovala porovnateľné výsledky pri klasifikácii negatívnych príspevkov.

Zároveň sme výsledky našich experimentov porovnali s výsledkami získanými v práci Taboada a kol. [32]. V tejto práci tiež boli použité obidve formy spracovania negácie: switch aj shift negácia. Porovnanie jednotlivých výsledkov môže byť iba približné vzhľadom k tomu, že algoritmy na spracovanie negácie v práci Taboada a kol. sú aplikované na anglický jazyk a naša práca je zameraná na slovenský jazyk. Každý z týchto jazykov má svoje špecifiká, a preto je priame porovnanie dosť náročné. Výsledky sú zobrazené v tabuľke V.

TABLE V
POROVNANIE CELKOVEJ PRESNOSTI MEDZI PODOBNÝMI PRÍSTUPMI K
SPRACOVANIU NEGÁCIE V SLOVENČINE A ANGLIČTINE

prístup	celková presnosť
Taboada (switch)	0.784
Taboada (shift)	0.714
naš prístup (switch)	0.607
naš prístup (shift)	0.606
naš prístup (kombinovaný)	0.61

Z výsledkov je možné vidieť rozdiel v presnosti klasifikácie v slovenskom a anglickom jazyku. Vyššia presnosť klasifikácie môže byť spôsobená aj tým, že spracovanie negácie je v anglickom jazyku jednoduchšie ako v slovenskom jazyku. Aj preto nie je priame porovnanie veľmi vhodné a jedná sa len o približné porovnanie, s možnosťou hľadania podobných trendov. Na druhú stranu, aj napriek tomu, že obidva prístupy boli použité v rôznych jazykoch, vykazujú podobné trendy. Z výsledkov sa dá vyčítať, že použitie shift negácie zhoršilo presnosť klasifikácie v porovnaní s použitím switch negácie.

V našej ďalšej práci sme sa venovali možnostiam rozšírenia slovníkového prístupu o metódy, ktoré by mohli zlepšiť presnosť klasifikácie názorov. Vzhľadom na problém, ktorý sa objavil v predchádzajúcich experimentoch, keď ľudia namiesto hodnotenia filmu opisovali jeho dej, sme sa rozhodli implementovať identifikáciu tém do algoritmu na klasifikáciu názorov. V týchto prácach sme rozvinuli myšlienku zvýšenia vplyvu tých viet, ktoré sa venujú téme, o ktorej je celá diskusia. Polarita týchto viet je oproti ostatným vetám upravená pomocou váh. Tieto váhy by mali zvýšiť dôležitosť viet venujúcich sa témam, ktorými sa príspevky zaoberajú.

Na nájdenie tém, o ktorých sa v datase rozprávalo, sme použili dva typy prístupov. Jednou z testovaných metód bola Latentná dirichletová alokácia (Latent Dirichlet Allocation - LDA). Táto metóda je štandardne používaná v oblasti identifikácie tém, preto sme sa ju rozhodli implementovať a otestovať v našom prístupe ku klasifikácii názorov. LDA je pravdepodobnostná metóda, ktorá je založená na tom, že pravdepodobnosti slov identifikujúcich tému a pravdepodobnosti tém pre každý dokument majú Dirichletovo rozdelenie. Na vstupe si táto metóda berie súbor dokumentov a vopred určený počet tém, ku ktorým tieto dokumenty patria. Na výstupe potom dostávame zoznam slov, ich relevanciu ku konkrétnej téme a zoznam dokumentov s ich relevanciou k téme. V našom prípade sme pomocou LDA vygenerovali zoznam 50 slov, ktoré boli najviac relevantné ku konkrétnym témam. Tento zoznam ďalej prešiel filtrovaním, počas ktorého boli zo

zoznamu odstránené neplnovýznamové slová, predložky, slová s polaritou a ostatné slová obsiahnuté s slovníku na analýzu sentimentu. Výsledný zoznam obsahoval 15 relevantných slov k daným témam.

Druhým spôsobom, ktorý sme použili na identifikáciu tém, bola analýza slov na základe termovej frekvencie slov v dokumente. Predpokladom použitia tejto metódy bol fakt, že témy ku ktorým sa príspevky v datase vzťahujú, by sa mali v texte vyskytovať častejšie, ako ostatné informácie. Miernou nevýhodou tejto metódy je fakt, že aj *stop slová* sa v texte vyskytujú s vyššou frekvenciou ako ostatné slová. Stop slová sú slová, ktoré nemajú význam pri analyzovaní textu. Môže sa jednáť o spojky, predložky, častice alebo niektoré neplnovýznamové slová. Z tohto dôvodu bol vytvorený zoznam stop slov, ktorý bol použitý na odstránenie uvedených slov z textu. Tento zoznam stop slov bol vytvorený na základe zoznamu stop slov poskytnutého spoločnosťou Google a bol rozšírený o ďalšie slová špecifické pre slovenský jazyk. Texty príspevkov z datase boli najskôr predspracované pomocou algoritmu na odstránenie stop slov a následne bol na ne použitý algoritmus, ktorý vytvoril zoznam najčastejšie sa vyskytujúcich slov. Zoznam tématických slov bol, podobne ako v predchádzajúcom prípade, dodatočne očistený od názorových slov. Z výsledného zoznamu bolo vybratých 5% najfrekvencovanejších slov, ktoré určili témy, o ktorých sa v datase rozpráva.

Na overenie kvality tohto riešenia bola použitá upravená verzia algoritmu na klasifikovanie názorov. Základ algoritmu vychádza zo slovníkového prístupu popísaného v predchádzajúcich kapitolách práce. Algoritmus spracuje a vyhodnotí polaritu jednotlivých slov a následne aj polaritu celej vety. Po tom, ako je získaná polarita celej vety, dôjde k overeniu, či konkrétna veta obsahuje slová k téme, ktorá bola identifikovaná pomocou algoritmu na identifikáciu tém. Ak sa veta týkala nájdenej témy, polarita vety bola vynásobená hodnotou 1.5.

Hodnota 1.5 bola získaná experimentálne. Aby bola vybraná vhodná hodnota, o ktorú sa bude polarita vety meniť, vykonali sme niekoľko experimentov s tromi rôznymi hodnotami: 1.5, 2 a 3. Jedenaplnásobná zmena polarit dosiahla najlepšie výsledky, a preto bola vybraná ako najvhodnejšia. Dvojnásobná a trojnásobná zmena polarit zaznamenali jemné zhoršenia kvality dosiahnutých výsledkov. Výsledky experimentov zaoberajúcich sa výberom najvhodnejšej hodnoty na úpravu polarit vety sú zobrazené v tabuľke VI.

TABLE VI
VYHODNOTENIE PRESNOSTI, NÁVRATNOSTI A MAKRO F1-MIERY
ZÍSKANÝCH ZMENOU HODNOTY, O KTORÚ BOLA UPRAVENÁ POLARITA
VETY OBSAHUJÚCEJ SLOVO POPISUJÚCE TÉMU

	presnosť (%)		návratnosť (%)		makro F1
	poz.	neg.	poz.	neg.	
váha, ktorou je násobená veta					
váha 1.5	0.605	0.792	0.878	0.448	0.644
váha 2	0.599	0.779	0.871	0.439	0.636
váha 3	0.597	0.77	0.865	0.437	0.632

Obidve metódy na identifikáciu tém boli testované a ich výsledky boli porovnané s algoritmom na klasifikáciu názorov, ktorý žiadne úpravy nerobil. Výsledky sú zaznamenané v tabuľkách VII a VIII. Experimenty vyhodnotené v tabuľke VII boli vykonané na príspevkoch zo všeobecného datasetu, ktoré sa venovali iba filmovej oblasti. Zároveň bola na identifikáciu tém v týchto experimentoch použitá metóda LDA.

TABLE VII

POROVNANIE PRESNOSTI A NÁVRATNOSTI MEDZI PRÍSTUPOM KU KLASIFIKÁCIÍ NÁZOROV VYUŽÍVAJÚCIM IDENTIFIKÁCIU TÉM (IT) POMOCOU LDA A PRÍSTUPOM, KTORÝ IDENTIFIKÁCIU TÉM NEPOUŽÍVAL

prístup	presnosť		návratnosť		makro F1
	poz.	neg.	poz.	neg.	
bez IT	0.68	0.75	0.90	0.41	0.652
s použitím IT	0.69	0.78	0.91	0.43	0.67

Experimenty vyhodnotené v tabuľke VIII boli vykonané na všetkých príspevkoch zo všeobecného datasetu a na identifikáciu tém bola použitá frekvencia slov nachádzajúcich sa v datasete.

TABLE VIII

POROVNANIE PRESNOSTI A NÁVRATNOSTI MEDZI PRÍSTUPOM KU KLASIFIKÁCIÍ NÁZOROV VYUŽÍVAJÚCIM IDENTIFIKÁCIU TÉM (IT) POMOCOU TERMOVEJ FREKVENCIE A PRÍSTUPOM, KTORÝ IDENTIFIKÁCIU TÉM NEPOUŽÍVA

prístup	presnosť (%)		návratnosť (%)		makro F1
	poz.	neg.	poz.	neg.	
bez IT	0.60	0.78	0.87	0.442	0.637
s použitím IT	0.605	0.792	0.878	0.448	0.644

Výsledky experimentov ukazujú, že implementácia identifikácie tém zlepšila presnosť a návratnosť klasifikácie názorov. Identifikácia tém pomocou LDA metódy dosiahla mierne lepšie výsledky ako metóda identifikácie tém pomocou termovej frekvencie. Výraznejšie sa zmenili najmä hodnoty pre negatívne príspevky, čo znamená, že sa ľudia negatívnejšie vyjadrovali k témam ako celkom. Negatívne vyjadrenie sa snažili kompenzovať pozitívnejšími vyjadreniami na menej podstatné aspekty, čím znížili presnosť klasifikácie v prípade, že identifikácia tém použitá nebola.

D. Kombinovaný prístup k analýze názorov

V našom výskume sme sa rozhodli reagovať aj na prípady, keď slovníkový prístup nebol schopný klasifikovať príspevky v datasete, lebo neobsahoval slová vyjadrujúce polaritu z daného príspevku. Na vyriešenie tohto problému sme vytvorili a implementovali tzv. "kombinovaný prístup", ktorý spája slovníkový prístup a metódu strojového učenia. Hlavnou myšlienkou kombinovaného prístupu je, použitie slovníkového prístupu na to, aby klasifikoval jednotlivé príspevky v datasete. Tieto príspevky sú následne rozdelené na príspevky, ktoré sa pomocou slovníka podarilo klasifikovať do jednej z tried (pozitívnej alebo negatívnej) a na ostatné príspevky, ktoré klasifikované neboli. Klasifikované príspevky sú následne použité

ako trénovacia množina pre algoritmus strojového učenia. Ten na základe klasifikovaných príspevkov vytvorí klasifikačný model, ktorý je použitý na príspevky, ktoré nebolo možné pomocou slovníkového prístupu klasifikovať. Model by mal byť schopný nájsť ďalšie slová nesúce polaritu, ktoré ale nie sú zahrnuté v slovníku. Uvedený prístup by mohol byť v budúcnosti použitý na rozširovanie a zlepšovanie slovníka. Medzi výhody kombinovaného prístupu tiež možno zahrnúť fakt, že nevyžaduje anotovaný dataset na to, aby naučil metódu strojového učenia. Trénovací dataset je vytvorený za behu a to práve za pomoci slovníkového prístupu. Otvárajú sa tak možnosti na využitie tohto prístupu v prípadoch, že nie je možné získať dataset anotovaných príspevkov. Jednou z takýchto aplikácií je práve aktívne učenie, pri ktorom sa strojové učenie preuča za behu v prípade, že je náročné získať anotovanú množinu novoprichádzajúcich dokumentov.

Kombinovaný prístup sa skladá z dvoch častí. V prvej časti je použitý štandardný slovníkový prístup popísaný vyššie. Ten v sebe implementuje viacero funkcií, napríklad spracovanie intenzifikácie a kombinovanej negácie. Ako bolo spomenuté, nevýhoda slovníkového prístupu spočíva v tom, že nie je schopný klasifikovať príspevky, ktoré neobsahujú slová zo slovníka, čo má za následok rapídne zníženie presnosti a návratnosti klasifikácie. To potvrdzujú aj výsledky experimentov, keď sme porovnali výsledky slovníkového prístupu dosiahnuté na celom datasete a výsledky dosiahnuté na príspevkoch obsahujúcich aspoň jedno slovo zo slovníka. Tieto výsledky sú zobrazené v tabuľke IX. Ako dataset bol použitý všeobecný dataset.

TABLE IX

POROVNANIE VÝSLEDKOV SLOVNÍKOVÉHO PRÍSTUPU (SP) NA CELOM DATASETE A NA ČASTI DATASETU, V KTOREJ KAŽDÝ PRÍSPEVKOV OBSAHUJE ASPOŇ JEDNO SLOVO ZO SLOVNÍKA

Prístup	F1(+)	F1(-)	makro-F1
výsledky SP na celom datasete (5242 príspevkov)	0.742	0.645	0.694
výsledky SP na príspevkoch obsahujúcich polaritné slová (4266 príspevkov)	0.89	0.824	0.857

Porovnanie ukázalo, že nami vytvorený slovník je schopný klasifikovať iba 4 266, čo predstavuje približne 81.4% z celkového počtu 5 242 príspevkov. Na druhú stranu sa ukázalo, že slovníkový prístup dosahuje oveľa lepšie výsledky ako boli dosiahnuté doteraz. Horšie výsledky boli dosiahnuté tým, že príspevky, ktoré nebolo možné klasifikovať, boli započítané ako chybné klasifikované príspevky, a teda výrazne ovplyvili a zhoršili celkovú kvalitu predstaveného riešenia.

V druhej časti je implementovaná metóda strojového učenia tak, aby bol kombinovaný prístup schopný spracovať dokumenty, ktoré nie je možné spracovať samostatným slovníkovým prístupom. Pred tým, ako je použitá metóda strojového učenia, je potrebné vytvoriť trénovaciu množinu z príspevkov, ktoré boli klasifikované pomocou slovníka. Klasifikované príspevky sú rozdelené na pozitívne a negatívne. Obidve skupiny príspevkov sú zo-

radené od najviac pozitívneho/negatívneho po najmenej pozitívny/negatívny. Následne sú obidve skupiny porovnané z hľadiska počtu príspevkov. Do trénovacej množiny sú vybraté všetky príspevky z menšej skupiny a ekvivalentné množstvo z väčšej skupiny. Týmto sa vytvorí vybalancovaná trénovacia množina, čo je veľmi dôležité hlavne preto, aby model naučený strojovým učením nepreferoval pozitívnu alebo negatívnu polaritu.

Ako metóda strojového učenia bola vybraná metóda Naïvného Bayesovho (NB) klasifikátora. Napriek tomu, že sa jedná o pomerne jednoduchý pravdepodobnostný klasifikátor, dosahuje pomerne dobré výsledky v oblasti klasifikácie sentimentu. NB klasifikátor vytvorí model, ktorý je postavený na pravdepodobnosti, že dané slovo patrí do pozitívnej alebo negatívnej triedy. Táto pravdepodobnosť je vypočítaná ako pomer frekvencie výskytu slova v jednej z tried a frekvencie výskytu v celom datasete. Na získanie pravdepodobnosti, že slovo w patrí do triedy c bola použitá rovnica 7:

$$P(w_c) = \frac{w_c}{w} \quad (7)$$

kde:

$P(w_c)$ - pravdepodobnosť, že slovo w je z triedy c

w_c - počet výskytov slova w v triede c

w - počet výskytov slova w v celom datasete

V prípade, že by pravdepodobnosť výskytu slova v jednej z tried mala byť nulová, bude nulová pravdepodobnosť nahradená veľmi malým číslom.

Vypočítaná pravdepodobnosť pre jednotlivé slová je použitá na výpočet pravdepodobnosti, či veta a neskôr celý príspevok patria do pozitívnej alebo negatívnej triedy. Na určenie, do ktorej triedy zaradiť vetu s sa používa rovnica 8. Podobne pomocou rovnice 9 je určená aj pravdepodobnosť, že príspevok r patrí do pozitívnej alebo negatívnej triedy.

$$P(s_c) = \frac{\sum P(w_c)}{\sum w} \quad (8)$$

kde:

$P(s_c)$ - pravdepodobnosť, že veta s patrí do triedy c

$\sum P(w_c)$ - sumovaná pravdepodobnosť, že slová w z vety patria do triedy c

$\sum w$ - počet slov vo vete

$$P(r_c) = \frac{\sum P(s_c)}{\sum s} \quad (9)$$

kde:

$P(s_c)$ - pravdepodobnosť, že príspevok r patrí do triedy c

$\sum P(w_c)$ - sumovaná pravdepodobnosť, že vety s z príspevku patria do triedy c

$\sum w$ - počet viet v príspevku

Pre každý príspevok potom platí, že patrí do tej triedy, pre ktorú má väčšiu pravdepodobnosť. Ak je pravdepodobnosť, že

príspevok patrí do pozitívnej triedy väčšia ako pravdepodobnosť, že patrí do negatívnej triedy, je príspevok označený ako pozitívny a naopak.

Prezentovaný kombinovaný prístup bol otestovaný na dvoch datasetoch. Všeobecný dataset bol použitý na overenie kvality predstaveného riešenia a filmový dataset bol použitý na to, aby sme mohli porovnať kombinovaný prístup s inými prístupmi používajúcimi anglickú verziu tohto datasetu. Filmový dataset obsahuje 2 000 príspevkov, rozdelených na 1000 pozitívnych a 1000 negatívnych príspevkov, a celkovo 1 135 938 slov. Výsledky sú zobrazené v tabuľke X.

TABLE X
POROVNANIE VÝSLEDKOV KLASIFIKÁCIE NÁZOROV POMOCOU SLOVNÍKOVÉHO PRÍSTUPU (SP) A KOMBINOVANÉHO PRÍSTUPU (KP) NA VŠEOBECNOM A FILMOVOM DATASETE

prístup	F1(+)	F1(-)	makro-F1
SP použitý na všeobecnom datasete	0.742	0.645	0.694
KP použitý na všeobecnom datasete	0.872	0.863	0.868
SP použitý na filmovom datasete	0.727	0.611	0.669
KP použitý na filmovom datasete	0.741	0.599	0.670

Dosiahnuté výsledky ukazujú, že neklasifikované príspevky výrazne znížili presnosť klasifikácie. Použitím kombinovaného prístupu sa zlepšili výsledky na oboch datasetoch. Kombinovaný prístup dokázal na všeobecnom datasete znížiť počet neklasifikovaných príspevkov z 976 na 16, čo predstavuje zníženie z 18% na 0.3%. Zároveň sa však ukázal zaujímavý fakt, keď NB klasifikátor dokázal opraviť triedu, do ktorej bol príspevok nesprávne zaradený pomocou slovníkového prístupu. Filmový dataset bol použitý na porovnanie našich prístupov s metódami použitými v iných prácach. Naše prístupy sme porovnali so slovníkovým prístupom popísaným v práci Taboada a kol. [32]. Ich metóda dosiahla presnosť v rozmedzí od 68.05% do 76.37%, ktorá bola získaná pridávaním rôznych funkcií do slovníkového prístupu.

Kombinovaný prístup sme zároveň porovnali s ďalšími bežne používanými prístupmi na klasifikáciu názorov. Do porovnania sme zahrnuli Naïvný Bayesov (NB) klasifikátor a metódu podporných vektorov (SVM). Tieto metódy boli testované pomocou dataminingového nástroja RapidMiner² a bola pri nich použitá 10-násobná krížová validácia. Výsledky sú zobrazené v tabuľke XI.

TABLE XI
POROVNANIE SLOVNÍKOVÉHO A KOMBINOVANÉHO PRÍSTUPU KU KLASIFIKÁCIÍ NÁZOROV S NB KLASIFIKÁTOROM A SVM

prístup	F1(+)	F1(-)	makro-F1
slovníkový prístup	0.742	0.645	0.694
kombinovaný prístup	0.872	0.863	0.868
Naïvný Bayesov klasifikátor	0.811	0.812	0.812
metóda podporných vektorov	0.845	0.863	0.854

Porovnanie kombinovaného prístupu s ostatnými prístupmi strojového učenia ukázalo, že kombinovaný prístup dosiahol

²<https://rapidminer.com/>

porovnateľné, alebo lepšie výsledky ako ostatné metódy strojového učenia. Kombinovaný prístup dosiahol výrazne lepšie výsledky ako samostatný Naïvný bayesovský klasifikátor. To je celkom zaujímavé zistenie, hlavne keď sa zameriame na fakt, že slovníkový prístup sa učil na datasete, ktorý nebol 100%-ne správny. Trénovacia množina, na ktorej sa kombinovaný prístup učil, dosahovala kvalitu výsledkov od 82.4% do 89%. Napriek tomu kombinovaný prístup dosiahol lepšie výsledky ako samostatný NB klasifikátor, a tiež bol schopný opraviť niektoré nesprávne klasifikované príspevky, z ktorých sa sám učil. Kombinovaný prístup zároveň dosiahol lepšie výsledky pre pozitívne príspevky ako metóda podporných vektorov, ktorá mohla byť ovplyvnená vyšším počtom negatívnych príspevkov v všeobecnom datasete.

E. Slovníkový prístup k analýze názorov anotovaný pomocou PSO

Významný vplyv na výsledky klasifikácie má aj kvalita anotácie slovníka. Anotovanie slovníka ale nie je jednoduchý proces. Manuálne anotovanie umožňuje slovám priradiť hodnoty polarity, ktoré nie sú priamo naviazané na štatistiku výskytu konkrétneho slova v korpuse, alebo v iných slovníkoch. Nevýhodou manuálneho spôsobu anotovania slovníkov je najmä časová náročnosť tohto riešenia. Automatické anotovanie rieši časovú náročnosť, ale hodnoty polarity získava na základe matematických výpočtov, ktoré nie vždy odzrkadľujú polaritu slova. Semi-automatické anotovanie môže využívať hodnoty vypočítané automaticky, ktoré sú následne skontrolované. Proces kontroly však tiež vyžaduje čas.

Jednou z možností pri manuálnom vytváraní slovníkov je použitie existujúceho slovníka v cudzom jazyku, ktorý je preložený do cieľového jazyka. V takomto prípade je možné v procese anotovania použiť hodnoty polarity priradené slovám v pôvodnom slovníku. Nevýhodou tohto prístupu je fakt, že preložené slová v cieľovom jazyku nemusia mať rovnakú silu polarity ako to bolo v pôvodnom jazyku. Ak sú preložené slová doplnené o synonymá a opozitá, tie nemusia mať rovnakú silu polarity ako tomu bolo pôvodne. Takto preložený slovník treba nanovo anotovať, čo je opäť časovo náročné. Možnostiam ako prispôsobiť slovník z jedného jazyka do druhého sme sa venovali v článku [22]. Tieto články sú zamerané na použitie evolučného algoritmu, ktorý by mohol nahradiť ľudí v procese anotácie slovníka. Hlavnou úlohou evolučného algoritmu bolo automaticky hľadať optimálne hodnoty polarity pre slová v slovníku. Ako evolučný algoritmus boli použité dve verzie optimalizácie pomocou roja častíc (PSO). Prvá verzia je postavená na štandardnej PSO, ktorá hľadá optimálne riešenie aplikovaním dvoch krokov: zmenou rýchlosti a zmenou polohy. Zmena rýchlosti je závislá na predchádzajúcej rýchlosti, najlepšej polohe konkrétneho jedinca, polohe najlepšieho jedinca v populácii, nastavenej zotrvačnosti a ďalších parametroch. Nová rýchlosť je vypočítaná pomocou rovnice 1. Zmena polohy je následne upravená na základe prechádzajúcej polohy a novej rýchlosti podľa vzorca 2.

Pri experimentoch so štandardnou PSO bol testovaný vplyv viacerých kombinácií vstupných parametrov, pričom ako najlepšia sa ukázala kombinácia popísaná nižšie:

noitemsep

- zotrvačnosť = 0.729844
- počet jedincov = 15 000
- počet iterácií = 100
- $c_1 = 1.49618$
- $c_2 = 1.49618$
- maximálna zmena polarity = 2

Druhá verzia je založená na implementácii Bare-Bones PSO (BBPSO). BBPSO používa hodnoty $pbest$ a $gbest$ na výpočet polohy jedinca pomocou Gaussovej distribúcie $\mathcal{N}(\mu, \sigma)$. Stredná hodnota μ je získaná z hodnôt $pbest$ a $gbest$ pomocou vzorca 4 a rozptýl je z týchto hodnôt vypočítaný pomocou vzorca 5. Pri experimentoch s BBPSO sme použili rovnaký počet jedincov a rovnaký počet iterácií ako v prípade štandardnej PSO. BBPSO použila na nájdenie optimálneho riešenia populáciu s 15 000 jedincami a celkovo 100 iterácií.

Dôležitú úlohu vo vyhodnocovaní jednotlivých verzií má fitness funkcia. V našom prípade je fitness funkcia odvodená od makro-F1 miery. Na získanie makro-F1 miery sme použili jednoduchý slovníkový prístup. Jeho princíp spočíva v tom, že skombinuje slová zo slovníka s váhami pre jednotlivé slová vygenerovanými pomocou evolučného algoritmu a vytvorí dočasný slovník. Ten je použitý na klasifikáciu sentimentu na vybranej vzorke dát z datasetu. Dáta v datasete sú uložené v predspracovanom formáte, čo znamená, že v texte bola odstránená diakritika, všetky písmená boli zmenené na malé a slová boli predspracované pomocou upravenej verzie Lancasterského stemovacieho algoritmu. Vstupný príspevok je rozdelený na vety a slová. Každé slovo je porovnané so slovami v dočasnom slovníku, a ak sa slovo z príspevku nachádza v dočasnom slovníku, hodnota polarity vety sa zmení. Ak je nájdené slovo pozitívne, sila polarity vety sa zvýši, naopak, ak je nájdené slovo negatívne, sila polarity vety sa zmenší. Tento proces je popísaný pomocou rovnice 10.

$$P_s = \sum p_{v_w} \quad (10)$$

kde:

P_s ... je sila polarity vety

p_{v_w} ... je sila polarity slova

Z toho vyplýva, že pozitívne slová zvyšujú silu polarity vety a negatívne slová silu polarity znižujú. Polarita príspevku je nakoniec vypočítaná ako suma polarít jednotlivých viet, ktoré analyzovaný príspevok obsahuje. Hodnoty presnosti a návratnosti sú vypočítané na základe porovnania polarity vypočítanej pomocou algoritmu a manuálne priradeným hodnotením.

V práci [22] bol prvýkrát predstavený malý slovník. Tento slovník je doménovo nezávislý, keďže bol vytvorený kombináciou šiestich anglických slovníkov, a teda existuje predpoklad, že extrahovaním slov, ktoré sa nachádzajú v každom jednom z nich získame iba doménovo nezávislé slová. Súčasne by mohol

byť tento slovník budúcim základom v prípade použitia kombinovaného prístupu, do ktorého sa doménovo nezávislý slovník hodí viac ako slovník, ktorý je doménovo závislý. Aby mohol malý slovník dosahovať dobré výsledky je potrebné nájsť čo najvhodnejšie hodnoty polarít pre slová v tomto slovníku. Z uvedeného dôvodu bol spomínaný slovník anotovaný pomocou obidvoch verzií evolučného algoritmu, ktorého úlohou bolo nájsť vhodné hodnoty polarít pre jednotlivé slová.

Na experimenty sme použili všeobecný a filmový dataset. Filmový dataset bol opäť použitý hlavne z dôvodu približného porovnania s ostatnými prácami vo svete. Datasets boli náhodne rozdelené na dve časti v pomere 90:10. To znamená, že optimálne riešenie bolo vyhľadávané na 90% príspevkov a nájdené optimálne riešenie bolo testované na 10% nepoužitých príspevkov. Rovnaká časť 10% príspevkov bola použitá aj pre overenie kvality manuálne anotovaného slovníka. Testovanie v pomere 90:10 bolo použité preto, aby bolo možné porovnať výsledky dosiahnuté použitím slovníka anotovaného pomocou evolučného algoritmu, ktorý sa podobá strojovému učeniu a klasického slovníkového prístupu. Experimenty boli vykonané na oboch slovníkoch: veľkom aj malom slovníku a výsledky boli zapísané do tabuľky XII.

TABLE XII

POROVNANIE F1-MIER, KTORÉ BOLI DOSIAHNUTÉ TROMI SPÔSOBAMI ANOTOVANIA VEĽKÉHO A MALÉHO SLOVNÍKA

	všeobecný dataset	filmový dataset
manuálne anotovaný veľký slovník	0.7668	0.6294
veľký slovník anotovaný pomocou PSO	0.6982	0.6944
veľký slovník anotovaný pomocou BBPSO	0.7752	0.7427
manuálne anotovaný malý slovník	0.5011	0.6788
malý slovník anotovaný pomocou PSO	0.5087	0.7272
malý slovník anotovaný pomocou BBPSO	0.5278	0.7384

Výsledky ukázali viacero zaujímavých zistení, ktoré protirečia štandardnému chápaniu znalostí v oblasti analýzy názorov. Z výsledkov je možné vidieť, že slovníky anotované pomocou evolučných algoritmov dosiahli lepšie výsledky v siedmich prípadoch z ôsmich. Slovníky anotované pomocou štandardnej PSO prekonal manuálne anotované slovníky v troch prípadoch zo štyroch a to konkrétne v prípade použitia veľkého slovníka na filmovom datasete a v prípadoch použitia malého slovníka na všeobecnom a filmovom datasete. Ešte lepšie výsledky dosiahli slovníky anotované pomocou BBPSO, ktoré prekonal manuálne anotované slovníky vo všetkých prípadoch. Slovníky anotované pomocou BBPSO súčasne prekonal aj tie verzie slovníkov, ktoré boli anotované štandardnou PSO.

Použitie filmového datasetu nám umožnilo približné porovnanie s výsledkami dosiahnutými v práci Taboada a kol. [32]. Taboada a kol. dosiahli vo svojej práci výsledky v rozsahu od 68.05% (použitie jednoduchej analýzy sentimentu založenej

iba na slovách zo slovníka) do 76.37% (sentiment analýza používajúca dodatočné funkcie). V našom prípade slovník anotovaný pomocou BBPSO dosiahol výsledok 73.84% za použitia iba 220 slov, čo predstavuje len 3.2% slov nachádzajúcich sa v slovníku predstavenom v práci Taboada a kol., ktorý obsahuje 6 793 slov.

Zaujímavým faktom, ktorý vyplýva z dosiahnutých výsledkov je ten, že evolučný algoritmus bol schopný prekonať manuálne anotovaný slovník. To znamená, že evolučný algoritmus bol schopný nájsť vhodnejšie hodnoty polarít pre slová v slovníku ako človek, čo je dosť prekvapivé. Uvedený efekt môže byť vysvetlený tak, že človek priradzuje polaritu slovám na základe intuície. Tento spôsob anotovania však nie vždy funguje. Ak máme príspevok ako napríklad "Dobrý film. Hrozný scenár bol kompenzovaný dobrými hercami.", bude tento príspevok na základe manuálne anotovaného slovníka (slovo dobrý má silu polaritu +1 a slovo hrozný má silu polaritu -3) vyhodnotený ako negatívny, hoci sa jedná o pozitívny príspevok. Takéto hodnotenie je ovplyvnené tým, že anotovanie slovníka človekom nie je nijako trénované počas toho ako dochádza k anotovaniu slovníka. Na rozdiel od manuálneho anotovania, anotovanie pomocou evolučných algoritmov je dosť podobné strojovému učeniu, a teda je schopné učiť sa v priebehu anotovania učiť.

Výsledky experimentov okrem toho ukázali rozdiely medzi jednotlivými datasetmi. Veľký slovník dosiahol výrazne lepšie výsledky na všeobecnom datasete vo všetkých experimentoch. Na druhú stranu, obidva slovníky dosiahli podobné výsledky na filmovom datasete, ktorý bol preložený z anglického jazyka. Tým sa ukázali rozdiely medzi slovenským a anglickým jazykom. Súčasne sa tak ukázala komplexnosť slovenského jazyka, ktorý na vyjadrenie pozitívneho alebo negatívneho názoru používa oveľa väčšie množstvo slov. Ukázalo sa, že dodatočné slová pridané do veľkého slovníka mali zásadný význam pri analýze názorov v slovenskom jazyku, zatiaľ čo tieto slová nemali významný vplyv na výsledky dosiahnuté na filmovom datasete.

Získané slovníky boli použité v spojení s metódou strojového učenia v kombinovanom prístupe. Výsledky experimentov, ktoré ukázali zlepšenie výsledkov klasifikácie pomocou aplikácie evolučného algoritmu v procese anotovania slovníkov, dávajú vhodné predpoklady, že kombinovaný prístup dosiahne ešte lepšie výsledky ako v predchádzajúcich experimentoch. Preto sme sa rozhodli implementovať novoanotované slovníky do kombinovaného prístupu ku klasifikácii názorov.

Kombinovaný prístup štandardne delí proces klasifikácie na dve časti. V prvej časti sú použité slovníky, ktoré boli anotované manuálne alebo evolučným algoritmom na to, aby klasifikovali príspevky, ktoré sa nachádzajú v datasete. V druhej časti sú príspevky v datasete rozdelené na príspevky, ktoré boli slovníkmi klasifikované do pozitívnej alebo negatívnej triedy a na príspevky, ktoré klasifikované neboli. Klasifikované príspevky boli použité na trénovanie klasifikátora postaveho na strojovom učení. V našom prípade sme opätovne použili Naïvný Bayesov (NB) klasifikátor, keďže sa jedná

o pomerne jednoduchý klasifikátor s dobrými výsledkami, ktorý v predchádzajúcich experimentoch dokázal ako súčasť kombinovaného prístupu prekonať aj metódu podporných vektorov (SVM). Model, ktorý bol natrénovaný Naïvným Bayesovým klasifikátorom bol použitý na klasifikovanie ostatných príspevkov, ktoré sa nepodarilo klasifikovať slovníkovým prístupom.

Kombinovaný prístup používajúci slovníky anotované pomocou evolučného algoritmu (PSO a BBPSO) bol testovaný na všeobecnom datasete. Ten bol po klasifikácii názorov rozdelený na klasifikované a neklasifikované príspevky. Klasifikované príspevky boli použité na vytvorenie tréningovej vzorky a natrénovaný model stojového učenia bol aplikovaný na neklasifikované príspevky. Dosiahnuté výsledky sú zobrazené v tabuľkách XIII a XIV.

TABLE XIII

POROVNANIE VÝSLEDKOV, KTORÉ DOSIAHOL VEĽKÝ SLOVNÍK ANOTOVANÝ TROMI RÔZNYMI SPÔSOBAMI (MANUÁLNE ANOTOVANÝ, ANOTOVANÝ POMOCOU PSO A ANOTOVANÝ POMOCOU BBPSO) BEZ A V SPOLUPRÁCI S KOMBINOVANÝM PRÍSTUPOM (KP)

prístup	F1(+)	F1(-)	makro F1
manuálne anotovaný slovník bez KP	0.740	0.645	0.694
manuálne anotovaný slovník s KP	0.852	0.826	0.839
slovník anotovaný pomocou PSO bez KP	0.717	0.608	0.663
slovník anotovaný pomocou PSO s KP	0.847	0.821	0.834
slovník anotovaný pomocou BBPSO bez KP	0.743	0.667	0.705
slovník anotovaný pomocou BBPSO s KP	0.869	0.860	0.865

TABLE XIV

POROVNANIE VÝSLEDKOV, KTORÉ DOSIAHOL MALÝ SLOVNÍK ANOTOVANÝ TROMI RÔZNYMI SPÔSOBAMI (MANUÁLNE ANOTOVANÝ, ANOTOVANÝ POMOCOU PSO A ANOTOVANÝ POMOCOU BBPSO) BEZ A V SPOLUPRÁCI S KOMBINOVANÝM PRÍSTUPOM (KP)

prístup	F1(+)	F1(-)	makro F1
manuálne anotovaný slovník bez KP	0.590	0.400	0.495
manuálne anotovaný slovník s KP	0.836	0.813	0.825
slovník anotovaný pomocou PSO bez KP	0.589	0.407	0.498
slovník anotovaný pomocou PSO s KP	0.840	0.828	0.834
slovník anotovaný pomocou BBPSO bez KP	0.595	0.421	0.508
slovník anotovaný pomocou BBPSO s KP	0.847	0.834	0.841

Výsledky ukazujú, že neklasifikované príspevky výrazne znižujú kvalitu dosiahnutých výsledkov. Použitím kombinovaného prístupu sme dosiahli rapidné zlepšenie presnosti a návratnosti klasifikovaných príspevkov. Tento rozdiel sa výraznejšie prejavil pri použití malého slovníka, ktorý bol samostatne schopný klasifikovať iba 59.8% príspevkov, na

ktorých dosiahol relatívne nízku kvalitu výsledkov. Po aplikovaní kombinovaného prístupu sa kvalita výsledkov malého slovníka výrazne zlepšila a výrazne sa priblížila výsledkom, ktoré dosiahol veľký slovník.

Zároveň sa ukázal aj vplyv kvalitnejších výsledkov, ktoré boli dosiahnuté kvalitnejšie anotovanými slovníkmi. Tie použili vhodnejšie hodnoty polaroty na zvýšenie presnosti a návratnosti pred použitím kombinovaného prístupu. Na základe toho bolo možné vytvoriť tréningovú množinu, ktorá ponúkla vhodnejšie príspevky na tréningovanie modelu, ktorý následne dosiahol lepšie výsledky.

V. CONCLUSION

Sociálne médiá v súčasnosti produkujú ohromné množstvo dát, ktoré je náročné analyzovať manuálne. Z tohto dôvodu sa do popredia dostáva automatická analýza sentimentu a názorov, ktorej úlohou je získať a analyzovať zozbierané dáta. Znalosti získané pomocou tejto analýzy môžu pomôcť pri podpore predaja produktov, zlepšiť imidž značky alebo poskytnúť konkurenčnú výhodu. V praxi sa uplatňujú dva hlavné prístupy k analýze sentimentu a názorov: slovníkový prístup a metódy strojového učenia. Obidva prístupy majú ako svoje výhody, tak aj nevýhody. V našej práci sme sa rozhodli zamerať na niektoré nevýhody, ako sú: zníženie kvality klasifikácie názorov opisom parciálnych častí produktu alebo služby, neschopnosť klasifikovať príspevky neobsahujúce slová zo slovníka a vhodné anotovanie slovníka. Spomínané nevýhody sú často spájané práve so slovníkovým prístupom.

V našej dizertačnej práci sme sa zamerali na tri vyššie spomenuté problémy, ktoré sprevádzajú slovníkový prístup na analýzu názorov. Na základe spomenutých problémov boli zadefinované ciele tejto práce, ktoré sme sa snažili naplniť. Najskôr bolo potrebné vytvoriť algoritmus na klasifikáciu názorov v slovenskom jazyku, ktorý sme vylepšovali a pridávali do neho dodatočné funkcie. Potom sme sa zamerali na prvý problém a súčasne druhý cieľ tejto práce, ktorý sme pri testovaní nášho algoritmu zaznamenali, a to zníženie presnosti a návratnosti v prípadoch, keď autor príspevku popisoval dej filmu namiesto toho, aby hodnotil celý film. Tento problém sa nám podarilo vyriešiť pridaním identifikácie tém do slovníkového prístupu. Uvedeným spôsobom sa nám podarilo zvýšiť váhy viet venujúcich sa témam, o ktorých sa diskutovalo. Implementáciou identifikácie tém sa nám podarilo zlepšiť kvalitu klasifikácie o 1 až 2% v závislosti na spôsobe, akým boli témy vyberané.

Druhý problém, ktorý bol formulovaný do tretieho cieľa, je nemožnosť klasifikovať príspevky, ktoré neobsahujú slová zo slovníka. Na vyriešenie tohto problému sme použili kombinovaný prístup. Kombinovaný prístup spája metódu postavenú na slovníku s algoritmom strojového učenia. Príspevky z datasetu boli klasifikované pomocou slovníka a rozdelené na tie, ktoré sa pomocou slovníka podarilo klasifikovať a na tie, ktoré sa klasifikovať nepodarilo. Klasifikované príspevky boli potom použité na natrénovanie klasifikátora na báze strojového učenia. Ten bol použitý na zaradenie neklasifikovaných

príspevkov do pozitívnej alebo negatívnej triedy. Kombinovanému prístupu sa tak podarilo zredukovať počet neklasifikovaných príspevkov z 18% na 0.3% v prípade použitia veľkého slovníka a zo 40.2% na 0.2% v prípade použitia malého slovníka. So zvýšeným počtom klasifikovaných príspevkov sme zaznamenali aj významný nárast kvality klasifikácie. Veľký slovník dosiahol zlepšenie výsledkov až o 16%. Zlepšenie týkajúce sa malého slovníka bolo ešte výraznejšie, a to až 42%.

Tretí spomenutý problém sme formulovali do štvrtého cieľa a našej dizertačnej práce. Týmto problémom je náročnosť pri vytváraní nového slovníka, ktorá je kladená na čas a ľudské zdroje. Pri riešení tohto problému sme sa zamerali na možnosť nahradenia manuálneho anotovania evolučným algoritmom. Ako evolučný algoritmus sme použili Particle Swarm Optimization (PSO), ktoré bolo úspešne aplikované na množstvo optimalizačných úloh. Vzhľadom na to, že aj anotovanie slovníka predstavuje istú formu optimalizačného problému, kedy hľadáme vhodné hodnoty polarít pre slová v slovníku tak, aby boli výsledky klasifikácie čo najlepšie, použili sme na anotovanie slovníka práve PSO algoritmus. Na základe vykonaných experimentov a získaných výsledkov môžeme konštatovať, že PSO bolo schopné nájsť vhodnejšie hodnoty polarít pre slová v slovníku, a tak významne zlepšiť výsledky klasifikácie. Výsledky sa zlepšili od 1 do 5% na slovenskom datasete a od 8 do 18% na filmovom datasete.

V rámci tejto práce boli vytvorené aj dva datasety umožňujúce testovanie a porovnávanie výsledkov. Tvorba datasetov síce nebola transformovaná do cieľov našej práce, ale bola ich nevyhnutnou súčasťou, hlavne preto, že pre slovenčinu neexistuje štandardný dataset určený na porovnanie dosiahnutých výsledkov.

Predstavené prístupy a vylepšenia zároveň poskytujú široké možnosti budúceho výskumu a rozširovania. Kombinovaný prístup ukrýva potenciál použitia v aktívnom učení, kedy by sa metóda strojového učenia mohla preúčať v čase na základe prichádzajúcich dát, ktoré by boli klasifikované pomocou kvalitného slovníka a bez potreby manuálneho anotovania novopridaných príspevkov. Anotovanie slovníkov tiež ponúka niekoľko možností vylepšenia. Či už je to inicializácia prvej generácie pomocou externých znalostí, použitia obmedzenia pri anotovaní pozitívnych a negatívnych slov alebo aplikovania zhľukovania na nájdenie podobných skupín slov. Na tieto skupiny by mohli byť použité rôzne formy anotovania pomocou PSO, kedy by boli hodnoty polarít priradené celým zhľukom alebo nezávisle jednotlivým slovám v rámci zhľukov. Takto by bolo možné proces anotovania paralelizovať a urýchliť.

ACKNOWLEDGMENT

Tento príspevok vznikol za podpory agentúry VEGA v rámci projektu č. 1/0493/16, agentúry na podporu výskumu a vývoja na základe zmluvy č. APVV-16-0213 a na základe zmluvy č. APVV-17-0267.

REFERENCES

- [1] Abbasi, A. a kol.: *Selecting Attributes for Sentiment Classification Using Feature Relation Networks*. In: Knowledge and Data Engineering. Roč. 23, č. 3 (2011), 447-462 s. ISSN 1041-4347.
- [2] Bai, X.: *Predicting Consumer Sentiments from Online Text*. In: Decision Support Systems. Roč. 50, č. 4 (2011), 732-742 s. ISSN 0167-9236.
- [3] Basari, S. H. a kol.: *Opinion Mining of Movie Review using Hybrid Method of Support Vector Machine and Particle Swarm Optimization*. In: Procedia Engineering, 2013, 453-462 s.
- [4] Benamara, F. a kol.: *Sentiment Analysis: Adjectives and Adverbs are better than Adjectives Alone*. In: Proceedings of the First International Conference on Weblogs and Social Media. Boulder: 2007.
- [5] Van den Bergh, F. a Engelbrecht, A. P.: *A study of particle swarm optimization particle trajectories*. In: Information sciences. (2006), 937-971 s.
- [6] Cambria, E. a kol.: *SenticNet 4: A semantic resource for sentiment analysis based on conceptual primitives*. In: COLING. Osaka, 2016. 2666-2677 s.
- [7] Escalante, H. J. a kol.: *Term-weighting Learning via Genetic Programming for Text Classification*. In: Knowledge-Based Systems, 2015, 176-189 s.
- [8] Günter, T. a Furrer, L.: *GU-MLT-LT: Sentiment analysis of short messages using linguistic features and stochastic gradient descent*. In: In Second Joint Conference on Lexical and Computational Semantics (*SEM), Volume 2: Proceedings of the Seventh International Workshop on Semantic Evaluation (SemEval 2013), 328-332 s.
- [9] Gupta, D. K. a kol.: *PSO-ASent: Feature Selection Using Particle Swarm Optimization for Aspect Based Sentiment Analysis*. In: NLDB, 2015. 220-233 s.
- [10] Habernal, I. a kol.: *Supervised Sentiment Analysis in Czech Social Media*. In: Information Processing and Management: an International Journal. Roč. 50, č. 5 (2014), 693-707 s. ISSN 0306-4573.
- [11] Hu, Y. and Li, W.: *Document Sentiment Classification by Exploring Description Model of Topical Terms*. In: Computer Speech and Language. Roč. 25, č. 2 (2011), 386-403 s. ISSN 0885-2308.
- [12] Hu, M. and Liu, B.: *Mining and Summarizing Customer Reviews*. In: Proceedings of the Tenth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '04). New York: ACM, 2004. 167-177 s. ISBN 1-58113-888-1.
- [13] Kacprzyk, J. a Pedrycz, W.: *Springer Handbook of Computational Intelligence*. 2015.
- [14] Kennedy, A. and Inkpen, D.: *Sentiment Classification of Movie and Product Reviews Using Contextual Valence Shifters*. In: Workshop on the Analysis of Informal and Formal Information Exchange during Negotiations (FINEXIN '05). Ottawa: 2005. 11-22 s.
- [15] Kennedy, J.: *Bare bones particle swarms*. In: Proceedings of the IEEE Swarm Intelligence Symposium (SIS), 2003. 80-87 s.
- [16] Kiritchenko, S. a Mohammad, S.: *Capturing Reliable Fine-Grained Sentiment Associations by Crowdsourcing and Best-Worst Scaling*. In: Proceedings of The 15th Annual Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL). San Diego, California: 2016.
- [17] Kiritchenko, S. a kol.: *Semeval-2016 Task 7: Determining Sentiment Intensity of English and Arabic Phrases*. In: Proceedings of the International Workshop on Semantic Evaluation (SemEval '16). San Diego, California: 2016.
- [18] Koncz, P. a Paralič, J.: *An approach to feature selection for sentiment analysis*. In: 15th IEEE International Conference on Intelligent Engineering Systems (INES). 2011. 357-362 s.
- [19] Liu, B. and Zhang, L.: *A Survey of Opinion Mining and Sentiment Analysis*. In: Mining Text Data. 2012. 415-463 s.
- [20] Lu, Y. a kol.: *Exploring the Sentiment Strength of User Reviews*. In: Proceedings of the 11th International Conference on Web-age Information Management (WAIM '10). Berlin: Springer-Verlag, 2010. 471-482 s. ISBN 978-3-642-14245-1.
- [21] Mejova, Y.: *Sentiment Analysis: An Overview*. 2009. 1-28 s.
- [22] Mikula, M. a kol.: *Adapting sentiment analysis system from English to Slovak*. In: IEEE Symposium Series on Computational Intelligence (SSCI'17). Danvers: IEEE, 2017. 1-7 s. ISBN 978-1-5386-2725-9.
- [23] Miura, Y. a kol.: *Teamx: A sentiment analyzer with enhanced lexicon mapping and weighting scheme for unbalanced data*. In: Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014).

- Dublin, Ireland: Association for Computational Linguistics and Dublin City University 2014. 628-632 s.
- [24] Mohammad, S. and Turney, P.: *Crowdsourcing a Word-Emotion Association Lexicon*. In: Computational Intelligence. Roč. 27, č. 3 (2013). 436-465 s.
- [25] Mohammad, S. a kol.: *NRC-Canada: Building the State-of-the-Art in Sentiment Analysis of Tweets*. In Proceedings of the seventh international workshop on Semantic Evaluation Exercises (SemEval-2013). Atlanta, USA. 2013.
- [26] Nielsen, F.: *A new ANEW: Evaluation of a word list for sentiment analysis in microblogs*. In: CoRR. 2011. 93-98 s.
- [27] Ortigosa, A. a kol.: *Sentiment Analysis in Facebook and Its Application to e-Learning*. In: Computers in Human Behavior. Roč. 31, (2014). 527-541 s. ISSN 0747-5632.
- [28] Pang, B. a kol.: *Thumbs Up?: Sentiment Classification Using Machine Learning Techniques*. In: Proceedings of the ACL-02 Conference on Empirical Methods in Natural Language Processing (EMNLP '02). Stroudsburg: Association for Computational Linguistics, 2002. 79-86 s.
- [29] Pang, B. and Lee, L.: *A Sentimental Education: Sentiment Analysis Using Subjectivity Summarization Based on Minimum Cuts*. In: Proceedings of the 42Nd Annual Meeting on Association for Computational Linguistics (ACL '04). Stroudsburg: Association for Computational Linguistics, 2004.
- [30] Proisl, T. a kol.: *Klue: Simple and robust methods for polarity classification*. In: In Second Joint Conference on Lexical and Computational Semantics (*SEM), Volume 2: Proceedings of the Seventh International Workshop on Semantic Evaluation (SemEval 2013), 395-401 s.
- [31] Sindhvani, V. and Melville, P.: *Document-Word Co-regularization for Semi-supervised Sentiment Analysis*. In: Eighth IEEE International Conference on Data Mining (ICDM '08). 2008. 1025-1030 s. ISSN 1550-4786.
- [32] Taboada, M. a kol.: *Lexicon-based Methods for Sentiment Analysis*. In: Computational Linguistics. Roč. 37, č. 2 (2011). 267-307 s. ISSN 0891-2017.
- [33] Thelwall, M. a kol.: *Sentiment Strength Detection in Short Informal Text*. In: J. Am. Soc. Inf. Sci. Technol. 2010. 2544-2558 s.

Podpora rozhodovania vo vybranom logistickom procese metódami analýzy dát

Miroslava Muchová

Katedra kybernetiky a umelej inteligencie
Fakulta elektrotechniky a informatiky, Technická univerzita
Košice, Slovensko
miroslava.muchova@tuke.sk

Ján Paralič

Katedra kybernetiky a umelej inteligencie
Fakulta elektrotechniky a informatiky, Technická univerzita
Košice, Slovensko
jan.paralic@tuke.sk

Abstract— Predkladaná článok sa zaoberá prepojením logistiky, podpory rozhodovania a analýzy dát. Článok sa venuje prepojeniu týchto kľúčových pojmov, kde na základe analýzy dát sa vytvára systém podpory rozhodovania v logistickom procese. Teoretická časť sa venuje analýze súčasného stavu výskumného problému vo svete spolu s návrhom riešenia konkrétnych výskumných problémov. Popisuje momentálnu situáciu a aktuálne využívaný systém vo zvolenej logistickej spoločnosti, zároveň opisuje použité metódy výskumu. Praktická časť je zameraná na vytvorenie podporného systému, ktorej základom je navrhovaná štruktúra riadenia logistiky. Základným východiskom pri tvorbe systému je metodológia CRISP-DM, aplikovaná na dáta logistickej firmy. Navrhovaný systém dokáže určiť kľúčové faktory vplyvajúce na spotrebu paliva alebo štýl jazdy celého vozového parku alebo jednotlivých vodičov. Informácie a znalosti, ktoré systém ponúkne používateľovi sú denne aktualizované a ukladané do databázy. Podporný systém rozhodovania logistickej firmy tak dokáže ponúknuť aktualizované informácie. Prostredníctvom získaných informácií a znalostí môže manažér logistickej firmy uskutočniť včasné a presné rozhodnutia. Na základe týchto informácií a zadaných parametrov dokáže systém odporučiť vodiča na plánovanú dodaciu trasu. Aktualizované dáta sú z databázy dostupné používateľovi formou excelovských súborov prostredníctvom ktorých dokáže vytvárať OLAP analýzy.

Keywords— Podpora rozhodovania, logistika, dolovanie dát, analýza dát, CRISP-DM, spotreba paliva

I. ÚVOD

Automobilový, energetický, strojársky alebo potravinársky priemysel je dnes viac zameraný na analýzu dát než kedykoľvek predtým. Senzory do áut, sledovanie GPS, automatizované procesy a iné, generujú dennodenne nespočetné množstvo údajov, ktoré je potrebné analyzovať a pochopiť. Úlohou je extrakcia údajov na informácie s cieľom porozumieť preferenciám a výrobným procesom, tak aby sa zabezpečila spokojnosť zákazníkov, minimalizovali sa náklady, maximalizoval sa zisk a zefektívni sa rôzne procesy v priemysle. Stratégia v oblasti dát v rámci organizácií sa rýchlo stáva kľúčovou konkurenčnou výhodou a nevyhnutnosťou pre inovácie, pretože ovplyvňujú množstvo obchodných rozhodnutí. Údaje pomáhajú podnikom vytvárať nové príležitosti na rast, pretože získavajú schopnosť zhromažďovať a analyzovať údaje priamo z odvetvia.

Cieľom článku je na základe analýzy dát vytvoriť podporný systém rozhodovania v konkrétnom logistickom procese reálnej firmy. Pomocou metód analýzy dát a modelovania navrhujeme systém pre podporu rozhodovania o výbere vodiča na plánovanú trasu. Navrhovaný systém ponúka aj ďalšie funkcionality ako exploračnú analýzu dát, vizualizáciu, závislosti atribútov s možnosťou analýzy vplyvu atribútov na priemernú spotrebu paliva a štýlu jazdy vodičov. Štýl jazdy môžeme chápať ako individuálnu charakteristiku vodiča. Správanie vodiča je ovplyvnené mnohými faktormi, ako sú dopravná situácia, prostredie, kontext jazdy a vlastné charakteristiky vodiča. Z týchto hľadísk je dôležité porozumieť chovaniu vodiča. Prínosom navrhovaného systému je, že systém disponuje aktualizáciou dát, čím tak poskytne používateľovi aktuálne informácie.

II. TEORETICKÝ ROZBOR ZVOLENEJ TÉMY

Cieľom kapitoly je podať stručný prehľad aktuálneho stavu problematiky súvisiacej s témou článku. Kapitola je venovaná prehľadu literatúry venujúcej sa problému plánovania vodičov na jednotlivé trasy a nákladné vozidlá ako aj snahe znížiť spotrebu paliva pomocou rôznych efektívnych jazdných programov.

A. Analýza dát

Analýza údajov má v dnešnej dobe stále rastúci význam. Prvýkrát sa o analýze údajov začalo hovoriť začiatkom deväťdesiatych rokov 20. storočia ako o získavaní poznatkov z databáz (KDD – knowledge discovery in databases), poprípade aj objavovanie poznatkov v databázach. Analýza dát začínala s databázami naplnenými informáciami o zákazníkoch, produktoch, transakciách. Fayyad definoval túto disciplínu ako: „Získavanie poznatkov z databáz je netriviálne získavanie implicitných, predtým neznámych a potenciálne užitočných informácií z údajov“ [1]. Získavanie poznatkov z databáz sa stalo synonymom pre analýzu údajov. Analýzu údajov môžeme definovať aj „ako proces výberu, skúmania a modelovania veľkého množstva údajov, zameraných na objavovanie vzorov alebo vzťahov, ktoré predtým neboli známe, s cieľom získania jasných a užitočných výsledkov pre vlastníka databázy“ [2]. Môžeme uviesť ešte jednu definíciu analýzy dát: „Analýza údajov je proces získavania rozličných

modelov, súhrnov a odvodených hodnôt z danej množiny údajov“ [3].

Analýzu údajov teda môžeme chápať ako nejaký proces výberu, skúmania, modelovania a vizualizácie veľkého množstva údajov, s cieľom objaviť vzory alebo vzťahy, ktoré doteraz neboli známe, čím tak chceme získať jasné a zrozumiteľné výsledky napr. pre zlepšenie analyzovaného procesu. Dnes už vďaka novým technológiám a nástrojom organizácie získavajú nové pohľady z predtým nevyužitých zdrojov dát [4].

V mnohých prípadoch je analýza dostupná koncovému používateľovi vo forme správ a vizualizácií. Vzhľadom k tomu, že surové dáta môžu byť nepochopiteľné, organizácie, firmy, podniky sa musia spoliehať na analytické nástroje a techniky, ktoré pomôžu prezentovať dáta zmysluplným spôsobom. Zatiaľ čo tradičné správy/reports a vizualizácie sú známe, sú však nepostačujúce pre vytvorenie nových aplikácií a prístupov pre analýzu veľkých dát [1].

B. Analýza dát v logistike

Pod pojmom logistika rozumieme efektívne skladovanie tovaru a riadenie toku tovaru medzi miestom pôvodu a miestom spotreby, s cieľom splniť požiadavky a potreby zákazníkov [5]. Jedná sa o systémové plánovanie, synchronizáciu, riadenie, realizáciu ako aj kontrolu materiálového a informačného toku. Niektorí odborníci tvrdia, že logistika je manažérska činnosť realizujúca služby zákazníkom. Technológie dolovania dát môžu pomôcť podnikom zhromaždiť a analyzovať rôzne informácie v oblasti riadenia logistiky včas a presne. Data mining a s ním súvisiace technológie môžu výrazne zlepšiť činnosť rozhodovacieho procesu v logistike, zlepšiť kvalitu analýzy dát, zvýšiť kvalitu služieb, zvýšiť spoľahlivosť a pod. [6]. Analýza dát a logistika spolu úzko súvisia. Logistické spoločnosti generujú denne množstvo dát, ktoré v sebe skrývajú obrovský potenciál pre nové, ďalšie analýzy. Umiestnenie rôznych senzorov vo vozidlách, riadenie zásob, sledovanie zásielok, všetky tieto činnosti generujú veľké množstvo dát [5]. Pre logistické spoločnosti je ťažké ťažiť cenné informácie z tak veľkého množstva dát, je ťažké uskutočňovať včasné a presné rozhodnutia, ktoré sa využívajú na riadenie procesu a prevádzkovú činnosť logistiky, je ťažké znížiť logistické náklady a zvýšiť príjmy podniku [6]. Rôzne technológie dokážu pomôcť manažérom analyzovať údaje a získať z nich užitočné informácie pre správne predvídanie a rozhodovanie. Navyše analýza dát pozerá na logistiku ako na sieť vzájomne prepojených informácií a mikroekonomických súvislostí. Technológie dolovania dát a štatistické analýzy môžu nájsť vzťah medzi modelmi a dátami, môžu pomôcť nájsť potenciál modelu a na základe neho pochopiť správanie zákazníkov a vykonať zodpovedajúcu stratégiu. Firma takto môže znížiť riziko plynúce z chybného rozhodnutia [6], [7]. Dolovanie a samotná analýza dát sa tak stáva pre logistiku dôležitou súčasťou z dôvodu pomoci pri dôležitých rozhodnutiach, pri predaji, znížení nákladov a pod.

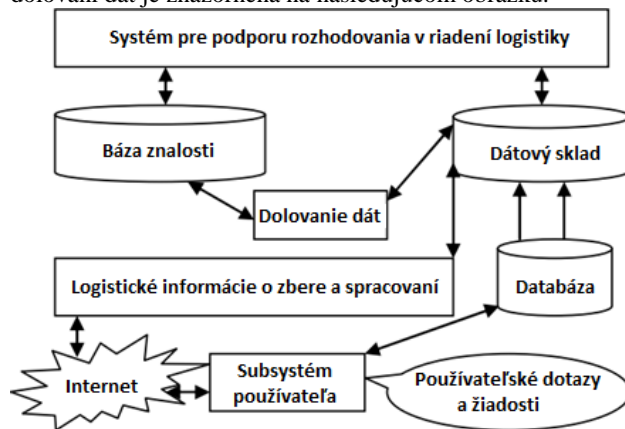
V globálnych dodávkach sietí sú sledované milióny zásielok, ktoré obsahujú informácie ako napr. pôvod a miesto

určenia, veľkosť, hmotnosť, obsah zásielky. Avšak vzniká otázka, či firmy sledovaním týchto údajov dokážu plne využiť ich hodnotu. Existuje nespočetné množstvo nevyužitých informácií, vďaka ktorým by sa mohli vytvárať nové, užitočné obchodné modely, čím by sa zlepšila prevádzková efektívnosť.

Na základe analýzy dát môžeme vytvárať inovatívny koncept minimálne v troch oblastiach logistiky. Po prvé, optimalizácia trasy pri doručovaní tovaru alebo balíkov v reálnom čase, ktorá zohľadňuje poradie dodávky, dopravnú situáciu ako aj dostupnosť odberateľa. Schopnosť predvídať meškanie dodávky v dodávateľskom reťazci, čo zabezpečuje vyššiu mieru spokojnosti zákazníkov je druhým konceptom z oblasti logistiky. A po tretie, analýza dát a samotné dáta predstavujú pre poskytovateľov logistických služieb akýsi zdroj inšpirácie pre vývoj nových obchodných modelov, napr. na základe analýzy korelácií medzi poveternostnými podmienkami, epidémiami chrípky a internetovými nákupmi spotrebiteľov. Takáto analýza dokáže napr. odhaliť, že zlé počasie vedie k vyššej realizácii nákupu prostredníctvom internetu, čo znamená vyšší počet odoslaných balíkov. Taktó vytvorené modely môžu optimalizovať procesy s cieľom zvýšiť spokojnosť zákazníkov. Prostredníctvom optimalizácie logistiky poskytovatelia logistických služieb po celom svete súťažia o čo najnižšie náklady pri dodaní tovaru. Optimalizácia procesov logistiky je v súčasnosti najväčšou príležitosťou ako dosiahnuť zníženie prevádzkových nákladov tak, že zlepši rozhodnutie a uskutoční optimálny výber o umiestnení zásob a druhu dopravy. Naším cieľom, okrem iného, je určiť kombináciu faktorov vplyvujúcich na spotrebu paliva.

Štruktúra moderného systému riadenia logistiky

Štruktúra moderného systému riadenia logistiky založenom na dolovaní dát je znázornená na nasledujúcom obrázku.



Obr. 1 Štruktúra systému riadenia logistiky [7]

Štruktúra jednotlivých častí [7], [8]:

Systém pre podporu rozhodovania v riadení logistiky – tento systém môže včas poskytnúť manažérom logistických spoločností najnovšie a najdôležitejšie poznatky, ktoré mu pomáhajú pri prijímaní správnych a platných rozhodnutí.

Modul dolovania dát – podľa účelu rozhodnutia manažmentu logistiky sa vyberajú algoritmy dolovania dát, ktoré sú aplikované na dáta v databáze. V tomto kroku

dochádza k extrakcii a k vyčisteniu užitočných informácií, ktoré sú preložené do zjednodušenej formy údajov.

Databáza a dátový sklad – všetky údaje súvisiace s podnikaním sú zhromažďované v databázach a ďalej organizované a agregované pre on-line analýzy do dátového skladu. Podľa charakteristík a poslania dolovania dát sa vyberajú potrebné údaje pre ďalšie analýzy.

Zber informácií a ich spracovanie – obrovské množstvo údajov, ktoré sú získané z logistických činností sa zhromažďujú, spracúvajú, prenášajú a ukladajú do databázy vo formáte danej platformy.

Subsystem používateľa – používatelia môžu získať prístup k webovému rozhraniu systému cez zodpovedajúci protokol, čím môžu odosielať dotazy a žiadosti.

Charakteristika moderného informačného systému riadenia logistiky pozostáva z dvoch hlavných charakteristík [7], [8]:

Technológia dátového skladu – dátový sklad umožňuje uchovávať viac dlhodobých historických údajov z logistických činností ako databáza. Plne dokáže využívať historické údaje na predpovedanie a analýzu trendov a predaja na trhu. Zároveň technológie dátového skladu môžu opísať a usporiadať obrovské množstvo rôznorodých dát logistického manažmentu, ktoré pomáhajú všetkým členom dodávateľského reťazca zdieľať logistické informácie.

Celkový dizajn – vzhľadom na to, že báza znalostí bola navrhnutá a realizovaná ako celok, rozhodovatelia môžu ľahko vybrať a používať vedomosti prostredníctvom vizuálneho rozhrania bez hlbšieho pochopenia rozhodovacieho systému, dátového skladu, dolovania dát a iných súvisiacich činností.

C. Analýza súčasného stavu v logistike a identifikácia aktuálnych výskumných problémov

V poslednej dobe rôzne výskumné štúdie poukazujú na výhody použitia veľkých dát v oblasti logistiky a dodávateľského reťazca. Keďže našim hlavným cieľom je identifikácia kľúčových faktorov vplyvujúcich na spotrebu paliva ako aj vytvorenie podporného systému, ktorý na základe daných podmienok dokáže pridelit' vodiča na plánovanú dodaciu trasu, v tejto časti podkapitoly poskytujeme prehľad literatúry, v ktorej sa autori venujú podobnej problematike. Úlohou je taktiež identifikovať aktuálne výskumné problémy s cieľom navrhnuť vlastné riešenie konkrétnych problémov.

Hľadanie dobrého riešenia problému plánovania vozidiel a vodičov je mimoriadne náročné z dôvodu zložitosti a rôznych obmedzení. Je ťažké nájsť optimálne riešenie vedúce k minimalizácii nákladov, ale zároveň spravodlivému rozdeleniu záťaže aktérov a spokojnosti samotných zamestnancov. Jednou oblasťou v logistike, kde existuje veľká medzera, je smerovanie a plánovanie vozidiel a posádky [9]. Problém s plánovaním vozidiel (Vehicle routing problem – VRP) patrí medzi najdôležitejšie logistické optimalizačné problémy. Problém smerovania vozidiel sa venuje celej skupine problémov, pri ktorých je potrebné určiť súbor trás pre flotilu vozidiel so sídlom v jednom alebo viacerých skladoch pre množstvo geograficky rozptýlených miest alebo zákazníkov. Cieľom VRP je samozrejme minimalizovať celkové náklady na všetky rozvrhované trasy. Samozrejmosťou

definovania celkových nákladov a ich minimalizácie je poznanie nákladov na každú trasu a čas cesty medzi každým zákazníkom alebo sklado.

Goel a Irnich [10] zaoberali sa kombinovaným problémom plánovania nákladných vozidiel s cieľom vytvoriť kalendár, ktorý by vyhovoval pracovným obmedzeniam (dodržiavanie pracovného času). Na vyriešenie tohto problému navrhli autori algoritmus vetvenia a medzí, ktorý je rozšírený o obmedzenia vyplývajúce z amerických vládnych predpisov. Algoritmus využíva silný dynamický programovací algoritmus na vytváranie trás v súlade s predpismi. Na základe názorov autorov môžeme konštatovať, že výskum riešenia problému s plánovaním vozidiel a s plánovaním vodičov nákladných vozidiel je ešte stále v počiatkoch a zatiaľ boli navrhnuté len heuristické prístupy. Problém plánovania posádky komplikuje skutočnosť, že existuje veľa obmedzení, ktoré môžu vyvolať zmeny.

Chen [11] zaoberal sa problémom plánovania posádky na základe čínskych predpisov. Cieľom článku bolo na základe heuristického prístupu minimalizovať počet posunov a veľkosť prevádzkových nákladov. Prístup generovania zmeny bol navrhnutý tak, aby vytvoril veľkú sadu potenciálnych posunov, ktoré vyhovujú čínskym pravidlám. Tento prístup bol testovaný pomocou riešenia ILOG Cplex Optimization Studio, ktorý umožňuje optimalizovať podnikateľské rozhodnutia, rýchlo rozvíjať a implementovať optimalizačné modely a vytvárať reálne aplikácie, ktoré môžu výrazne zlepšiť obchodné modely. Výsledky ukázali, že riešenie je možné aplikovať na rôzne problémy s plánovaním posádky. Autori dospeli k záveru, že účinné plánovanie posádky môže výrazne znížiť prevádzkové náklady podniku. Nedostatkom výskumu je, že navrhovaný algoritmus je možné aplikovať len v Číne a s ich pravidlami.

Súčasný problém smerovania a plánovania vozidiel a posádky, ktorý vznikol pri diaľkovej cestnej preprave v Európe bol spracovaný v [12]. Autori prieskumom literatúry zistili, že veľká väčšina článkov o jazde a smerovaní vozidiel nerozlišuje medzi vodičom a vozidlom. Preto sa článok venuje výpočtu samostatnej, ale synchronizovanej cesty pre vodičov a vozidlá, no bez daného časového rozvrhu. Cieľom bolo minimalizovať súčet celkových prevádzkových nákladov, ktoré pozostávajú z fixných nákladov a z nákladov závislých od vzdialenosti. Trasa vodiča ako aj vozidla začína a končí v určenom sklade a môže sa vzťahovať na niekoľko dní. Na splnenie požiadaviek musia byť dva rôzne objekty (vodič a vozidlo) synchronizované a tým vzniká problém tzv. vzájomnej závislosti. Problém vzájomnej závislosti odkazuje na skutočnosť, že zmena jednej trasy môže mať vplyv na uskutočniteľnosť iných ciest, čo znamená, že zmena trasy jedného nákladného vozidla alebo jedného vodiča môže mať za následok, že všetky ostatné nákladné vozidlá a cesty vodiča nebude možné realizovať. Základnou myšlienkou navrhovaného algoritmu je dvojstupňový prístup. V prvej etape sa určí trasa pre nákladné vozidlá s prihliadnutím na dodržanie pravidiel pre vodičov. V druhej etape sa vypočítajú trasy pre vodičov, na základe výpočtu ciest z prvého stupňa, berúc do úvahy zostávajúce pravidlá vodičov. Na konci plánovacieho horizontu sa každé vozidlo musí vrátiť prázdne do svojho domovského skladu. Na vyriešenie tohto problému autori

navrhli metaheuristické vyhľadávanie susedov. Navrhovaný algoritmus je schopný riešiť vzniknuté situácie v reálnom svete a je schopný dosiahnuť konzistentné a prakticky relevantné výsledky. Výsledky ukazujú na platnosť algoritmu, sú však platné len pre zainteresovanú firmu.

Za posledné desaťročia sa dopravné spoločnosti snažia znížiť spotrebu paliva pomocou rôznych efektívnych jazdných programov. V nich musia motoristi uplatňovať rôzne špecifické techniky. Hodnotenie výkonu vodiča a energeticky efektívnej jazdy získava čoraz väčšiu pozornosť. Článok [13] sa zaoberá aplikovaným výskumom ekologickej jazdy, ktorý je založený na obrovskom dátovom súbore. Prostredníctvom OLAP techník a techník objavovania znalostí autori určili hlavné faktory vplyvajúce na priemernú spotrebu paliva. Za hlavný cieľ dolovania dát si určili analýzu spotreby paliva na vodiča. Aplikovali Naivný Bayesov klasifikátor, na základe ktorého identifikovali faktory, ktoré majú kľúčový vplyv na spotrebu paliva. Výsledky ukázali, že najväčší vplyv na spotrebu paliva má použitie spojky, maximalizácia inerciálneho pohybu, minimalizácia času rotácie motora a pod. Zistenia ukazujú, že zavedenie jednoduchých pravidiel ako optimálne využitie spojky, otáčky motora, voľnobež, môžu znížiť spotrebu pohonných hmôt od 3 do 5 l na 100 km. Rôzny jazdný štýl ako aj rôzne vonkajšie podmienky majú za následok rôzne úrovne spotreby paliva. Autori dospeli k záveru, že aj extrémne počasie (hustý dážď, vysoké teploty, hmla) vplyva na priemernú spotrebu paliva.

D. Popis systému

Firma na komunikáciu s vozidlami využíva systém Dynafleet Online – Volvo Truck Corporation [15]. Táto komunikácia je podmienená inštaláciou mobilných jednotiek Dynafleet do vozidiel. Komunikácia medzi systémom a vozidlami prebieha prostredníctvom mobilnej telefónnej siete. Vozidlá môžu byť nastavené tak, aby pravidelne exportovali dáta do systému alebo dáta môže dispečer stiahnuť aj ručne. Informácie sťahované z vozidiel sú ukladané do databázy.

Výkazy hodnotení spotreby paliva		
Výkaz hodnotení spotreby paliva		
Standardní výkazy	vůz	řidič
Přehledový výkaz		
Souhrnný výkaz		
Výkaz vyjímek		
Výkaz paliva & AdBlue		
Výkaz proběhu km		
Časový výkaz		
Výkaz okolních podmínek		
Výkaz počítadla km		
Výkaz činností		
Sestava SPD		
Sestava sledování		
Výkaz podrobností		
Správa zaznamenaných dat		

Obr. 2 Dynafleet online reports [14]

III. DOSIAHNUTÉ VÝSLEDKY

Kapitola obsahuje jednotlivé kroky a články, od pochopenia problému, cez pochopenie a prípravu dát až po vytvorenie a vyhodnotenie navrhovaných modelov. Záver kapitoly je venovaný návrhu a vytvoreniu systému pre podporu rozhodovania.

A. Pochopenie problému

Vytvorenie systému pre podporu rozhodovania s využitím metód dolovania dát má za cieľ určiť kombináciu faktorov vplyvujúcich na spotrebu paliva celého dátového súboru, vozového parku a vodičov ako aj určiť faktory ovplyvňujúce hodnotenie jazdného štýlu. V prípade tvorby systému pre podporu rozhodovania je cieľom odporučiť vodiča na plánovanú dodaciu trasu na základe vopred zadaných parametrov. Navrhnutý systém umožní nájsť vhodného vodiča na plánovanú dodaciu trasu, tak aby dosiahol čo najnižšiu spotrebu paliva alebo čo najlepšie hodnotenie jazdného štýlu. Cieľom je navrhnuť taký systém, ktorý dokáže denne aktualizovať dostupné dáta z vozidiel, čím tak dokáže aktualizovať modely dolovania dát a používateľovi poskytne aktuálne a presné výsledky. Systém okrem iného dokáže brať do úvahy aj počet odjazdených dní a počet dní voľna. Vychádzame pritom z nami navrhovanej štruktúry riadenia logistiky.

Z hľadiska biznis cieľov takýto systém umožní manažérovi firmy získať komplexnejší pohľad na vodičov a vozový park, čím môže zvýšiť efektívnosť, konkurencieschopnosť, motiváciu a spravodlivejšie odmeňovanie vodičov. Z hľadiska dolovania dát ide o prepojenie troch oblastí, a to: logistiky, podpory rozhodovania a analýzy dát, kedy sa tieto kľúčové pojmy spájajú a na základe analýzy dát vytvárajú systém podpory rozhodovania v logistickom procese.

B. Popis dát

Ako už bolo spomínané, firma na komunikáciu s vozidlami využíva systém Dynafleet Online – Volvo Truck Corporation. Komunikácia medzi systémom a vozidlami prebieha prostredníctvom mobilnej telefónnej siete. Informácie sťahované z vozidiel sú ukladané do databázy. Následne je možné dáta exportovať do súboru Excel za účelom ďalších analýz. K dispozícii sme mali niekoľko výkazov. Pre naše analýzy sme však využili len Výkaz hodnotenia spotreby paliva a Zostavu sledovania. Výkazy obsahovali informácie o deviatich vozidlách označených písmenami od A po I a o 12-ich vodičoch.


C. Príprava dát

Cieľom prípravy dát je na základe dátumu zlúčiť informácie o vozidle zo Zostavy sledovania vozidla a z Výkazu hodnotenia spotreby paliva do jedného excelovského súboru. A následne po tomto zlúčení informácií o každom vozidle, zlúčiť informácie o všetkých vozidlách do jedného súboru. Skôr než sme takéto zlúčenie vykonali, uskutočnili sme ešte niekoľko potrebných úprav. Úlohou predspracovania v tomto prípade bolo, že sme si vytvorili nový atribút s názvom Hmotnosť. Tento atribút bol vytvorený

ako súčet atribútov: Ťahača vzadu (kg) a Príves celkom (kg). Keďže atribút Miesto podáva informáciu o krajine, meste, kraji a ulici (príp. označeniu cesty), rozdelili sme tento atribút pomocou programu v jazyku R na ďalšie štyri atribúty.

D. Pochopenia dát

Na Obr. 3 máme možnosť vidieť graf popisujúci priemernú spotrebu paliva jednotlivých vodičov. Z grafu je možné vyčítať, že Vodič_H má najhoršiu priemernú spotrebu paliva, zatiaľ čo Vodič_E a Vodič_K majú najnižšiu priemernú spotrebu paliva na 100 km. Pomocou aplikácie metód strojového učenia dokážeme určiť, ktoré atribúty a aké faktory najviac ovplyvňujú priemernú spotrebu paliva.



Obr. 3 Priemerná spotreba paliva na 100 km u jednotlivých vodičov


E. Modelovanie

Po výbere a čistení dát môžeme pristúpiť k samotnému modelovaniu. Samotná podkapitola bude pozostávať z viacerých čiastkových experimentov.

Vplyv atribútov na priemernú spotrebu paliva

Cieľom experimentu bude prostredníctvom Naivného Bayesovského klasifikátora a dostupných dát identifikovať, ktoré atribúty majú najväčší vplyv na spotrebu paliva. Pre túto úlohu sme si zvolili programové prostredie Visual Studio 2013 s balíkom Business Intelligence.

V ďalšom kroku si rozdelíme dáta na tréningovú a testovaciu množinu a to v pomere 70:30. Po spustení procesu učenia Bayesovského klasifikátora získame nasledovný graf závislosti (Obr. 4). Na tomto obrázku máme možnosť vidieť, ktoré atribúty ovplyvňujú spotrebu paliva.

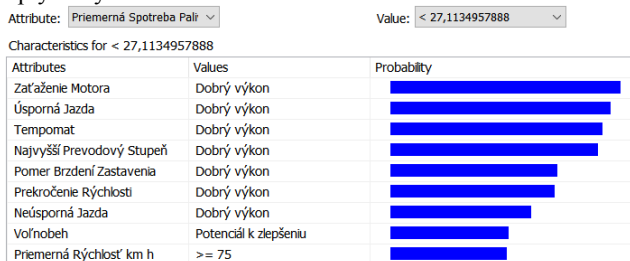


Obr. 4 Graf závislosti

Na grafe závislosti sa však vieme posúvať o rôzne úrovne, čím tak môžeme eliminovať slabšie väzby. Z čoho teda vyplýva, že na najnižšej úrovni grafu ostanú len atribúty, ktoré najviac ovplyvňujú priemernú spotrebu paliva.

Ak stále berieme do úvahy najnižšiu triedu spotreby paliva, pod 27,11 l/100 km, na Obr. 2 môžeme vidieť, že atribúty ako *zapaženie motora*, *úsporná jazda*, *tempomat*,

najvyšší prevodový stupeň, *pomer brzdení/zastavenia*, *prekročenie rýchlosti*, *neúsporná jazda*, *voľnobeň* a *priemerná rýchlosť nad 75 km/h* vplyvajú na spotrebu paliva pod 27 l/100 km. Na obrázku sú zobrazené atribúty s pravdepodobnosťou ovplyvu vyššou ako 50%.



Obr. 2 Atribúty vplyvajúce na najnižšiu triedu spotreby paliva


Návrh používateľských scenárov

Cieľom tejto časti modelovania je vytvoriť analýzy pre manažera logistickej firmy, prostredníctvom ktorých dokáže získať potrebné a cenné informácie. Vďaka takýmto informáciám môže používateľ sledovať nielen spotrebu vozidiel, vodiča alebo celého vozového parku, ale aj sledovať iné faktory, ktoré vplyvajú na spotrebu paliva, vďaka čomu môže uskutočňovať včasné a presné rozhodnutia.

Návrh používateľských scenárov bol realizovaný pomocou nástrojov Microsoft SQL Server 2016, Visual Studio a pomocou MS Excel s nástrojom analýzy údajov pre vytvorenie kontingenčnej tabuľky. Dôležitou úlohou bolo rozdelenie dát do tabuľky faktorov a tabuliek dimenzií na základe už pripravených dát. Databáza pre dátový model bola vytvorená v programe MS SQL Server 2016, kde bolo vytvorených 9 tabuliek dimenzií a jedna tabuľka faktorov. Prostredníctvom primárnych kľúčov sme prepojili tabuľky dimenzií s tabuľkou faktorov.

Analýza priemernej spotreby vodičov v jednotlivých krajinách


Cieľom ďalšej analýzy je určiť, v ktorých krajinách, akí vodiči dosahujú akú priemernú spotrebu paliva. Pre túto analýzu sme vybrali vodičov, ktorých celková prejedaná vzdialenosť je väčšia ako 100 000 km. Jedná sa o vodičov: Vodič_C, Vodič_D, Vodič_G, Vodič_I, Vodič_J, Vodič_K, Vodič_L.



Obr. 6 Celková vzdialenosť vodičov

Ďalej sme vybrali len tie štáty, medzi ktorými sa najazdilo viac ako 4000 km. Išlo o krajiny: Rakúsko, Belgicko, Česká republika, Nemecko, Dánsko, Francúzsko, Švajčiarsko, Taliansko, Holandsko, Švédsko a Slovensko. Následne sme namiesto počtu celkovej vzdialenosti pridali pole priemernej spotreby paliva a vybraných vodičov. Ako prvé sme

analyzovali jazdnú trasu smerujúcu z Nemecka do ostatných krajín. Podľa nasledujúceho obrázku (Obr. 7) môžeme vidieť spotrebu paliva jednotlivých vodičov smerujúcich z Nemecka do iných krajín, ako napr. Rakúsko, Belgicko, Česká republika, Nemecko, Dánsko... Prostredníctvom takejto analýzy môžeme povedať, že rôzni vodiči medzi krajinami mali rôznu spotrebu paliva. V prípade ak Vodič_C šiel z Nemecka do Rakúska, spotreboval 26,5 l/100 km, pričom Vodič_G spotreboval 32,2 l/100 km. Na trase Nemecko – Belgicko sa priemerná spotreba u všetkých vodičov pohybovala v rozmedzí 22 – 26 l/100 km. Na trase Nemecko – Česká republika dosahoval Vodič_I najhoršiu spotrebu paliva (37 l /100 km), pričom Vodič_D a Vodič_G dosahovali priemernú spotrebu paliva okolo 27,5 l/100 km. Zaujímavé výsledky dosiahli vodiči na trase Nemecko – Holandsko, kde Vodič_C spotreboval 22 l/100 km a Vodič_D spotreboval až 32 l/100 km. Dôvodom vyššej spotreby paliva môže byť zmena počasia, poprípade vyššia hmotnosť nákladu.



Obr. 7 Priemerná spotreba vodičov idúcich z Nemecka

F. Vyhodnotenie

Prostredníctvom vytvorenej databázy a programového nástroje sme na základe Naivného Bayesovského klasifikátora určili hlavné faktory, ktoré vplyvajú na priemernú spotrebu paliva. Môžeme povedať, že atribúty ako *priemerná rýchlosť*, *najvyšší prevodový stupeň* a *neúsporná jazda* majú najväčší vplyv na priemernú spotrebu paliva. Vplyv na najnižšiu triedu nízkej spotreby paliva, čo predstavovalo hodnotu menej ako 27,11 l/100 km, majú atribúty *zaťaženie motora*, *úsporná jazda*, *tempomat* a *najvyšší prevodový stupeň*. Manažér logistickej firmy môže poskytnúť odporúčania vodičom, aby zlepšili vybrané atribúty, ak chcú zlepšiť spotrebu paliva.


Ďalším experimentom sme sa zamerali na jednotlivých vodičov. Kompletne dáta sme rozdelili na 12 menších súborov, pričom každý súbor niesol informácie o danom vodičovi. Modely boli vytvorené pre každého jedného vodiča. Najčastejšie priemernú spotrebu paliva u vodičov ovplyvňoval atribút *najvyšší prevodový stupeň*, *úsporná a neúsporná jazda*, *tempomat* a *zaťaženie motora*. Po odstránení týchto nedostatkov môžu vodiči dosahovať vyšší výkon, nízku priemernú spotrebu paliva, čím tak budú jazdiť efektívnejšie.

Cieľom vytvorených používateľských scenárov bolo rýchlo, jednoducho a vizuálne prítiahlivejšie analyzovať jazdný štýl vodiča, vodičov, prevádzku jednotlivého vozidla alebo aj celého vozového parku. Keďže súčasný nástroj takéto analýzy neumožňoval, prostredníctvom SQL Server 2016 sme vytvorili databázu a prostredníctvom nástroja MS Excel s nástrojom analýzy údajov pre vytvorenie kontingenčnej

tabuľky sme analyzovali dostupné dáta. Takto vytvorené používateľské scenáre sú jednoduché, ľahko interpretovateľné a pochopiteľné. Prostredníctvom rôznych filtrov je možné pozerať sa na dáta z rôznych uhlov pohľadu bez akýchkoľvek obmedzení. Používateľské scenáre môžu pomôcť pri sledovaní spotreby paliva jednotlivých vozidiel alebo vodičov ako aj nájdení dôvodov vyššej spotreby paliva. Zaujímavou je aj možnosť sledovať vyťaženosť vodičov spolu s plánovaním jazdy na ďalšie dni. V porovnaní s už existujúcimi analýzami sú získané zistenia v používateľských scenároch niečím novým, nakoľko existujúce riešenia nepoužívajú business intelligence na vizualizáciu dát.

G. Nasadenie

Súčasný systém, ktorý používa logistická spoločnosť je nepostačujúci. Je možné zvoliť si rôzne výkazy s cieľom analýzy, ale nie je nijako možné vyberať ďalšie, pre manažéra logistickej firmy zaujímavé atribúty. V doposiaľ používanom nástroji nie je možné vytvárať reporty, či grafy a porovnávať medzi sebou spotrebu a rôzne iné atribúty. Na základe požiadaviek používateľa nie je možné v softvérovom nástroji Dynafleet Online – Volvo Truck Corporation kombinovať atribúty, iba prezerať výsledky podľa nástrojom vopred nastavených atribútov. Okrem toho sú dáta v tejto databáze po určitom čase automaticky mazané, kvôli čomu nie je možné pracovať s historickými dátami. Na Obr. 8 máme možnosť vidieť súčasný systém, ktorý spoločnosť využíva na analýzu údajov. Nie je nijako možné spojiť atribúty z dvoch rôznych výkazov.



Obr. 8 Súčasný používaný systém generovania výkazov

IV. NAVRHNUTÝ A VYTVORENÝ SYSTÉM PRE PODPORU ROZHODOVANIA

Systém bol navrhnutý pre manažéra logistickej firmy z dôvodu lepšieho pochopenia a spracovania dát pre podporu jeho rozhodovania pri pridelení vodičov a vozidiel na jazdné trasy. Prostredníctvom grafického rozhrania môže používateľ denne aktualizovať dáta z predošlého dňa, môže dáta štatisticky a graficky vyhodnotiť. Okrem toho systém ponúka vždy aktuálny prehľad faktorov vplyvajúcich na spotrebu paliva a celkové hodnotenie. Systém taktiež dokáže podľa stanovených parametrov odporučiť vodiča na plánovanú trasu. Po aktualizácii dát a uložení do databázy si môže manažér firmy stiahnuť dáta vo forme kontingenčnej tabuľky a vytvárať reporty.

Pre ľahšie ovládanie navrhovaného systému je grafické rozhranie rozdelené nasledovne:

- Aktualizácia dát
- Štatistika
- Vplyv na priemernú spotrebu paliva
- Vplyv na celkové hodnotenie
- Rozhodovacie stromy

- Odporúčanie

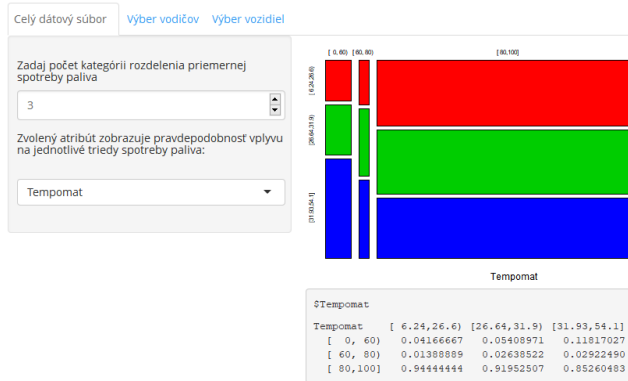
Štatistika

Táto časť aplikácie obsahuje viacero popisných charakteristík výsledného, denne aktualizovaného súboru, vrátane grafov a korelácií. Ďalšia záložka obsahuje sumár atribútov aktualizovaného súboru v predošlej časti. Poskytuje informácie o minimálnej, maximálnej, priemernej, strednej hodnote a ďalších štatistických ukazovateľoch. Záložka grafy umožňuje používateľovi rýchly a jednoduchý náhľad na vizualizáciu dát. Používateľ si môže zvoliť typ grafu.

Vplyv atribútov na priemernú spotrebu paliva

Ďalšia navrhovaná funkcionálnosť v systéme je záložka venujúca sa analýze vplyvu atribútov na priemernú spotrebu paliva a skladá sa z troch častí a to: z analýzy celého dátového súboru, z výberu vodičov a z výberu vozidiel. V pozadí aplikácie bežia algoritmy strojového učenia.

V tomto prípade sme si priemernú spotrebu paliva rozdelili na tri intervaly a zisťovali sme vplyv tempomatu na priemernú spotrebu paliva. Z obrázku (Obr. 9) môžeme povedať, že s efektívnym využívaním tempomatu dosiahne vodič s pravdepodobnosťou 94,44% spotrebu paliva v rozmedzí 6,24 – 26,6 l/100 km. Výsledok môžeme vyčítať z tabuľky, ale aj z grafu. Súčet každého stĺpca tabuľky musí mať hodnotu 1, čo predstavuje 100%. Ide o pravdepodobnosť pre danú triedu spotreby paliva. Naopak, riadky v grafe predstavujú pravdepodobnosť dosiahnutia spotreby paliva v určitej triede. Os x zobrazuje pravdepodobnosť zvoleného atribútu na jednotlivé triedy spotreby paliva. Čím je riadok širší, tým je pravdepodobnosť väčšia. Os y predstavuje rozdelenie tried spotreby paliva. V tomto prípade, čím je stĺpec vyšší, tým je pravdepodobnosť v danej triede spotreby paliva väčšia.

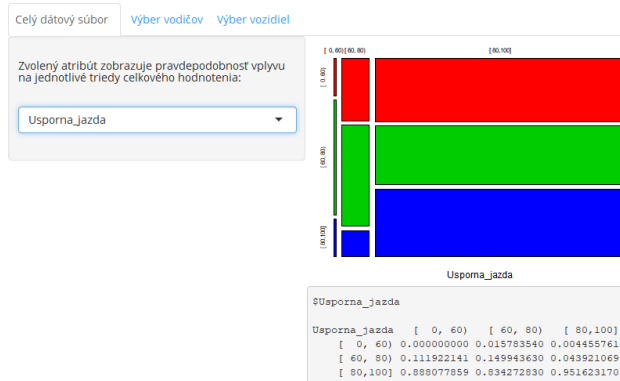


Obr. 9 Vplyv tempomatu na spotrebu paliva

Vplyv atribútov na priemernú spotrebu paliva

Po testovaní systému v logistickej firme bola na podnet manažéra spoločnosti pridaná do systému ďalšia funkcionálnosť. Ide o možnosť zobrazenia vplyvu atribútov na celkové hodnotenie (Obr. 10). Pre vlastníka spoločnosti hrá kľúčovú rolu aj celkové hodnotenie, teda hodnotenie jazdného štýlu vodiča. Štýl jazdy môžeme chápať ako individuálnu charakteristiku vodiča. Správanie vodiča je ovplyvnené mnohými faktormi, ako sú dopravná situácia, prostredie, kontext jazdy a osobnostné charakteristiky vodiča. Z týchto

hľadísk je dôležité porozumieť chovaniu vodiča. Funkčnosť sledovania atribútov vplyvajúcich na celkové hodnotenie je v princípe rovnaký ako v prípade sledovania atribútov vplyvajúcich na priemernú spotrebu paliva. Používateľ si môže vybrať, či bude sledovať celý dátový súbor, jednotlivých vodičov alebo jednotlivé vozidlá.



Obr. 10 Analýza vplyvu atribútov na celkové hodnotenie

Na Obr. 10 môžeme vidieť analýzu atribútov, ktoré vplyvajú na štýl jazdy. V tomto prípade si nemôže používateľ zvoliť počet tried rozdelenia niektorých numerických atribútov (ide o atribúty *Priemerná spotreba paliva*, *Hmotnosť*, *Priemerná rýchlosť*, *Celková vzdialenosť*). Početnosť tried je pevne daná v kóde programu, z dôvodu rýchlejšieho a efektívnejšieho výpočtu a zobrazenia výsledkov. Na obrázku môžeme vidieť zobrazenie atribútu *Usporná jazda* v grafickej podobe ako aj formou matice s pravdepodobnosťami zaradenia atribútu do danej triedy.

Odporúčanie

Posledná časť aplikácie sa venuje samotnému odporúčaniu vodiča na plánovanú dodaciu trasu. Princíp fungovania poslednej časti systému je podobný ako predchádzajúce časti aplikácie aj v tomto prípade ide o plne automatizovanú a denne aktualizovanú funkcionálnosť. Na Obr. 11 máme možnosť vidieť menu pre výber parametrov, na základe ktorých systém vypočíta pravdepodobnosti jednotlivých vodičov. Ide o pravdepodobnosti týkajúce sa atribútu rozhodovania.

Odporúčanie vodiča

Zvoľ parametre:

Štát (z)
Nemecko

Mesto (z)
Rostock

Štát (do)
Švédsko

Mesto (do)
Trelleborg

Zvoľ vzdialenosť (km)
[200, 400)

Zvoľ hmotnosť (kg)
[10000,20000)

Zvoľ mesiac
Marec

Zvoľ atribút rozhodovania
Priemerná_spotreba_paliva

Zadaj počet kategórií rozdelenia priemernej spotreby paliva
3

Obr. 11 Výber parametrov pre odporúčanie vodiča

Pre ukážku sme si zvolili trasu Rostock (Nemecko) – Trelleborg (Švédsko) so vzdialenosťou z intervalu [200, 400) a hmotnosťou z interval [10000, 20000). Pre mesiac sme vybrali marec, z dôvodu, že testovanie prebiehalo v marci. Ako atribút rozhodovania sme vybrali priemernú spotrebu paliva s rozdelením do troch intervalov. V pozadí aplikácie sa spúšťajú modely pre všetkých vodičov, pričom vstupom do testovacej množiny sú používateľom zadané parametre a výstupom sú pravdepodobnosti tried priemernej spotreby paliva (alebo celkovej hodnoty) jednotlivých vodičov. Z výslednej tabuľky (Obr. 12) môžeme povedať, že Vodič_A na trase Rostock – Trelleborg spotrebuje s pravdepodobnosťou 67 % palivo v rozmedzí intervalu 31,93 – 54,1 l/100 km. Vodič_C s pravdepodobnosťou 68 % spotrebuje menej ako 26,6 l/100 km. Vodič_D na tej istej trase spotrebuje viac ako 31,93 l/100 km a to s pravdepodobnosťou 97%. Používateľ si môže počet intervalov rozdelenia priemernej spotreby paliva meniť a následne uvidí aktualizované pravdepodobnosti.

	6.24-26.6	26.65-31.93	31.93-54.1	Dátum poslednej jazdy	Počet dní jazdy	Počet dní kedy vodič nejazdil
Vodič_A	0.06	0.27	0.67	2018-02-13	-	36
Vodič_B	0.23	0.40	0.37	2018-03-16	19	5
Vodič_C	0.68	0.27	0.05	2018-01-25	-	55
Vodič_D	0.01	0.02	0.97	2018-03-20	6	1
Vodič_E	0.56	0.33	0.10	2018-02-02	-	47
Vodič_F	0.00	0.04	0.96	2017-06-02	-	292
Vodič_G	0.59	0.33	0.08	2018-03-20	15	1
Vodič_H	0.56	0.33	0.10	2017-03-20	-	366
Vodič_I	0.68	0.27	0.05	2018-03-03	6	18
Vodič_J	0.01	0.07	0.93	2017-09-07	-	195
Vodič_K	0.08	0.05	0.87	2018-03-19	21	2
Vodič_L	0.65	0.29	0.06	2018-03-19	33	2

Obr. 12 Pravdepodobnosti spotreby paliva v troch intervaloch

Keďže náš návrh riadenia logistiky pozostáva aj z bázy znalostí, v tejto časti aplikácie sa využívajú pravidlá uložené v systéme na základe štruktúry riadenia logistiky (Obr. 1). Posledné tri stĺpce tabuľky, znázornené na Obr. 12, poskytujú časové údaje o jazde jednotlivých vodičov. Údaje v týchto stĺpcoch sa viažu k dátumu 21. marec 2018, kedy v logistickej firme prebiehalo testovanie navrhovanej aplikácie. Informácie a dáta sú aktualizované k predošlému dňu, čo je v našom prípade 20. marec 2018. Stĺpec o dátume poslednej jazdy hovorí, kedy vodič naposledy jazdil. Použitý formát dátumu je rok-mesiac-deň. Keďže spoločnosť disponuje šiestimi vozidlami, počet dní jazdy sa vypočítava z dátumu v poslednom riadku jednotlivých vozidiel, pričom sa testuje podmienka atribútu *meno*. Ak podmienka neplatí odrátajú sa dátumy a určí sa počet dní, kedy vodič jazdil. Okrem toho sa uloží aj meno vodiča, ktorý viedol dané motorové vozidlo. Tento údaj sa zapisuje do tabuľky k danému vodičovi. Počet dní, kedy vodiči nejazdili používa funkciu aktuálneho dátumu `Sys.Date()` a odpočítava od dátumu poslednej jazdy. Údaj o počte dní jazdy pomôže manažérovi spoločnosti rozhodnúť, či vodič už má nárok na voľno. Informácia o počte dní, kedy vodič nejazdil zase poskytuje informáciu o pracovnom voľne vodiča.

V. ZÁVER

Predložený článok sa zameriava na prepojenie troch oblastí, a to: logistiky, podpory rozhodovania a analýzy dát, kedy sa tieto kľúčové pojmy spájajú a na základe analýzy dát vytvárajú systém podpory rozhodovania v logistickom procese. Hlavným cieľom práce bolo navrhnuť a na získaných dátach logistickej firmy verifikovať systém pre podporu rozhodovania o priradzovaní vodičov na dodacie trasy. Návrh systému vychádzal z vlastnej štruktúry riadenia logistiky, ktorá bola oproti iným doplnená o bázu znalostí a o možnosti aktualizácie dát. Možnosť aktualizácie dát posunula systém na vyššiu úroveň, pretože systém dokáže preučiť modely spúšťané na pozadí aplikácie a manažérovi spoločnosti tak dokáže poskytnúť aktuálne informácie. Podciele práce súviseli s aplikáciou metodiky CRISP-DM na dáta, kedy sme pomocou metód analýzy dát určili hlavné faktory vplyvajúce na spotrebu paliva s cieľom identifikovať najvhodnejšie štýly vodičov a jazdné postupy. Vytvorený systém sme overili v zvolenej logistickej spoločnosti na základe čoho môžeme v nasledujúcich častiach kapitoly zhodnotiť výsledky nášho

vedeckého bádania ako aj zhodnotiť prínosy pre ďalší rozvoj vedy a prax.

POĎAKOVANIE

This work was supported by the Slovak Research and Development Agency under the contract No. APVV-16-0213 and by the Slovak Grant Agency of the Ministry of Education and Academy of Science of the Slovak Republic under grant No. 1/0493/16.

Abstrakt v Anglickom jazyku

This dissertation thesis is focused on linking of logistics, decision support and data analysis. The work deals with the interconnection of these key concepts, where based on the data analysis, a decision support system has been designed and created in the logistics process. The theoretical part of the thesis deals with the analysis of the current state of the research problem in the world together with the proposal of solving specific research problems within the context of a case study in a logistics company. It therefore describes also the current situation and currently used system in the chosen logistics company, together with a description of the used research methods. The practical part of the research is aimed at creating a decision support system based on the proposed structure of logistics management. The CRISP-DM methodology, which is applied to the data of the logistics company, is the basic starting point for the creation of the system. The proposed system is able to identify key factors affecting fuel consumption or driving style of individual drivers, as well as related metrics of the entire fleet. The information and knowledge that the system offers to the user are daily updated and stored in the database. It means that the logistics decision support system can offer up-to-date information and models. Through the information and knowledge gained, the logistics manager can make timely and accurate decisions. Based on this information and specified parameters, the system can recommend the driver to the planned delivery route. Updated data is available from the database in the form of excel files which enables also OLAP analysis.

REFERENCIE

- [1] Fayyad, U. M. a kol.: *Advances in Knowledge Discovery and Data Mining*. Cambridge MA: AAAI Press/MIT Press, 1996.
- [2] Guidici, P.: *Applied Data Mining. Statistical Methods for Business and Industry*. USA: John Wiley and Sons, Inc., 2004, 2 pp.
- [3] Kantardzic, M.: *Data Mining. Concepts, Models, Methods, and Algorithms*. USA: John Wiley and Sons, Inc., 2003, 5 pp.
- [4] Terek, M. a kol.: *Hĺbková analýza údajov: Prvé vydanie*. Bratislava: Ekonomická univerzita, 2010. 265 pp., ISBN 978-80-8078-336-5.
- [5] Berglund, M., Laarhoven, P., Sharman, G.: *Third-Party Logistics: Is There a Future*. In: *The International Journal of Logistics Management*, 2006. pp. 59-70, ISSN 0957-4093.
- [6] Daoping, W., Xiaojing, X.: *Analysis and Design of the Logistics Information System Based on Data Mining*. In: *Intelligent Computation Technology and Automation (ICICTA)*, International Conference on. Changsha: IEEE, 2010. pp. 635-638, ISBN 978-1-4244-7279-6.
- [7] Congna, Q., Hui Feng, Z.: *Study on Application of Data Mining Technology to Modern Logistics Management Decision*. In: *International Forum on Information Technology and Applications*, 2009. pp. 433-436, ISBN 978-0-7695-3600-2.
- [8] Dejun, L., Guangsheng, Z.: *Application of data mining technology in modern agricultural logistics management decision*, *Journal of Shenyang Normal University (Natural Science)*, 2008, pp.310-312. [online]. [cit. 2017-12-11]. Dostupné na internete: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.456.747&rep=rep1&type=pdf>
- [9] Golden, B., Raghavan, S., Wasil, E.: *The Vehicle Routing Problem: Latest Advances and New Challenges*, vol. 43 of *Operations Research/Computer Science Interfaces Series*. Springer, Berlin, 2008. 591 pp. ISBN 978-0-387-77778-8.
- [10] Goel, A., Irnich, S.: *An Exact Method for Vehicle Routing and Truck Driver Scheduling Problems*. In: *Transportation Science*, 2016. pp. 1-18, ISSN1526-5447.
- [11] Chen, S. a kol.: *A Crew Scheduling with Chinese Meal Break Rules*. In: *Journal of Transportation Systems Engineering and Information Technology*, 2013. pp. 90-95. ISSN 1570-6672.
- [12] Drexl, M., Rieck, J., Sigl, T.: *Simultaneous Vehicle and Crew Routing and Scheduling for Partial-and Full-Load Long- Distance Road Transport*. In: *Business Research*, Springer International Publishing, 2014. pp.242 – 264. ISSN 2198-3402.
- [13] Ferreira, J., Almeida, J., Silvia, A.: *The Impact of Driving Styles on Fuel Consumption: A Data Warehouse and Data Mining based Discovery Process*. In: *IEEE Transactions on Intelligent Transportation Systems*, 2015, pp. 2653 – 2662. ISSN 1524-9050.
- [14] Ma, H., Xie, H., Huang, D., Xiong, S.: *Effects of driving style on the fuel consumption of city buses under different road conditions and vehicle masses*. In: *Transportation Research part D: Transport and Environment*, 2015. pp. 205 – 216. ISSN 1361-9209.
- [15] *Systém na komunikáciu s vozidlami Dynafleet Online – Volvo Truck Corporation*, dostupné na internete: <http://www.volvotrucks.com/trucks/dynafleet-help/splash/Pages/splash.aspx>

Implementácia protokolu P_{RO}PHET v prostredí OPNET s prvkami bezpečnosti

Roman PALITEFKA

Katedra elektroniky a multimediálnych telekomunikácií
Fakulta elektrotechniky a informatiky TUKE
Košice, Slovenská Republika
roman.palitefka@student.tuke.sk

Ľubomír DOBOŠ

Katedra elektroniky a multimediálnych telekomunikácií
Fakulta elektrotechniky a informatiky TUKE
Košice, Slovenská Republika
lubomir.dobos@tuke.sk

Abstract—Delay Tolerant Networks (DTN) with store and forward architecture are able to operate in environment with considerable delays and intermittent connectivity. Evaluation of such networks and protocols requires reliable simulation tool as is OPNET (Optimized Network Engineering Tool) modeler. One drawback of the OPNET is missing implementation of the wireless DTN protocols and models, therefore we developed bundle protocol extension and the forwarding algorithm based on the history of past encounters P_{RO}PHET (Probabilistic Routing Protocol using History of Encounters). Protocol enables communication between participating nodes in an intermittently connected network where at least few of the nodes are mobile nodes. We implemented to protocol also new security component able to measure the social pressure of the two contacts and this information can be used for security purposes.

Keywords—P_{RO}PHET; Delay Tolerant Network (DTN), Social pressure metric

Abstrakt—Sieť tolerujúce oneskorenie DTN (Delay Tolerant Networks) s architektúrou uložiť a prepošli (store and forward) sú schopné pracovať v prostredí so značným oneskorením a prerušovaným spojením. Preverovanie takýchto sietí a protokolov vyžaduje spoľahlivý simulačný nástroj akým je napríklad OPNET (Optimized Network Engineering Tool) modeler. Podstatným nedostatkom OPNET modeleru je chýbajúca implementácia bezdrôtových DTN protokolov a modelov, preto sme vyvinuli rozšírenie OPNET modeleru o balíkový protokol a smerovací algoritmus založený na histórii stretnutí P_{RO}PHET (Probabilistic Routing Protocol using History of Encounters). Protokol umožňuje komunikáciu medzi dvoma zariadeniami v sieti s prerušovaným spojením, kde prinajmenšom niekoľko zariadení je mobilných. V článku sa zaoberáme implementačnými detailmi protokolu. Protokol sme rozšírili o výpočet metriky sociálneho tlaku, ktorá slúži pre posilnenie bezpečnosti protokolu.

Keywords— P_{RO}PHET; Sieť Tolerujúce Oneskorenie, Metrika sociálneho tlaku

I. ÚVOD

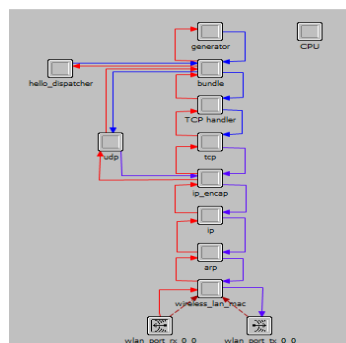
Štandardné bezdrôtové siete používajú koncept komunikácie bod - bod zdedený zo spoľahlivých fixných sietí. Tento koncept však nie je ideálny pre bezdrôtové siete, ktoré pracujú väčšinou rozpojené, tiež označované ako siete tolerujúce oneskorenie DTN (Delay Tolerant Networks) [1]. Aj napriek tomu, že OPNET modeler patrí medzi výkonné simulačné nástroje pre fixné ako aj bezdrôtové siete,

neobsahuje žiadnu implementáciu DTN protokolov a modelov. Rozhodli sme sa preto navrhnúť a implementovať balíkový protokol prenosu dát a smerovací DTN algoritmus založený na histórii stretnutí P_{RO}PHET [2,3,7].

Autori smerovacieho protokolu P_{RO}PHET upozorňujú na jeho slabú odolnosť voči útokom typu čierna diera (Black hole), kedy zlomyseľný uzol predstiera, že je vhodný kandidát na preposielanie balíkov iným uzlom v DTN sieti. Prezentuje sa tak, že má častý kontakt s cieľovým uzlom a preto je vhodné preposlať mu dáta. Častý kontakt dvoch uzlov v sieti DTN sa považuje za pozitívny parameter vedúci k väčšej výmene dát, preto sú takéto uzly pre prenos dát uprednostňované. Okrem množstva prenesených dát, musíme však mať stále na pamäti aj bezpečnosť spojenia. Pokiaľ ide o veľké bezpečnostné riziko, je lepšie dáta vôbec neodosielať.

Protocol P_{RO}PHET nemá žiadne bezpečnostné vylepšenia a je náchylný na útoky typu čierna diera, rozhodli sme sa preto pridať do protokolu aj nový bezpečnostný prvok, ktorý je schopný určiť sociálny tlak dvoch kontaktov. Uzly s nízkou hodnotou sociálneho tlaku môžeme potom považovať za bezpečnostné riziko a môžeme s nimi obmedziť alebo úplne odmietnuť spojenie.

Štruktúra článku je nasledovná: v nasledujúcej časti sa najskôr zaoberáme implementačnými detailmi DTN protokolu P_{RO}PHET; v časti III. pokračujeme s popisom simulácie a výsledkami simulácie; ďalej nasleduje naše bezpečnostné rozšírenie a článok ukončujeme v časti V. záverom a zoznamom použitej literatúry.



Obr. 1. Model uzla

II. MODEL PROTOKOLU PROPHET V MODELERI OPNET

Model zariadenia, akým je mobilné zariadenie, bezdrôtová základňová stanica a podobne je označované v OPNET modeleri ako "model uzla". Celkovú architektúru nášho modelu uzla máme znázornenú na obrázku Obr. 1.

Protokol PROPHET sa pokúša využiť nenáhodné vzorce mobility, vyskytujúce sa v rôznych aplikačných prípadoch, na vylepšenie smerovacieho procesu. Namiesto slepej epidemickej replikácie, aká je použitá v niektorých starších protokoloch, je použitá na replikáciu dát „pravdepodobnostné smerovanie“. Protokol vychádza z predpokladu, že pohyb zariadení v typickej mobilnej sieti nie je náhodný a môže byť predvídateľný. Zariadenia sa pohybujú na základe predvídateľného vzoru, ktorý je založený na opakovaných stretnutiach.

Vzhľadom na to, že OPNET modeler neobsahuje žiaden ucelený balík na prácu s DTN sieťami, vytvorili sme architektúru uzla s podporou balíkovej vrstvy, rovnako sme implementovali logiku protokolu PROPHET a ich činnosť sme overili simuláciami.

Pri návrhu modelu uzla sme použili za základ existujúci model uzla wlan_wkstn_adv z knižnice OPNET. Niektoré nepotrebné komponenty uzla sme počas vývoja vyhodili, iné potrebné pre správnu činnosť protokolu PROPHET sme naopak pridali.

Kľúčovými prvkami nášho modelu sú bloky balíkovej vrstvy (bundle) a hello_dispatcher. Blok riadiaci zostavovanie TCP spojenia, TCP handler, by mal byť súčasťou balíkoveho bloku ale pre účely prehľadnosti sme ho vytvorili samostatne. Balíková vrstva v prípade potreby požiada tento blok o vytvorenie nového TCP spojenia, cez ktorý sú potom odosielané balíky.

Okrem toho sme pridali do modelu nášho uzla aj konfigurovateľný generátor paketov, ktorý nám zabezpečí úplnú kontrolu nad odosielanými ale aj prijatými dátami, nakoľko obsahuje aj štatistickú časť pre prijaté pakety z balíkovej vrstvy. Z pohľadu OSI modelu, generátor predstavuje aplikačnú vrstvu. Balíková vrstva, hello_dispatcher, TCP handler sú na úrovni balíkovej vrstvy, nižšie sú transportné protokoly TCP, UDP a nasledujú ostatné nižšie vrstvy OSI modelu, ako je zrejmé z ich názvu: ip_encap, ip, arp, wireless_lan_mac, wlan_port_rx, a wlan_port_tx. Transportné bloky TCP, UDP a všetky nižšie funkčné časti sme nemenili, s výnimkou na úrovni fyzickej vrstvy, kde sme menili vyžarovací výkon uzla podľa potrieb simulácií.

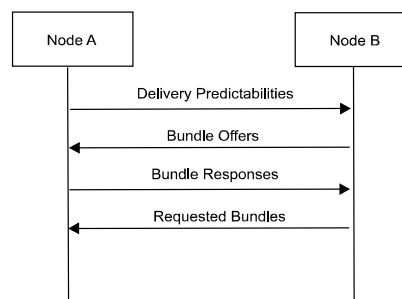
A. Modul HELLO dispatcher

Modul *hello_dispatcher* má nasledujúce funkcie:

- Detekcia susedov – fungovanie protokolu PROPHET je závislé na schopnosti detegovať susedov a udržiavať informácie o ich stave. Takýto mechanizmus nie je súčasťou protokolu PROPHET, preto tieto funkcie musia poskytovať

nižšie vrstvy alebo musí existovať iný mechanizmus na detekciu susedných uzlov. V našom prípade *hello_dispatcher* vysiela v pravidelných časových intervaloch signál obsahujúci identitu uzla a informáciu o frekvencii vysielať signálu. Tento signál sa označuje aj ako „*hello signál*“. Keď uzol prvý krát prijme tento signál, uloží si identitu uzla do tzv. zoznamu aktívnych susedov, spolu s hodnotou opakovania a aktuálneho času. Ak je už uzol v zozname aktívnych susedov, aktualizuje sa čas a v prípade, že sa zmenila aj hodnota opakovacieho intervalu, aktualizuje ju. V prípade, že uzol neprijme od iného uzla signál do špecifikovaného časového intervalu, je tento považovaný za neaktívny uzol.

- Udržiavanie hodnôt predvídateľnosti doručenia (delivery predictabilities) – Ak existuje komunikačná príležitosť medzi dvoma uzlami PROPHET, tieto začnú fázu výmeny informácií IEP (Information Exchange Phase). V prvej fáze výmeny sú navzájom poskytnuté všetky údaje predvídateľnosti doručenia. Výmena týchto údajov je vykonaná každým uzlom individuálne, s cieľom aktualizovať internú predvídateľnosť doručenia každého uzla, ako je definované v [4].



Obr. 2. Výmena informácií medzi uzlami

- Udržiavanie informácií o balíkoch (bundles) – Každý uzol udržiava informácie o uložených balíkoch, jednak o tých, ktoré sám vygeneroval alebo balíkoch, ktoré prechádzajú daným uzlom a sú dočasne uložené v uzle.

- Výber balíkov na prenos – V druhej časti informačnej výmeny si uzly navzájom vymenia informácie o ponúkaných balíkoch na prenos (bundle offers). Na základe týchto informácií, aktuálnej kapacity dočasnej pamäte, stratégie zvolenej pre prenos a aktualizovaných údajov predvídateľnosti doručenia sa uzol rozhodne, ktoré balíky akceptuje a odošle o tom informáciu susednému uzlu (bundle responses). Ten po prijatí tejto informácie začne požadované balíky (requested bundles) vysielať susednému uzlu. Celý tento proces máme vykreslený na obrázku Obr. 2. Je potrebné upozorniť, že obrázok vykresľuje proces prenosu z pohľadu uzla A k uzlu B, úplne rovnaká komunikácia prebieha aj opačným smerom.

B. Modul Bundle

Kľúčové funkcie modulu *bundle* sú nasledovné:

- Uloženie balíkov do pamäte uzla – každý balík

prijatý z vyššej vrstvy je okamžite uložený do dočasnej pamäte, podobne každý balík prijatý z nižších vrstiev, pre ktorý je daný uzol len prepravca (forwarder),

- Informovanie *hello_dispatcher* o nových balíkoch – Ak sú prijaté balíky z vyšších alebo nižších vrstiev, modul *bundle* informuje o tejto skutočnosti modul *hello_dispatcher*,
- Distribúcia balíkov – balíky, ktoré sú určené pre aktuálny uzol, sú odoslané vyšším vrstvám, balíky určené pre iné uzly sú v prípade kontaktu s nimi odoslané nižším vrstvám a potom cez fyzickú vrstvu uzlom,
- Udržiavania údajov v pamäti – Veľkosť pamäte je obmedzená, uzol preto musí niektoré balíky zahodiť.

C. Modul TCP Handler

Funkciou bloku „TCP handler je podľa požiadaviek „balíkového bloku“ zostavovať TCP spojenie s požadovaným uzlom a potom cez toto spojenie odosielať dáta. Z vyšších vrstiev potrebuje prijať okrem dátovej časti aj informácie o tom, pre koho je balík určený, deje sa to s použitím ICI (Interface Control Information). Posledným krokom po inicializácii bloku je vytvorenie pasívneho TCP spojenia a prechod do stavu čakania (wait). Uzol v tomto stave počúva na porte 162 a čaká na prípadne požiadavky zo siete, prípadne z vyšších vrstiev.

D. Generátor paketov

Aplikačnú vrstvu máme reprezentovanú generátorom paketov. Ide o existujúci generátor z knižnice OPNET s našimi malými úpravami. Vygenerovaný paket má dve časti, prvá je formátovaná a obsahuje štruktúru pre zapisovanie štatistických údajov počas prenosu paketu. Ide o unikátny identifikátor paketu, čas vygenerovania paketu a počet skokov, ktoré paket prekonal, kým dorazil do cieľa, na začiatku je inicializovaný na hodnotu 0. Druhá časť paketu je neformátovaná. Tento blok okrem generovania paketov, podľa špecifikovaných parametrov, prijíma aj pakety z balíkovej vrstvy, zisti a zapíše štatistické údaje do súboru a paket odstráni. Okrem samotného paketu generátor generuje údaj, pre koho je paket určený. Ide o reťazec, ktorý vieme preformátovať buď na IP adresu alebo iným spôsobom. Ide o unikátny identifikátor uzla v simulovanej sieti. Táto informácia je zaslaná do balíkovej vrstvy ako ICI.

III. VÝSLEDKY SIMULÁCIÍ

Pre overenie funkčnosti protokolu sme pripravili 3 simulačné scenáre s počtom 30uzlov a rýchlosťami uzlov akoje špecifikované v tabuľkeTab. I.

Aplikačná vrstva bola reprezentovaná generátorom paketov s veľkosťou paketu od 1 – 5MB (rovnorné rozloženie). Rozloženie času príchodu (inter-arrival time) paketov bolo exponenciálne s hodnotou 7200s. Cieľová destinácia paketu bola vybraná náhodne.

E. Parametre sledované pri simulácii

Počas simulácií sme sledovali tieto parametre: *priemerné oneskorenie balíkov*, *strednáhodnota cesty*, ktoré balíky prekonal, kým dorazili do cieľa. *Priemerné oneskorenie balíkov*: Ide o celkový čas, ktorý uplynie počas prenosu balíka cez sieť od zdroja k cieľu. Meranie oneskorenia začína vygenerovaním paketu a uložením do dočasnej pamäte uzla a končí doručením balíka z nižších vrstiev do aplikačnej vrstvy. V tabuľke výsledkov máme uvedený údaj o najkratšom a najdlhšom oneskorení balíka.

Stredná hodnota cesty: Ide o priemerný počet uzlov, ktorými prešiel balík, kým dorazil do cieľa. V tabuľke máme uvedený údaj aj pre najkratšiu a najdlhšiu cestu.

Tab. I
Parametre použité pri simulácii

Parameter	Hodnota
Smerovací protokol	PRoPHET
Parametre protokolu	$\beta = 0.9; \gamma = 0.999; \delta = 0.01$
Plocha simulácie	2000 m x 2000 m
Čas simulácie	86400 s
Dosah uzla	100 m
Počet uzlov	30
Rýchlosť uzlov	0 - 2m/s , 0 - 14 m/s, 14 - 25 m/s
Umiestnenie v modeli	náhodné
Model mobility	Default Random Waypoint s časom pauzy 100 s
Vyžiarený výkon	60.0 μ W
Fyzická vrstva	IEEE 802.11b

Tab. II
Výsledky simulácií pri rýchlosti 0-2m/s

Parameter	Hodnota
Počet vzoriek	11216
Stredná hodnota cesty	1,1442
Štandardná odchýlka	0,4985
Minimálna cesta	1
Maximálna cesta	7
Priemerné oneskorenie	9408,90s
Štandardná odchýlka	9737,94s
Minimálne oneskorenie	1,2565s
Maximálne oneskorenie	83215,08s

Tab. III
Výsledky simulácií pri rýchlosti 0-14m/s

Parameter	Hodnota
Počet vzoriek	10555
Stredná hodnota cesty	1,1090
Štandardná odchýlka	0,4310
Minimálna cesta	1
Maximálna cesta	5
Priemerne oneskorenie	5142,0s
Štandardná odchýlka	7891,1s
Minimálne oneskorenie	0,6046s
Maximálne oneskorenie	83147,77s

Tab. IV
Výsledky simulácií pri rýchlosti 14-25m/s

Parameter	Hodnota
Počet vzoriek	10283
Stredná hodnota cesty	1,1092
Štandardná odchýlka	0,4452
Minimálna cesta	1
Maximálna cesta	5
Priemerne oneskorenie	3153,891s
Štandardná odchýlka	5490,13s
Minimálne oneskorenie	1,338s
Maximálne oneskorenie	60814,41s

Z výsledkov vidíme, že vzhľadom na počet uzlov v sieti a relatívne malú plochu, väčšina balíkov je doručená priamo pri kontakte zdrojového uzla s cieľovým. Oneskorenie v sieti je pre aplikáciu DTN primerané. Iné simulačné scenáre sme publikovali v [2,3,7].

III. BEZPEČNOSŤ PROTOKOLU PROPHET

Tak ako je bezpečnosť dôležitým prvkom vo všetkých fixných sieťach, rovnako zostáva dôležitá aj v novovznikajúcich DTN, MANET a hybridných MANET-DTN sieťach. Oproti známym bezpečnostným problémom z fixných sietí pribudli nové, špecifické problémy charakteristické pre tieto nové siete. Mohli by sme tu zaradiť napríklad problém distribúcie kľúčov z autorizačných autorít, nedostatočná anonymita používateľov siete, slabá kooperácia zariadení a známy problém z pevných sietí s nevyžiadanimi správami. Pri návrhu bezpečnostných opatrení sme limitovaní

podobnými obmedzeniami ako pri návrhu smerovacích protokolov, a to hlavne nedostatkom zdrojov vyplývajúcich z povahy mobilnej komunikácie

Autori smerovacieho protokolu PROPHET upozorňujú na jeho slabú odolnosť voči útokom typu čierna diera (Black hole), kedy zlomyseľný uzol predstiera, že je vhodný kandidát na preposielanie balíkov iným uzlom v DTN sieti. Prezentuje tak, že má častý kontakt s cieľovým uzlom a preto je vhodné preposlať mu dáta. Častý kontakt dvoch uzlov v sieti DTN sa považuje za pozitívny parameter vedúci k väčšej výmene dát, preto sú takéto uzly pre prenos dát uprednostňované. Okrem množstva prenesených dát, musíme však mať stále na pamäti aj bezpečnosť spojenia. Pokiaľ ide o veľké bezpečnostné riziko, je lepšie dáta vôbec nedosielat.

A. Dôveryhodnosť

Na dôveryhodnosť v sociálnych väzbách má veľký vplyv, okrem iného, aj celkový čas trvania sociálnej väzby. Môžeme vo všeobecnosti povedať, že s narastajúcim časom sa naša schopnosť zhodnotiť kvalitu väzby zlepšuje. Povaha každodenných aktivít nás smeruje do vytvárania určitých skupín, komunit so svojimi osobitými vlastnosťami. Z pravidiel máme príslušnosť k viacerým skupinám.

Keď tento poznatok preniesieme do prostredia DTN, je veľký predpoklad, že aj dáta ktoré členovia komunity budú preposielat, skočia v danej komunite alebo komunita bude použitá na prenos týchto údajov. Na mobilný uzol sa môžeme teda pozerat' aj ako na člena určitej komunity. Nový uzol v bezdrôtovom dosahu takto vstupuje okrem do siete tvorenej inými zariadeniami aj do "určitého vzťahu" s komunitou. Na takéto uzly je potrebné pozerat' sa s určitou opatrnosťou a je dobré keď o nich vieme. Navrhli sme preto rozšírenie protokolu PROPHET o algoritmus, ktorý je schopný zo signalizačných údajov zhromažďovat' informácie o celkovom čase kontaktu a časoch vzniku/zániku kontaktu, tieto údaje sú použité pri výpočte metriky sociálneho tlaku. Čím je hodnota tohoto parametra vyššia, kontakty dvoch uzlov sú tesnejšie.

B. Metrika sociálneho kontaktu


Určiť sociálny vzťah medzi dvoma uzlami sa pokúšali autori vo viacerých prácach. Existuje viacero metrik založených na frekvencii spojení, celkovom čase alebo priemernom čase kontaktu, priemernom čase medzi spojeniami a metrike sociálneho tlaku [8]. Metrika sociálneho tlaku SPM (Social Pressure Metric) dáva pomerne dobrý obraz o tom ako často nastáva kontakt (frekvencia kontaktu) a aká bola dĺžka kontaktu. Je definovaná nasledovne:

$$SPM_{a,b} = \frac{\int_{t=0}^T f(t)dt}{T} = \frac{\sum_{i=1}^m \int_{t_i}^{t_i+d_i} (t_i+d_i-t)dt}{T} \quad (1.1),$$


kde funkcia $f(t)$ vráti zostávajúci čas do ďalšieho kontaktu uzlov A a B po uplynutí času t , ak sú teraz uzly v kontakte

$f(t)=0$. Kde m je celkový počet časových úsekov, kedy boli uzly v rozpojenom stave počas sledovaného časového okna T .

Signalizačné správy protokolu PROPHET [4] sme použili na zistenie v akom stave sa spojenie práve nachádza a tieto získané údaje nám slúžili ako vstup do algoritmu pre výpočet metriky sociálneho tlaku (1.1). Na obrázku Obr. 3. a Obr. 4. vidíme celkový čas kontaktu dvoch uzlov počas jedného dňa, údaj sme získali poskladaním pozitívnych a negatívnych signalizačných správ odosielanými medzi uzlami.




Obr. 3. Celkový čas spojenia z pohľadu uzla A, rýchlosť pohybu 0-2m/s



Obr. 4. Celkový čas spojenia z pohľadu uzla B, rýchlosť pohybu 0-2m/s

Ďalej sme zistili zo správ, aký majú priebeh intervaly medzi spojeniami. Vykresľuje nám to Obr. 5.




Obr. 5. Čas medzi spojeniami dvoch uzlov, rýchlosť uzlov 0-2m/s


Na x-ovej osy máme časy vzniku nového kontaktu pre uzol A a B, na osy y máme zobrazený čas, aký uplynul od posledného kontaktu. Opäť vidíme, že údaje z oboch uzlov sa nám zhodujú.

Keď sme overili fungovanie našich dvoch algoritmov pre zisťovanie času spojenia, ako aj času medzi spojeniami, údaje z nich sme použili na výpočet metriky sociálneho tlaku.


Vykonal sme tri sady simulácií s počtom 100 simulácií v jednej sade. Simulovaný čas každej simulácie bol 24 hodín, overovali sme tri rýchlosti uzlov, tak ako v prípade protokolu PROPHET. Získané výsledky zo simulácie sme zobrazili graficky.



Obr. 6. Hodnoty metrick sociálneho kontaktu pri rýchlosti uzlov 0-2m/s



Obr. 7. Hodnoty metrick sociálneho kontaktu pri rýchlosti uzlov 0-14m/s



Obr. 8. Hodnoty metrick sociálneho kontaktu pri rýchlosti uzlov 14-25m/s

Z uvedených hodnôt sme získali strednú hodnotu a použili sme ju ako ako parameter protokolu PROPHET. V prípade, že

vypočítaná hodnota metriky sociálneho kontaktu je pod touto hodnotou, uzly nepokračujú komunikácií.

IV. ZÁVER

V príspevku sme prezentovali implementáciu DTN protokolu PRoPHET v OPNET modeli. Na to aby sme overili funkčnosť protokolu, uskutočnili sme simulácie s 30 mobilnými uzlami. Z výsledkov vidíme, podstatný vplyv mobility na oneskorenie balíkov a celkový počet odoslaných/prijatých balíkov. Okrem mobility majú na správanie protokolu vplyv aj prostredie a hodnoty parametrov protokolu [6]. Pri simulácii sme použili základné parametre ako boli odporúčané v [4].

Okrem implementácie protokolu PRoPHET, sme tento protokol rozšírili o výpočet metriky sociálneho tlaku, ktorá slúži pre posilnenie bezpečnosti protokolu.

V budúcnosti plánujeme implementovať ďalšie bezpečnostné prvky použiteľné nielen v prípade protokolu PRoPHET ale aj v iných DTN protokoloch.

ZOZNAM POUŽITEJ LITERATÚRY

- [1] P. Hui, J. Crowcroft, E. Yoneki, "BUBBLE Rap: Social-Based Forwarding in Delay-Tolerant Networks", *Mobile Computing, IEEE Transactions on*, pp. 1576-1589, vol. 10, issue 11, 2011.
- [2] J. Papaj, R. Palitefka, L. Doboš, "DTN modeling in OPNET modeler", In: *Journal of Electrical and Electronics Engineering*, ISSN 2067-2128. - Vol. 7, no. 1, p. 127-130, pp. 1-10, 2014.
- [3] J. Papaj, R. Palitefka, D. Kocur, A. Pietrikova, "PRoPHET protocol for DTN in OPNET", In: *Electrical Engineering and Informatics 5: Proceedings of the Faculty of Electrical Engineering and Informatics of the Technical University of Košice*, ISBN 978-80-553-1704-5, p. 798-803, 2014.
- [4] A. Lindgren, A. Doria, E. Davies, S. Grasic, "Probabilistic Routing Protocol for Intermittently Connected Networks", ISSN: 2070-1721, <http://tools.ietf.org/html/rfc6693>, August 2012.
- [5] Z. Lu, H. Yang, "Unlocking the Power of OPNET Modeler", Cambridge University Press 2012, ISBN 978-0-521-19874-5 Hardback, 2012.
- [6] A. Keränen, J. Ott, T. Kärkkäinen, "Simulating Mobility and DTNs with the ONE.", *Journal of Communications* 5.2: 92-105, 2010.
- [7] R. Palitefka, J. Papaj, L. Doboš, "How to simulate DTN in OPNET modeler", In: *Radioelektronika 2016, Danvers: IEEE*, 2016. - ISBN 978-150901674-7., pp. 381-385.
- [8] E. Bulut, B. K. Szymanski, "Friendship Based Routing in Delay Tolerant Mobile Social Networks" (2010), 1-5.

Videodohľadový systém s využitím optického korelátoru

František Rakoci

Katedra elektroniky a multimediálnych telekomunikácií
Fakulta elektrotechniky a informatiky, Technická univerzita
v Košiciach
Košice, Slovensko
ferorak@gmail.com

Ľuboš Ovseník

Katedra elektroniky a multimediálnych telekomunikácií
Fakulta elektrotechniky a informatiky, Technická univerzita
v Košiciach
Košice, Slovensko
lubos.ovsenik@tuke.sk

Abstrakt—Tento článok sa zaoberá návrhom automatického inventarizačného systému dopravných značiek s využitím optického korelátoru. Najkritickejšim krokom automatickej inventarizácie je rozpoznávanie dopravných značiek v zaznamenatej sekvencii obrazov. Miera podobnosti dvoch obrazov je určená ich krížovou koreláciou. Optický korelátor je zariadenie, ktoré je schopné vykonávať koreláciu optickou cestou. Výhodou jeho použitia je vysoká rýchlosť spracovania obrazu. Táto vlastnosť je využiteľná v systémoch automatického rozpoznávania dopravných značiek. Prvá časť článku sa zaoberá prehľadom súčasného stavu tejto problematiky a súvisiacimi teoretickými základmi. V ďalšej časti je predstavený návrh automatického inventarizačného systému. V poslednej časti článku je experimentálne overená funkcia a spoľahlivosť navrhnutého inventarizačného systému. Realizované experimenty sú podrobne opísané a ich výsledky sú vyhodnotené v závere.

Kľúčové slová— *automatická inventarizácia; dopravné značky; optický korelátor; spracovanie obrazu; videodohľadové systémy*

Abstract—This paper deals with a proposal of an automatic traffic signs inventory system with use of the optical correlator. The most critical step of the automatic inventory process is a recognition of the traffic signs in a recorded image sequence. A similarity rate between two images is determined by their cross-correlation. The optical correlator is a device, which is able to provide the correlation optical way. An advantage of its use is high image processing speed. This property is usable in automated traffic signs recognition systems. The first part of the paper deals with the current state of the problem and the theoretical basics. In the next part, a proposal for an automatic inventory system is presented and described in detail. The proposal of the system includes principles and algorithms for identifying traffic signs, determining their exact location and detecting their status, respectively damage. Results of inventory process are written to the inventory database. Interaction between the inventory system and user is provided through a graphical user interface. In the last part of the paper function and reliability of the proposed inventory system are experimentally verified. The realized experiments are described in detail and their results are evaluated in the conclusion.

Keywords— *automatic inventory, image processing, optical correlator, traffic signs, videosurveillance systems*

I. ÚVOD

Obrazové spracovanie vo videodohľadových systémoch zabezpečuje analýzu zaznamenaného obrazu, ktorej výsledkom sú informácie o objektoch, ich pohybe a ďalších parametroch. Konvenčná analýza vizuálnych informácií vyžaduje istú mieru ľudskej inteligencie, ktorá na základe dlhodobých skúseností a vedomostí dokáže reagovať na typické, ale aj nepredvídateľné informácie. Metódy počítačového videnia sú schopné do určitej miery nahradiť ľudské myslenie. Výskum a vývoj v oblasti videodohľadových systémov je zameraný práve na automatizované spracovanie obrazu a rozpoznávanie hľadaných objektov v ňom.

Kľúčovou metódou v procese rozpoznávania objektov v obraze je výpočet korelácie medzi vzorkami hľadaných objektov a referenčnými vzorkami. Korelácia je založená na báze Fourierových transformácií. Rýchlosť spracovania elektronickými systémami je výrazne závislá od množstva a hustoty spracovávaných informácií (rozlíšení spracovávaného obrazu). Zvyšovanie nárokov na množstvo spracovávaných informácií v rovnako krátkom čase má za následok dosiahnutie vrchnej hranice výpočtového výkonu elektronických zariadení. Riešením tohto problému v oblasti spracovania obrazu Fourierovými transformáciami je použitie vhodnej sústavy optických difrakčných šošoviek, vďaka ktorým je možné Fourierovu transformáciu dvojrozmerného signálu (obrazu) vykonávať v reálnom čase. Optická Fourierova transformácia je vo svojej podstate paralelným procesom, vďaka čomu rýchlosť spracovania principiálne nie je obmedzená množstvom spracovávaných informácií. Optický korelátor je zariadenie, ktoré pre svoju činnosť využíva práve vlastnosti difrakčných šošoviek a vykonáva tak Fourierovu transformáciu optickou cestou. Vhodným usporiadaním šošoviek a použitím doplnkových komponentov je možné zabezpečiť koreláciu dvoch vstupných vzoriek obrazu. Výsledkom tejto korelácie je korelačná rovina pozostávajúca z korelačných špičiek. Intenzita týchto špičiek určuje mieru podobnosti porovnávaných vzoriek a ich relatívne umiestnenie určuje relatívne umiestnenie porovnávaných vzoriek obrazu vo vstupnej rovine optického korelátoru.

Významnou oblasťou potenciálneho využitia technológie optického spracovania obrazu je rozpoznávanie dopravných značiek v zaznamenanom obraze. Dopravné značenie je nenahraditeľnou súčasťou dopravnej infraštruktúry. Jeho úlohou je riadenie premávky, navigácia a zvyšovanie bezpečnosti. Údržba dopravných komunikácií zahŕňa pravidelnú kontrolu stavu všetkých dopravných značiek a v prípade ich poruchy aj ich následnú opravu, alebo výmenu. S rozvíjajúcou sa infraštruktúrou sa zvyšujú požiadavky na efektívnosť vykonávania týchto rutinných úkonov. Navrhovaný systém by mal výrazne uľahčiť realizáciu detailnej inventarizácie.

Hlavným výpočtovým prvkom navrhovaného inventarizačného systému je vyššie spomenutý optický korelátor, ktorý dokáže vykonávať Fourierovu transformáciu optickou cestou vo veľmi vysokej rýchlosti. Vhodnou kombináciou spracovania obrazu optickým korelátorom je možné porovnávať vzory zaznamenaných dopravných značiek so vzormi referenčnej databázy. Na základe výsledku je následne možné vyhodnotiť ich podobnosť a určiť kategóriu a typ dopravnej značky. Optický korelátor vyžaduje pre svoj vstup obrazy v binárnom tvare. Obraz získaný kamerami je preto potrebné vopred vhodne spracovať. Keďže dopravné značky sú charakteristické svojím tvarom a farebnou reprezentáciou jednotlivých častí, základom tohto predspracovania je farebná filtrácia. Farebnou filtráciou sú vyselektované oblasti obrazu tvorené obrazovými prvkami s farbou z rozmedzia vopred definovaných hraničných hodnôt. Výsledkom predspracovania je skupina segmentov obrazu, ktoré by mohli reprezentovať hľadané dopravné značky. Zo získaných segmentov sú postupne generované obrazy vstupných rovín optického korelátora. Výsledkom optického spracovania týchto obrazov je miera podobnosti reálnych a referenčných vzoriek umiestnených vo vstupnej rovine.

Doplnkovou informáciou k zaznamenaným obrazovým sekvenciám je informácia o aktuálnej pozícii inventarizačného vozidla. Tá je získavaná pomocou GPS prijímača umiestneného v bezprostrednej blízkosti kamerového systému. Na základe informácie o aktuálnej pozícii vozidla je možné počas spracovania záznamu určiť presnú pozíciu dopravných značiek. Analýzou geometrických vlastností a textúr vzoriek v zaznamenanom obraze je možné vyhodnotiť aktuálny stav dopravnej značky. Stav dopravnej značky je dôležitou súčasťou výsledku inventarizácie, keďže na jeho základe je možné vykonať opatrenia pre odstránenie detegovaných porúch, resp. zamedziť ich opätovnému vzniku.

Prvá časť tohto článku je venovaná súčasnému stavu problematiky videodohľadových systémov. Je v nej zahrnutý prehľad využitia videodohľadových systémov, opis všeobecne používaných metód spracovania obrazu a charakteristika inventarizačných systémov v doprave. V druhej časti článku je predstavená implementácia navrhnutého systému. Predposlednú časť článku tvorí opis a výsledky realizovaných experimentov. V závere sú vyhodnotené klady a zápory použitia navrhnutých algoritmov a sú spomenuté možnosti zamerania ďalšieho výskumu v budúcnosti.

II. SÚČASNÝ STAV PROBLEMATIKY

Úlohou videodohľadových systémov vo všeobecnosti je zbierať obrazové informácie a ich analýzou vyhodnocovať prítomnosť, identifikovať a sledovať aktivitu objektov záujmu. Neustály pokrok v oblasti informačných technológií umožňuje neustále zvyšovanie efektivity spracovania obrazov. Vďaka rýchlejšiemu a efektívnejšiemu spracovaniu je možné videodohľadové systémy prispôbovať a nasadzovať v čoraz širšom spektre aplikácií. Svoje využitie v súčasnosti nachádzajú vo výrobných závodoch, v asistenčných systémoch automobilov, v oblastiach zabezpečenia majetku a monitorovania verejných priestorov. Najzákladnejšou rutinou videodohľadových systémov je záznam obrazu. Rôzne metódy jeho spracovania zabezpečujú analýzu prítomnosti a aktivity objektov, ktorá je vhodná pre rôzne oblasti využitia [1,2].

Videodohľadové systémy je možné klasifikovať do skupín podľa viacerých kritérií. Príkladom je rozdelenie podľa rýchlosti a miesta spracovania.

- **On-line spracovanie** – záznam a spracovanie obrazu prebieha v jednom momente v mieste záznamu. Každá zaznamenaná snímka je analyzovaná okamžite v čase záznamu. Tento typ spracovania je vhodný pre aplikácie, kde je výsledok analýzy potrebný poznať okamžite. Spracovanie v reálnom čase však kladie vysoké požiadavky na výpočtový výkon hardvérového vybavenia [3-6].
- **Off-line spracovanie** – spracovanie obrazu sa vykonáva separátne, po samotnom zázname. Tento spôsob je možné využiť v systémoch, ktoré vyžadujú na spracovanie obrazu výpočtový výkon presahujúci dostupné hardvérové možnosti. Nevýhodou takéhoto spracovania je jeho dlhšie trvanie, následkom čoho nie je možné ich využitie v systémoch pracujúcich v reálnom čase.

Klasifikácia podľa miery pohybu rozdeľuje videodohľadové systémy do dvoch skupín:

- **Statické** – sú inštalované v pevnom bode a nemenia svoju pozíciu. Zaznamenávajú a spracovávajú obraz vopred definovanej oblasti, resp. skupiny viacerých oblastí. Predpokladom spracovania obrazu v statických videodohľadových systémoch je vo väčšine prípadov konštantné pozadie.
- **Dynamické** – môžu meniť svoju pozíciu a zaznamenávajú aktuálny obraz svojho okolia. Sú inštalované v rôznych typoch vozidiel. Používajú sa na záznam okolia trasy, ktoré dané vozidlo absolvuje. Spracovanie v dynamických systémoch nie je založené na konštantnom pozadí, ale vykonáva analýzu na základe špecifických parametrov obrazu. Metódy tejto analýzy sú zvolené podľa vlastností zobrazenia potenciálnych objektov záujmu.

Najrozsiahlejším typom klasifikácie je klasifikácia podľa oblastí využitia videodohľadových systémov.

Najvýznamnejšie oblasti využitia sú popísané v nasledujúcej podkapitole.

A. Oblasti využitia videodohľadových systémov

1) Bezpečnosť

Najrozšírenejšou oblasťou využitia videodohľadových systémov je oblasť bezpečnosti a ochrany majetku. Jednoduché systémy chrániace majetok pred poškodením, alebo odcudzením sú založené na princípe detekcie nežiaduceho pohybu v určenom priestore počas neprítomnosti majiteľov. Tieto systémy zaznamenávajú činnosť nepovolaných osôb a rôznymi komunikačnými kanálmi odosielaajú notifikácie o detegovanom pohybe. Prevencia voči kriminalite vyžaduje taktiež monitorovanie verejných priestranstiev a uzavretých priestorov. Monitorovanie spočíva v detekcii jednotlivých osôb ako samostatných objektov v zaznamenanom obraze. Ich izolovaním v obraze celkovej scény je možné sledovať smer a rýchlosť ich pohybu. Pre zvýšenie účinnosti týchto systémov sa v pokročilých architektúrach využíva identifikácia konkrétnych osôb. V rámci uzavretej organizácie je tak možné jednoducho a nepretržite monitorovať prítomnosť zamestnancov aj nepovolaných osôb, ich detailný pohyb v rámci objektu a podrobné sledovať ich aktivitu [7-9].

2) Priemysel

Videodohľadové systémy vo výrobných procesoch vo veľkej miere prispievajú k zvyšovaniu rýchlosti a efektivity. Príkladom jednoduchého využitia je počítadlo výrobkov, alebo súčiastok. Jeho princíp spočíva v segmentácii obrazu podľa špecifických parametrov, ktoré charakterizujú daný kus výrobku. Počet segmentov získaných vhodným spracovaním je rovný počtu sledovaných výrobkov v zornom poli kamery videodohľadového systému. Na výstupe každého výrobného procesu je nevyhnutná kontrola kvality. Videodohľadové systémy majú v tejto sfére taktiež svoje zastúpenie. Sledovaním a porovnaním ideálnych vzoriek s reálnymi je možné zabezpečiť detekciu anomálií a automaticky začleniť daný výrobok medzi nepodarky, alebo odstrániť zistenú chybu. Ďalšou často využívanou aplikáciou videodohľadových systémov v priemysle je triedenie. Kamerový systém zaznamenáva identifikátory výrobkov vo forme sériových čísel, čiarových kódov, alebo popisov a každý kus následne smeruje na príslušný dopravník. Špecifickou sférou, kde je automatizované triedenie využívané v obzvlášť veľkej miere sú doručovacie služby. Keďže smerové čísla zásielok sú uvádzané na rôznych miestach, rôznym písmom, svoju úlohu tu zohrávajú aj neuronové siete, ktoré na základe množstva naučených vzoriek dokážu s vysokou presnosťou rozpoznať správny symbol a zásielku tak nasmerovať správnym smerom [10,11].

3) Navigácia

Ďalšou z aplikácií videodohľadových systémov je navigácia rôznych typov autonómnych vozidiel. Ich autonómnosť siaha od jednoduchej podpory vodiča, alebo pilota až po plne automatickú jazdu bez prítomnosti ľudskej obsluhy. Podporné videodohľadové systémy slúžia na

varovanie človeka pred prekážkami, alebo asistenciu pri pristávaní lietadiel. Detekcia dopravných značiek v osobných a nákladných automobiloch signalizuje prekročenie maximálnej povolenej rýchlosti a určuje povolený smer jazdy. Plne autonómne vozidlá využívajú videodohľadové systémy pre analýzu prostredia, v ktorom sa nachádzajú, generovanie mapy tohto prostredia a detekciu prekážok. Dobrým príkladom analýzy prostredia je detekcia lesných požiarov pri zásahu bezpilotnými lietadlami. Plne autonómne vozidlá v súčasnosti nie sú hromadne vyrábané a masovo predávané. Autonómne vozidlá sú však využívané vo vojenských misiách (bepilotné lietadlá, autonómne strely) a vesmírnych prieskumoch (Mars Rover spoločnosti NASA, alebo ExoMars Rover spoločnosti ESA) [2].

4) Medicína

Videodohľadové systémy veľmi významne prispievajú aj k efektívnemu spracovaniu informácií v medicíne. Analýza v tejto oblasti je charakteristická extrahovaním informácií z obrazových dát pre účely určovania medicínskych diagnóz pacientov. Vstupnými informáciami sú mikroskopické obrázky, röntgenové obrázky a obrázky z počítačovej tomografie. Jednoduchšie metódy spracovania obrazov v medicíne zahŕňajú skvalitňovanie nedokonalých obrazov zaostréním a redukciou šumu. Tým je znížené riziko chybných interpretácií týchto obrazov človekom. Výsledkom automatickej analýzy týchto obrazov je detekcia nádorov, aterosklerózy, alebo iných malígnych zmien. Môže to byť taktiež meranie rozmerov orgánov, prúdenia krvi v cievach, atď. Táto oblasť aplikácie videodohľadových systémov podporuje medicínsky výskum poskytovaním nových informácií o nedostatočne preskúmaných štruktúrach ľudského organizmu.

5) Mapovanie

Schopnosti videodohľadových systémov spolu so snímačmi pozície a orientácie dokážu zabezpečiť efektívne mapovanie okolitého prostredia a automatickú inventarizáciu zaznamenaných objektov záujmu v teréne. Najjednoduchším príkladom je paralelný záznam obrazu a GPS informácií z ktorého je možné vyextrahovať prítomnosť hľadaných objektov a jednotlivým položkám priradiť informácie o ich pozícii. Výsledkom môže byť zoznam objektov záujmu so zistenými vlastnosťami a s informáciou, kde sa tieto objekty nachádzajú. Komplikovanejšou aplikáciou využitia videodohľadových systémov v mapovaní je fotogrametria. Metódami fotogrametrie je možné na základe obrazových informácií rekonštruovať informácie ako reálne rozmery snímaného objektu a jeho relatívna pozícia. Pomocou fotogrametrie je tiež možné generovať 3D štruktúru snímaných objektov a zaznamenávať priestorový tvar snímaného terénu [12].

B. Metódy spracovania obrazu vo videodohľadových systémoch

Štruktúra videodohľadových systémov je vo veľkej miere závislá od aplikácie. Niektoré systémy sú implementované v jednoduchších, samostatne pracujúcich aplikáciách pre riešenie špecifického merania, alebo detekcie, pričom ostatné

sú súčasťou väčších architektúr. Väčšina týchto systémov však pre svoju prácu využíva rovnaké operácie a pozostáva z niekoľkých ustálených krokov. Spracovanie obrazu vo videodohľadových systémoch zahŕňa metódy získavania, spracovania, analýzy a reprezentácie digitálnych obrazov a extrakcie informácií, ktoré popisujú reálny svet numerickými alebo symbolickými parametrami. Na základe získaných parametrov je možné vykonať potrebnú analýzu obrazu [13-15].

1) Záznam obrazu

Digitálny obraz je zaznamenaný jedným, alebo viacerými obrazovými senzormi, ktoré sú súčasťou rôznych typov kamier, diaľkometerov, radarov, zariadení tomografie a ultrazvuku. V závislosti od typu obrazového senzora, výsledná skupina informácií môže nadobúdať formu 2D obrazu, 3D štruktúry, alebo ich sekvencie. Reprezentácia obrazových prvkov zvyčajne korešponduje s intenzitou dopadajúceho svetla. Obrazové prvky však môžu reprezentovať aj iné fyzikálne veličiny, ako hĺbku, mieru absorpcie, alebo odrazu vlnenia.

2) Predspracovanie

Pred tým ako je možné aplikovať metódy pre extrakciu špecifických informácií zo zaznamenaného obrazu, je zvyčajne nevyhnutné upraviť obrazové informácie pre potreby danej metódy počítačového videnia, napr.:

- **Prevzorkovanie** – kvôli zvýšeniu spoľahlivosti presného určenia súradníc v obraze.
- **Redukcia šumu** – kvôli zníženiu produkcie chybných informácií spôsobených šumom.
- **Zlepšenie kontrastu** – kvôli zvýrazneniu a detekcii relevantných informácií

3) Extrakcia vlastností

Objekty v obraze sú zvyčajne reprezentované svojimi farebnými vlastnosťami a ohraničením. Pri tejto operácii sa získavajú popisy vlastností zobrazených objektov. Typickými príkladmi sú:

- čiary, hrany,
- lokalizované oblasti záujmu ako rohy, body a ich skupiny,
- komplexnejšie vlastnosti, ako textúry, tvary a pohyby.

4) Segmentácia

Vlastnosti objektov môžu, ale nemusia spĺňať stanovené kritériá. V tomto bode spracovania je realizované rozhodovanie, ktoré objekty obrazu sú vhodné pre ďalšie spracovanie. Objekty spĺňajúce definované požiadavky sú následne izolované a poskytnuté pre ďalšie spracovanie ako skupina oblastí pôvodného obrazu.

5) Vysokoúrovňové spracovanie

Vstup vysokoúrovňového spracovania predstavuje malé množstvo informácií, ktoré charakterizujú základné vlastnosti objektov zobrazených v spracovávanom obraze. Môžu to byť

napr. súradnice skupiny bodov, ktoré predstavujú hranice špecifického objektu. V procese vysokoúrovňového spracovania sú izolované oblasti a vlastnosti objektov podrobne analyzované. Výsledkom vysokoúrovňového spracovania môže byť napr.:

- verifikácia zhody objektov s modelovým predpokladom,
- odhad parametrov ako pozícia objektu, jeho veľkosť, atď.,
- klasifikácia objektov do rôznych kategórií.

6) Reakcia

Posledným krokom vo funkcii videodohľadových systémov je reakcia na výsledok spracovania vstupného obrazu. Reakciou na detekciu nežiaduceho pohybu môže byť spustenie poplachu. Rozpoznaná prekážka v dráhe automobilu môže spustiť signalizáciu, ktorá upozorní vodiča na nebezpečenstvo. Výsledkom detekcie dopravnej značky pri inventarizácii môže byť zápis položky do databázy. Reakcie na jednotlivé typy výsledkov spracovania môžu byť realizované interne, v rámci samotného systému, alebo odoslaním notifikácie do externého systému. Typ a parametre reakcie sú vopred definované pre všetky typy a stavy výsledkov spracovania.

C. Inventarizačné systémy dopravných značiek

Špecifickým typom videodohľadových systémov sú systémy automatickej inventarizácie. Výsledkom spracovania obrazu v inventarizačných systémoch je zoznam zaznamenaných, rozpoznaných a klasifikovaných položiek vrátane príslušných informácií o týchto položkách. Inventarizačné systémy je možné rozdeliť do dvoch kategórií podľa miery autonómnosti [16-20].

Manuálne inventarizačné systémy sa spoliehajú na ľudskú inteligenciu. Inventarizácia prebieha ručným zadávaním požadovaných informácií do formulárov inventarizačného systému. Človek vykonávajúci inventarizáciu pred výjazdom zadáva základné informácie o dopravnej komunikácii, na ktorej sa inventarizácia bude vykonávať. Následne pomocou meracích prístrojov zistí a zapíše informácie o stave a pozícii dopravnej značky. Dôležitým krokom je vyhotovenie fotografie, ktorá je súčasťou každého záznamu [21,22].

Automatické inventarizačné systémy vykonávajú inventarizáciu bez potreby, alebo iba s minimálnou potrebou manuálneho zásahu do celého procesu. Fotografie dopravnej značky zaznamenávajú kamerami a informácie o type a stave dopravnej značky sa vyhodnocujú práve z týchto obrazových záznamov. Pozícia dopravnej značky je určená priradením konkrétnej GPS súradnice každej snímke zo záznamu. Tieto súradnice môžu byť korigované použitím informácií z diaľkometerov, lidarov, alebo z hĺbkovej mapy generovanej taktiež metódami spracovania obrazu.

1) Štruktúra inventarizačných systémov

Inventarizačné systémy pozostávajú z niekoľkých, viac či menej nevyhnutných častí. Ich nutnosť využitia závisí od typu a množstva očakávaných funkcií.

Inventarizačné vozidlo je vozidlo v ktorom sú inštalované všetky súčasti inventarizačného systému. Pohybuje sa po dopravnej komunikácii v okolí ktorej je potrebné vykonať inventarizáciu. Inventarizačným vozidlom môže byť obyčajný osobný automobil. Trendom však je inštalácia inventarizačných systémov vo vozidlách, ktoré svojou bežnou činnosťou pravidelne navštevujú jednotlivé úseky dopravných komunikácií. Patria medzi ne vozidlá údržby, policajné autá a sanitky. Týmto spôsobom je zabezpečená pravidelná inventarizácia dopravných značiek bez zvyšovania nákladov na špeciálne vyhradené vozidlá a ich obsluhu.

Kamerový systém je tvorený jednou, alebo niekoľkými kamerami. Ich počet závisí od konkrétnej implementácie. Jednokamerový systém zaznamenáva okolie vozovky v rámci svojho zorného poľa. Pre 3D rekonštrukciu snímanej scény je vhodné použitie dvoch kamier, pričom vzniká stereoskopický záznam tvorený sekvenciou párov snímok. Z týchto párov je možné generovať hĺbkovú mapu, analyzovať reálne tvary objektov a merať ich vzdialenosti od kamerového systému. Viackamerové systémy sú používané na rozšírenie zorného poľa, až po úroveň simulácie 360° záberov, kedy je k dispozícii celá panoráma konkrétneho miesta vozovky [23].

Systémy merania pozície zahŕňajú GPS prijímače, gyroskopy, diaľkomery a lidary. GPS prijímač poskytuje informácie o absolútnej pozícii inventarizačného systému vo forme GPS súradníc. Gyroskop slúži na relatívne meranie pozície v miestach s nedostatočným pokrytím GPS signálu. Na základe záznamu relatívnej trasy je následne možné určiť jej absolútne body, ktorých základom je GPS súradnica z miesta s ideálnou kvalitou prijímaného signálu. Úlohou diaľkomerov a lidarov je poskytnúť informácie o vzdialenosti dopravných značiek od inventarizačného systému pre účely korekcie GPS súradníc. Kvôli zníženiu obstarávacej ceny systému sa presné diaľkomery a lidary nahrádzajú menej presným meraním analýzou zaznamenaných obrazov [24-26].

GIS databáza umožňuje vytvárať záznamy o jednotlivých dopravných značkách s informáciou o presnej globálnej pozícii. Takto vytvorený zoznam je následne použiteľný v širokej škále grafických programov, kde sú zaznamenané informácie premietnuté do prehľadných máp. Existuje niekoľko komerčne využívaných GIS databázových systémov, ktoré sú veľmi úspešne využívané na záznam informácií z viacerých typov inventarizačných systémov [27,28].

Počítač s riadiacim softvérom má za úlohu hardvérovo prepojiť jednotlivé periférie a zabezpečiť ich spoľahlivú vzájomnú komunikáciu. Kamerový systém a systémy merania pozície sú pripájané sériovými rozhraniami, resp. Ethernetovým rozhraním prostredníctvom siete TCP/IP. GIS databáza môže byť súčasťou softvérového vybavenia použitého počítača, alebo externej on-line služby. Úlohou

riadiaceho softvéru je zozbierať a spracovať informácie z periférií a výsledok zapísať do tejto databázy.

2) Parametre inventarizácie

Každá inventarizácia a každá jej položka je nositeľom série informácií. Inventarizácia je charakterizovaná časom, kedy bola vykonaná, úsekom dopravnej komunikácie, na ktorom bola vykonaná a osobou, ktorá ju vykonávala. Položky inventarizačného zoznamu obsahujú informácie o ich parametroch spolu s označením, kategóriou a doplnkovými poznámkami [22,29,30].

Dátum inventarizácie určuje, kedy bola daná inventarizácia realizovaná. Táto informácia je známa na začiatku inventarizačného procesu a môže byť generovaná priamo inventarizačným systémom bez potreby explicitného zadávania používateľom.

Používateľ je osoba, ktorá inventarizáciu vykonáva. V jednoduchších prípadoch je identifikovaná svojim menom a priezviskom. V komplexnejších riešeniach je vedená evidencia používateľov, ktorí sa pred inventarizáciou autentifikujú a inventarizácia nesie záznam o konkrétnom používateľovi vo forme identifikátora, na základe ktorého je kedykoľvek možné vyhľadať a zobrazit' jeho detailné informácie.

Inventarizovaný úsek predstavuje časť dopravnej komunikácie na ktorej sa vykonáva inventarizácia. Je charakterizovaný svojim začiatočným a koncovým bodom definovaným pomocou GPS súradníc. Dôležitou informáciou o úseku je taktiež číslo príslušnej cesty.

Správca úseku je organizácia, ktorá má na starosti prevádzku a údržbu úseku, na ktorom sa inventarizácia vykonáva. V závislosti od zložitosti systému môže byť záznam o správcovi vo forme jednoduchého názvu, alebo identifikátora, ktorý odkazuje na podrobné informácie.

Kategória a typ dopravnej značky sú základnými informáciami, ktoré určujú účel danej dopravnej značky. Automatické inventarizačné systémy zisťujú kategóriu a typ dopravných značiek analýzou zaznamenaného obrazu. Sú to primárne parametre, ktoré sa pri inventarizácii konkrétnej dopravnej značky definujú.

MUTCD kód je jednoznačným identifikátorom, ktorý charakterizuje kategóriu a typ dopravnej značky. Pri rozpoznaní dopravných značiek definovaných štandardom MUTCD sa príslušný kód priradí aktuálne spracovanej položke v inventarizačnom zozname. V prípade, že rozpoznaná dopravná značka nepatrí do štandardu MUTCD, k danej položke zoznamu sa doplní poznámka o tejto skutočnosti [31].

Rozmery dopravnej značky sú zistené na základe manuálneho merania, alebo obrazovej analýzy. Ich formát v inventarizačnej databáze je dvojicou desatinných čísel so základnou presnosťou.

GPS pozícia určuje absolútnu pozíciu dopravnej značky. V závislosti od implementácie inventarizačného systému môže

hodnota súradníc predstavovať absolútnu pozíciu dopravnej značky, alebo pozíciu vozidla v momente detekcie dopravnej značky, ktorá je doplnená o korekčné informácie.

Orientácia charakterizuje absolútne natočenie smerom na kľúčovú svetovú stranu (vo väčšine prípadov Sever). Orientácia dopravnej značky je v čase inventarizácie odvodená od orientácie vozidla v momente detekcie danej dopravnej značky.

Stav dopravnej značky môže nadobúdať niekoľko hodnôt. Východzu hodnotou je bezproblémový stav. Postupným meraním a skúmaním dopravnej značky sa zisťuje prítomnosť viacerých typov porúch. V prípade detekcie problému je bezproblémový stav aktualizovaný na príslušnú hodnotu, ktorá charakterizuje zistený problém.

Inventárne číslo je jedinečným identifikátorom každej položky inventarizačného zoznamu. Pri inventarizáciách menšieho rozsahu môže byť zadávané manuálne. V rozsiahlejších prípadoch sa definujú pravidlá pre automatické generovanie týchto identifikátorov.

Materiál je jedným z mála parametrov, ktoré nie je možné určiť na základe analýzy zaznamenaného obrazu. Informáciu, z akého materiálu je dopravná značka vyrobená zadáva manuálne používateľ inventarizačného systému spravidla po inštalácii dopravnej značky.

Dátum inštalácie určuje kedy bola dopravná značka osadená v teréne. Táto informácia je nápomocná pri plánovaní pravidelnej údržby a pri vyšetrovaní rôznych typov poškodenia dopravnej značky.

Popis a komentár sú doplnkové textové informácie slúžiace pre uchovanie poznámok o neštandardných vlastnostiach dopravných značiek, alebo o histórii úkonov, ktoré boli s danou značkou realizované.


III. NÁVRH A IMPLEMENTÁCIA AUTOMATICKÉHO INVENTARIZAČNÉHO SYSTÉMU DOPRAVNÝCH ZNAČIEK

Súčasti navrhovaného automatického inventarizačného systému sú rozdelené do niekoľkých funkčných blokov. Jadrom inventarizačného systému je riadiaci softvér, ktorý riadi komunikáciu medzi perifériami a vyhodnocuje získané informácie. Sústava periférnych zariadení je vstupným bodom pre získavanie a záznam potrebných informácií z prostredia v ktorom je inventarizačný systém nasadený. Hlavným výpočtovým prvkom systému je optický korelátor. Jeho úlohou je vyhodnocovanie podobnosti spracovávaných a referenčných vzoriek obrazu. Optický korelátor v inventarizačnom systéme nahrádza konvenčné spracovanie obrazu pomocou Fourierovej transformácie. Výhodou použitia optického korelátora je jeho schopnosť rýchleho spracovania, ktorá je teoreticky nezávislá od rozlíšenia vstupného obrazu.

A. Hardvérové technické vybavenie

Hardvérová schéma na Obr. 1 znázorňuje základnú štruktúru inventarizačného systému a komunikáciu medzi

jednotlivými perifériami a riadiacim počítačom. Vrechnú časť blokovej schémy tvorí skupina vstupných periférnych zariadení. V spodnej časti je znázornená výpočtová vrstva, ktorú tvorí optický korelátor a riadiaci počítač. Funkcia jednotlivých zariadení a komunikácia medzi nimi je opísaná v nasledujúcom texte.



Obr. 1. Hardvérová schéma automatického inventarizačného systému

1) Optický korelátor

Optický korelátor je zariadenie vykonávajúce koreláciu dvoch vstupných obrazov (2D signálov) optickou cestou. Podstata jeho činnosti je založená na schopnosti difrakčných šošoviek produkovať Fourierovu transformáciu obrazu modulovaného na nosnú vlnu – koherentné, kruhovo polarizované svetlo. Vhodnou kombináciou Fourierových transformácií vstupného signálu optický korelátor vytvára korelačnú rovinu, ktorej súčasťou sú korelačné špičky. Intenzita korelačných špičiek charakterizuje mieru podobnosti obrazov umiestnených vo vstupnej rovine optického spracovania. Vzájomná pozícia týchto špičiek je závislá od vzájomnej pozície spracovávaných vzoriek vo vstupnej rovine. Vstupný obraz je zobrazovaný na priestorovom modulátore svetla prostredníctvom DVI rozhrania. Výstup korelácie zaznamenaný priemyselnou CMOS kamerou je získavaný pomocou sieťového rozhrania GigE. Reálna podoba optického korelátora je zachytená na Obr. 2. Parametre jeho súčastí sú uvedené v Tab. 1.



Obr. 2. Optický korelátor

TAB. I. PARAMETRE SÚČASTÍ OPTICKÉHO KORELÁTORA

PRIESTOROVÝ MODULÁTOR SVETLA	
Rozlíšenie	1024x768 o.p.
Bitová hĺbka	8 bit
Rozstup obrazových prvkov	9x9 um
Reflektivita	62% pri 633 nm
Rozmery užitočnej plochy	9,3x7 mm
Konfigurácia tekutých kryštálov	Krútená nematická štruktúra
Pracovná vlnová dĺžka	430-650 nm
Vstupná polarizácia	Paralelná s najdlhšou stranou
Kontrast	350:1
Reakčný čas tekutých kryštálov	200 us
Rozhranie	DVI
Vstupné napätie	5V DC
KAMERA	
Rozhranie	GigE Ethernet
Maximálna snímková frekvencia	Do 196 fps
Rozlíšenie	656x494 o.p.
Výstupná bitová hĺbka	10 bit
LASER	
Typ	635nm laserová dióda s jednovidovým optickým vláknom
Výkon	2.5mW variabilný výstup

2) *Riadiaci počítač*

Spracovanie informácií z pripojených zariadení a riadenie celého inventarizačného procesu zabezpečuje riadiaci počítač. Špecifikom tohto počítača je nainštalovaný riadiaci softvér, ktorý dokáže prijať informácie zo vstupných rozhraní, zabezpečiť ich predspracovanie a komunikáciu s optickým korelátorom a zobrazit' výsledok na obrazovke, resp. zapísať ho do databázy. Pomocou USB rozhraní sú riadiacemu počítaču pripojené kamery stereoskopického kamerového systému a GPS prijímač. Komunikácia s optickým korelátorom je zabezpečená pomocou rozhrania DVI a Ethernet. V Tab. 2 sú uvedené parametre riadiaceho počítača.


TAB. II. PARAMETRE RIADIACEHO POČÍTAČA

Typ	IBM ThinkPad T61
Procesor	Intel(R) Core(TM)2, T5300 @ 1.73MHz
RAM	2.99 GB, 795 MHz
HDD	120 GB, Kingston SSD

3) *Stereoskopický kamerový systém*

Inventarizačný systém využíva obraz okolitého prostredia ako hlavnú vstupnú informáciu na detekciu prítomnosti dopravnej značky. Tento obraz je zaznamenávaný dvojicou vzájomne posunutých kamier. Ich vzájomné posunutie umožňuje rekonštrukciu trojrozmerného priestoru, vďaka čomu je v aktuálnej verzii inventarizačného systému možné merať vzdialenosť dopravnej značky od vozidla. Komunikácia medzi kamerami a riadiacim softvérom je zabezpečená pomocou dvojice USB rozhraní. Parametre kamerového

systému sú uvedené v Tab. 3. Na Obr. 3 je zobrazená podoba kamerového systému a testovacieho pracoviska [14,32,33].



Obr. 3. Testovacie pracovisko vybavené sústavami kamier

TAB. III. PARAMETRE STEREOSKOPICKÉHO KAMEROVÉHO SYSTÉMU

Natívne rozlíšenie	640x480 o.p.
Softvérovo upravené rozlíšenie	1280x720 o.p.
Maximálna snímková frekvencia	Do 30fps
Rozhranie	USB 2.0
Vstupné napätie	5V DC

4) *GPS prijímač*

TAB. IV. PARAMETRE GPS PRIJÍMAČA

Platforma	u-blox 6 UBX-G6000-BT
Pracovná frekvencia	GPS: L1, 1575.4200 MHz
Automatická prenosová rýchlosť	Do 115200 bps
Citlivosť	Maximálne -162 dBm
Presnosť určenia pozície	2.5 m CEP 2 m CEP so SBAS
Rozhranie	USB 2.0
Vstupné napätie	5 V DC



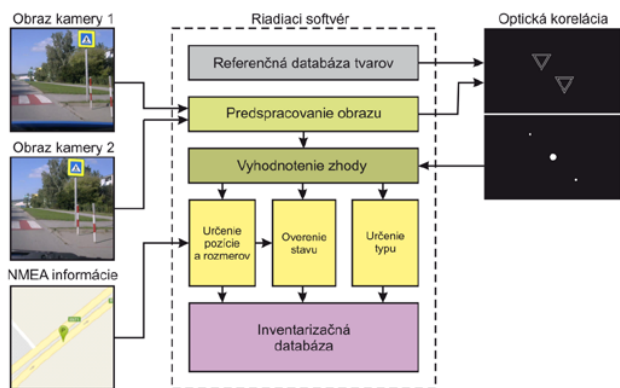
Obr. 4. GPS prijímač umiestnený v inventarizačnom vozidle.

Aktuálna pozícia inventarizačného vozidla je získavaná prostredníctvom GPS prijímača vo forme NMEA viet. Jej výpočet je založený na oneskorení vzájomne zodpovedajúcich časových známk prijatých z niekoľkých družíc na obežnej dráhe zeme. Doplnkovou informáciou, ktorú GPS prijímač poskytuje je jeho horizontálna orientácia, resp. smer jazdy vozidla. Informácie o pozícii a orientácii sú získavané pravidelne v krátkych časových intervaloch prostredníctvom virtuálneho sériového portu na hardvérovom USB rozhraní.

Parametre GPS prijímača sú uvedené v Tab. 4. Jeho podoba a umiestnenie v inventarizačnom vozidle sú znázornené na Obr. 4.

B. Riadiaci softvér

Najpodstatnejšou činnosťou riadiaceho softvéru automatického inventarizačného systému je riadenie získavania informácií z periférnych zariadení a ich spracovanie do formy výsledného inventarizačného zoznamu. Tento celok obsahuje implementovanú referenčnú databázu tvarov, na základe ktorej sa v prípade rozpoznania dopravnej značky vykonáva klasifikácia. Blok segmentácie spracuje vstupný obraz z kamier do binárneho tvaru, ktorý je vhodný pre spracovanie optickým korelátorom. Na základe výsledku optickej korelácie sú jednotlivé segmenty vstupného obrazu rozpoznané ako časti konkrétnej dopravnej značky, alebo sú tieto segmenty označené ako nerozpoznané. Obrazy úspešne rozpoznávaných dopravných značiek sú podrobené analýze, ktorej výsledkom je informácia o ich stave. Každý rozpoznanej dopravnej značke je priradená jej pozícia na základe GPS súradníc vozidla a korekcie podľa jeho orientácie a vzdialenosti od zaznamenananej dopravnej značky. Výsledky sú následne zapísané do inventarizačného zoznamu. Schéma na Obr. 5 znázorňuje vzťahy medzi jednotlivými funkčnými blokmi riadiaceho softvéru automatického inventarizačného systému.



Obr. 5. Bloková schéma riadiaceho softvéru

1) Referenčná databáza tvarov

Vzorky kandidátov dopravných značiek zo zaznamenaného obrazu sú porovnávané s ideálnymi vzorkami z referenčnej databázy. Táto databáza je komplexnou štruktúrou rozdelenou na niekoľko úrovní. Jednotlivé úrovne sú charakterizované svojou funkciou pri rozpoznávaní konkrétnej časti dopravnej značky. Najvyššia úroveň je vo väčšine prípadov tvorená základnými farebnými tvarmi dopravných značiek. Rozpoznaním a klasifikáciou základného tvaru je určená kategória dopravnej značky. Druhá úroveň spravidla pozostáva z vnútorných piktogramov na základe ktorých je možné určiť presný typ rozpoznanej dopravnej značky. U niektorých typov značiek je možné ich presný typ určiť už po klasifikácii základného tvaru. Rozpoznávanie a klasifikácia ostatných farebných častí sa v tomto prípade

používa na vyhodnotenie stavu dopravnej značky. Príklady štruktúry referenčnej databázy pre jednotlivé farby základných tvarov sú uvedené v Tab. 5 – Tab. 7 [34,35].

TAB. V. DOPRAVNÉ ZNAČKY SO ZÁKLADNÝM TVAROM ČERVENEJ FARBY

Červená-kategória		Čierna-typ		
		Čierna-stav		
		-		

TAB. VI. DOPRAVNÉ ZNAČKY SO ZÁKLADNÝM TVAROM MODREJ FARBY

Modrá-kategória		Čierna-typ		
		-		

TAB. VII. DOPRAVNÉ ZNAČKY SO ZÁKLADNÝM TVAROM ŽLTÉJ FARBY

Žltá		-		
		Čierna-stav		

2) Blok predspracovania obrazu

Zaznamenaný vstupný obraz z kamerového systému je tvorený množstvom objektov rôznych farieb. Blok predspracovania vykonáva úpravu zaznamenaného obrazu do tvaru vhodného pre spracovanie optickým korelátorom. Celá vstupná scéna je rozdelená na menšie časti definované farebnými rozsahmi, ktoré zodpovedajú prirodzenému rozptylu farieb častí konkrétnych dopravných značiek v určitých svetelných podmienkach. Predspracovanie obrazu začína úpravou jeho parametrov elimináciou šumu, vyvážením bielej farby a korekciou jasu, kontrastu a farebnosti. Najdôležitejším krokom v predspracovaní je farebná filtrácia a prahovanie. Výsledkom filtrácie sú izolované oblasti obrazových prvkov, ktoré reprezentujú tvary farebných častí hľadaných dopravných značiek. Prahovaním sa zabezpečí farebná homogenita týchto oblastí. V získaných binárnych obrazoch je následne aplikované spájanie hrán, vďaka ktorému je z obrazu odstránená jednosmerná zložka. Výsledkom spájania hrán sú obrisy izolovaných oblastí v obraze. Vzniknuté vzorky sú použiteľné pre generovanie vstupnej roviny optického korelátoru [36-41,42-45].

3) Blok vyhodnotenia zhody

Výstupom optického korelátoru je korelačná rovina obsahujúca korelačné špičky. Tie charakterizujú mieru podobnosti a vzájomnú pozíciu porovnávaných vzoriek obrazu. Blok vyhodnotenia zhody analyzuje výstupnú korelačnú rovinu z optického korelátoru a určuje úroveň zhody medzi referenčnou a porovnávanou vzorkou. Keďže obraz okolitého prostredia je získavaný viacerými kamerami súčasne, podmienkou úspešného rozpoznania je nájdenie rovnakej dopravnej značky s rovnakou veľkosťou na rovnakom mieste (s definovanou toleranciou) na oboch zodpovedajúcich snímkach súčasne. Po určení miery podobnosti sa vzorky z korešpondujúcich snímkov párujú podľa príslušnosti k zhodným referenčným vzorkám a podľa ich umiestnenia na snímkach. Na ďalšie spracovanie sú posunuté iba úspešne spárované vzorky tvarov dopravných značiek, ktoré dosiahli stanovenú minimálnu úroveň podobnosti s niektorou so vzoriek referenčnej databázy.

4) Blok určenia kategórie a typu

Kľúčovou informáciou pre určenie kategórie a typu dopravnej značky je miera podobnosti so vzorkami referenčnej databázy. Táto informácia sa získava z bloku vyhodnotenia zhody. Kategória dopravnej značky je určená vzorkou referenčnej databázy, ktorá ma s porovnávanou vzorkou najväčšiu zhodu spomedzi všetkých referenčných vzoriek danej farby a úrovne. Typ dopravnej značky je v niektorých prípadoch možné určiť v jednom momente s kategóriou a to v prípade, že daný typ dopravnej značky má jedinečný základný tvar. V opačných prípadoch sa presný typ určuje na základe zhody vnútorného piktogramu dopravnej značky s referenčnými vzorkami piktogramov [46-56].

5) Blok overenia stavu

Táto časť inventarizačného systému zo zaznamenaných informácií vyhodnocuje stav jednotlivých dopravných značiek. Proces zisťovania stavu využíva niekoľko algoritmov

na detekciu rôznych typov porúch. Najjednoduchším testom je kontrola proporcií dopravných značiek. Ak je pomer rozmerov reálnej dopravnej značky výrazne odlišný od pomeru rozmerov ideálnej vzorky, dopravná značka je s najväčšou pravdepodobnosťou naklonená nesprávnym smerom. Ďalším testom pre overenie stavu dopravnej značky je porovnávanie vnútorných piktogramov voči piktogramom referenčnej databázy. Pri dopravných značkách, ktorých typ je určený už počas rozpoznávania a klasifikácie základného tvaru, overenie zhody piktogramu slúži na odhalenie vizuálnych nedostatkov vo vnútornej časti dopravnej značky. Test kontrastu medzi jednotlivými farebnými časťami dopravnej značky overuje, či sú farebné rozdiely týchto častí dostatočné na to, aby dopravná značka bola dobre čitateľná. Výsledkom tohto testu je odhalenie dopravných značiek s vyblednutou farbou. Overením farebnej homogenity je možné detegovať vzniknutú koróziu, alebo iné faktory, skresľujúce pôvodný obsah dopravnej značky [57-60].

6) Blok určenia pozície a rozmerov

Neoddeliteľnou súčasťou inventarizačného zoznamu sú informácie o globálnej pozícii jednotlivých dopravných značiek. Pozícia konkrétnej dopravnej značky je definovaná jej GPS súradnicami. Hardvérová časť inventarizačného systému je počas procesu inventarizácie umiestnená vo vozidle, ktorého pozícia je vždy rozdielna oproti pozícii dopravnej značky. Presné určenie pozície dopravnej značky je preto možné vykonať iba dodatočnou korekciou podľa vzájomnej vzdialenosti a horizontálnej orientácie kamerového systému (smeru pohybu vozidla). GPS súradnice a informácia o horizontálnej orientácii sú získavané priamo z GPS prijímača. Vzájomná vzdialenosť dopravnej značky a vozidla je vypočítavaná stereoskopickou rekonštrukciou na základe rozdielu umiestnenia konkrétnej dopravnej značky medzi paralelnými snímkami získanými zo vzájomne posunutých kamier. Zistená vzdialenosť je okrem korekcie súradníc použitá pri výpočte reálnych rozmerov dopravnej značky. Rozmery sú určené násobením obrazových rozmerov porovnaním koeficientom, ktorý je závislý od vzdialenosti medzi dopravnou značkou a kamerovým systémom [61,62-75].

7) Inventarizačná databáza

Výsledkom inventarizačného procesu je inventarizačná databáza. Táto databáza predstavuje komplexnú štruktúru vzťahov medzi inventarizáciou, dopravnými značkami, dopravnými komunikáciami, ich úsekmi a správcami týchto komunikácií. Každý inventarizácii sú priradené informácie o jej čase a d a ť u n e a označení cesty a ú s e k u n a k t r o m s a vykonáva. Položky inventarizovaných dopravných značiek nesú informáciu o ich kategórii, type, globálnej pozícii, rozmeroch, stave a úseku dopravnej komunikácie, na ktorej sa nachádzajú. Inventarizačná databáza v grafickom používateľskom rozhraní predstavuje tabuľku s uvedenými informáciami. Výsledok inventarizácie je však uložený do, resp. načítavaný z komplexnej štruktúry dát, ktorú je možné ďalej spracovávať nezávislými nástrojmi, napr. pri vytváraní a hodnotení štatistik poruchovosti dopravného značenia.


IV. POPIS A VÝSLEDKY REALIZOVANÝCH EXPERIMENTOV

A. Vplyv vyváženia bielej farby na rozptyl farebných odtieňov

Výsledná farba pozorovaných objektov je ovplyvňovaná dopadajúcim svetelným žiarením. Rôzny charakter zdroja svetelného žiarenia má za následok rôznu reprezentáciu rovnakej farby pozorovaného objektu. Riešením nežiaduceho rozptylu farebnej reprezentácie pri rôznych svetelných podmienkach je vyváženie bielej farby. Za ideálnych podmienok by jej výsledkom mal byť rovnaký pomer farebných zložiek pri rôznych svetelných podmienkach. Overenie vplyvu vyváženia bielej farby bolo realizované na totožných vzorkách rôznych farieb pri rôznych svetelných podmienkach.

Na Obr. 6 sú znázornené zistené hodnoty s vyhodnotením, ktorá farba bola najviac ovplyvnená svetelnými podmienkami pred vyvážením a ako vyváženie bielej farby vplývalo na rozptyl reprezentácie jednotlivých farieb.

Z týchto výsledkov je zrejmé, že reprezentácia červenej a žltej farby je na zmenu svetelných podmienok citlivejšia ako reprezentácia modrej farby. Aplikácia vyváženia bielej farby má na rozptyl farebnej reprezentácie vo všetkých prípadoch pozitívny vplyv. Vyvážením sa rozptyl vo všetkých prípadoch zmenšil minimálne na úroveň 50% pôvodnej hodnoty. V prípade červenej a žltej farby bol tento rozptyl vplyvom vyváženia eliminovaný ešte výraznejšie. Aplikácia vyváženia farieb podľa referenčných hodnôt umožňuje použitie farebných filtrov s užším rozsahom pre segmentáciu snímkov zaznamenaných v rôznych svetelných podmienkach. V konečnom dôsledku je eliminovaná nutnosť definície rôznych rozsahov farebných filtrov pre rôzne svetelné podmienky, resp. zúžením rozsahov parametrov farebných filtrov je potlačený vznik parazitných segmentov spôsobený príliš širokými rozsahmi týchto parametrov.



Obr. 6. Porovnanie rozptylu farebných odtieňov pred a po vyvážení bielej farby

B. Úspešnosť rozpoznania dopravných značiek

Úspešnosť rozpoznania dopravných značiek optickým korelátorom je závislá od kvality záznamu a kvality predspracovania obrazu pre vstup optického korelátoru. Úspešnosť bola overená v rôznych svetelných podmienkach, vždy so sadou 20 vzoriek dopravných značiek pre každú z troch základných farieb a taktiež pre čiernu farbu, ktorá vo väčšine prípadov tvorí vnútorný piktogram dopravnej značky. Miera podobnosti je stanovená intenzitou korelačných špičiek, ktorá sa pohybuje v rozsahu $<0;255>$. Percento zhody je potom stanovené podielom maximálnej hodnoty a aktuálne zistenej hodnoty obidvoch korelačných špičiek.

Počas experimentov s úspešnosťou správneho rozpoznania dopravných značiek bola zaznamenaná vysoká vzájomná zhoda medzi niektorými vzorkami referenčnej databázy. Pre určenie kategórie, alebo typu dopravnej značky preto nepostačovalo jednoduché prekročenie prahového limitu miery podobnosti. Algoritmus klasifikácie bol upravený tak, aby výsledok klasifikácie bol stanovený podľa referenčnej vzorky s najvyššou mierou podobnosti spomedzi všetkých vzoriek referenčnej databázy v príslušnej skupine.

Prahový limit pre podobnosť základných tvarov bol stanovený na úroveň 40%. Táto hodnota bola určená experimentálne s dôrazom na elimináciu vzniku falošného rozpoznania dopravnej značky. Prahový limit pre podobnosť piktogramov bol stanovený na úroveň 20%. Úroveň zhody vnútorných piktogramov čiernej farby vďaka ich veľkosti, členitosti a nízkemu rozlíšeniu kamerového systému dosahovali výrazne nižšiu podobnosť s referenčnými vzorkami. Keďže piktogram je získavaný iba z obrazu vnútornej časti dopravnej značky, zníženie rozhodovacej úrovne v tomto prípade nezvyšuje riziko falošného rozpoznania.

V nasledujúcich podkapitolách sú opísané, znázornené a vyhodnotené experimenty realizované v rôznych svetelných podmienkach. Každý experiment obsahuje stručnú charakteristiku, tabuľku zistených hodnôt a ich zobrazenie v prehľadných grafoch. Tab. 8 obsahuje rozsahy parametrov farebných filtrov, ktoré boli pri experimentoch použité.

TAB. VIII. DEFINÍCIA POUŽITÝCH FAREBNÝCH FILTROV

	Červená	Modrá	Žltá	Čierna
Hue	$<280;20>$	$<165;235>$	$<0,2;0,7>$	$<0;360>$
Saturation	$<0,1;1>$	$<0,4;1>$	$<0;1>$	$<0;0,3>$
Value	$<0;0,7>$	$<0,15;0,75>$	$<0,1;0,9>$	$<0;0,6>$

1) Úspešnosť rozpoznania pri ideálnych svetelných podmienkach

Prvé meranie bolo realizované na vzorkách dopravných značiek, ktoré boli získané za ideálnych svetelných podmienok. Dopravné značky boli dostatočne osvetlené a kvalita záznamu nebola ovplyvnená žiadnymi rušivými zdrojmi svetla. Zaznamenané dopravné značky boli v zornom poli obidvoch kamier a v ich dostatočnej blízkosti. Tým bola splnená podmienka minimálnej obrazovej veľkosti pre

označenie príslušnej oblasti obrazu ako vhodného kandidáta pre rozpoznanie dopravnej značky. Tento experiment zahŕňa aj vzorky z oblačného, daždivého a hmlistého počasia, ktoré splňali podmienku ich dostatočného osvetlenia. Príklady obrazov analyzovaných v rámci tohto experimentu sú znázornené na Obr. 7.

Zo zistených hodnôt je zrejmé, že rozpoznanie základných tvarov dopravných značiek pri ideálnych svetelných podmienkach je jednoznačná. Ideálne svetelné podmienky zabezpečujú ostré odlíšenie farebných častí dopravnej značky a s tým súvisiace bezchybné prahovanie a detekciu hrán. Výsledkom sú jasne izolované a čitateľné segmenty, ktoré dosahujú vysokú zhodu pri porovnávaní so vzorkami referenčnej databázy.




Obr. 7. Príklady zaznamenaných scén pri ideálnych svetelných podmienkach

Základné tvary červenej a modrej farby dosahovali vo všetkých prípadoch úroveň zhody vysoko nad prahovou hodnotou. Pri úrovniach zhody tvarov dopravných značiek žltej farby bol zaznamenaný výraznejší rozptyl. Rozpoznanie aj napriek tomu vo všetkých prípadoch prebehlo úspešne.

Úroveň zhody vnútorných piktogramov dosahovali vo všeobecnosti nižšie hodnoty s väčším rozptylom. Dôvodom bola ich nedostatočná veľkosť, rôzne úrovne členitosti a nízke rozlíšenie kamerového systému. Celková úspešnosť rozpoznania za ideálnych svetelných podmienok dosiahla hodnotu 97,5%.

2) Úspešnosť rozpoznania pri zhoršených svetelných podmienkach



Obr. 8. Príklady zaznamenaných scén pri zhoršených svetelných podmienkach

Druhý experiment úspešnosti rozpoznania bol realizovaný so vzorkami, ktoré boli zaznamenané v neideálnych svetelných podmienkach. Medzi negatívne vplyvy, ktoré zhoršujú kvalitu záznamu patrí nedostatočné osvetlenie dopravných značiek, alebo nežiaduce priame svetlo dopadajúce z rôznych zdrojov (slnko, alebo reflektory oprotiidúcich vozidiel) na plochu kamerového snímača.

Nežiaduci vplyv na kvalitu záznamu mali prudké zmeny svetelných podmienok v rôznych úsekoch dopravnej komunikácie. Príklady negatívne ovplyvnených snímok sú zobrazené na Obr. 8.


Z výsledkov experimentu vyplýva, že zhoršené svetelné podmienky negatívne ovplyvňujú kvalitu zaznamenaného obrazu a jeho ďalšej analýzy. Reprezentácia hľadaných tvarov dopravných značiek bola v týchto prípadoch mierne znehodnotená a výsledkom segmentácie boli objekty s narušenou celistvosťou, resp. objekty s parazitnými prvkami. Vďaka týmto nedostatkom boli výsledky porovnávania segmentov so vzorkami referenčnej databázy menej jednoznačné a spoľahlivosť korektného rozpoznania bola nižšia ako v predchádzajúcom prípade, pri ideálnych svetelných podmienkach. Rozptyl úrovni zhody bol podstatne vyšší ako za ideálnych svetelných podmienok. Najvyššia miera úspešného rozpoznania bola zaznamenaná v prípade dopravných značiek so základným tvarom modrej farby, kde boli úspešne rozpoznané všetky vzorky. V prípade červenej farby neboli rozpoznané 2 dopravné značky a v prípade žltej farby 4 dopravné značky. Z piktogramov neboli rozpoznané 4 vzorky. Celková úspešnosť v tomto prípade dosahovala 87,5%.

3) Úspešnosť rozpoznania v noci

Posledným experimentom pre zistenie úspešnosti rozpoznávania dopravných značiek je spracovanie vzoriek, ktoré boli zaznamenané v noci. Zaznamenané dopravné značky boli osvetlené reflektormi inventarizačného vozidla a tiež lampami pouličného osvetlenia. Výsledky tohto experimentu poukazujú na výrazné nedostatky v zázname obrazov dopravných značiek realizovaných bez prítomnosti denného svetla.



Obr. 9. Príklady scén zaznamenaných v noci



Obr. 10. Rozmazané zábery zaznamenané z pohybujúceho sa vozidla v noci

Primárnym nedostatkom bola rozdielnosť vo farebnej reprezentácii dopravných značiek z rôznych materiálov a v rôzne osvetlených prostrediach. Rozdielnosť reprezentácie je viditeľná na Obr. 9. Sekundárnym nedostatkom pri použití

špecifikovaných kamier bola nízka citlivosť obrazového snímača. Použiteľné hodnoty expozičného času vzhľadom na vyhovujúcu farebnú reprezentáciu mali za následok rozmazané obrazy objektov pri pohybe inventarizačného vozidla. Ich príklady sú znázornené na Obr. 10. Keďže vzorky dopravných značiek neboli v tomto prípade pre segmentáciu použiteľné, experiment bol realizovaný so statickými vzorkami.

Výsledky tohto experimentu poukazujú na výrazný vplyv konkrétnych svetelných podmienok na úspešnosť rozpoznania dopravných značiek. Rozpoznávanie dopravných značiek z úsekov s verejným osvetlením dosahovalo vysokú úspešnosť. Pri vzorkách z úsekov bez osvetlenia bola úspešnosť výrazne nižšia. Najvyššia miera úspešného rozpoznania bola dosiahnutá pri vzorkách dopravných značiek modrej farby, kde boli úspešne rozpoznané všetky dopravné značky. Pri vzorkách červenej farby neboli rozpoznané 3 dopravné značky, pri vzorkách modrej farby neboli rozpoznané 2 dopravné značky a pri vzorkách žltej farby bolo problematických 5 dopravných značiek. Segmentácia piktogramov bola kvôli nižšiemu kontrastu a vysokému šumu taktiež problematická. Zo všetkých vzoriek zaznamenaných v noci nebolo rozpoznávaných až 6 piktogramov. Celková úspešnosť rozpoznania dopravných značiek zaznamenaných v noci bola na úrovni 80%.

4) Celková úspešnosť rozpoznania a jej porovnanie so svetovými výsledkami

V Tab. 9 sú uvedené hodnoty percentuálnej úspešnosti pre každú farbu a pre všetky typy svetelných podmienok. Z hľadiska úspešnosti rozpoznania tvaru konkrétnej farby boli dosiahnuté najlepšie výsledky so značkami modrej farby, kde celková úspešnosť rozpoznania bola 96,66%. Nižšia úspešnosť bola zaznamenaná pri vzorkách červenej farby, kde jej hodnota dosahovala 91,66. Vzorky žltej farby boli rozpoznané v 85% prípadov. Najnižšia celková úspešnosť bola zaznamenaná pri rozpoznávaní piktogramov, kde jej hodnota dosahovala iba 80%.

Z hľadiska svetelných podmienok dosiahnuté výsledky odrážali kvalitu zaznamenaného obrazu. Pri obraze zaznamenanom v ideálnych svetelných podmienkach bola reprezentácia dopravných značiek v obraze zreteľná, vďaka čomu bola dosiahnutá vysoká kvalita segmentácie. So zhoršujúcimi sa svetelnými podmienkami sa kvalita získaných segmentov zhoršovala, čím sa znižovala aj podobnosť so vzorkami referenčnej databázy.

Rozdielnosť úspešnosti rozpoznania medzi vzorkami jednotlivých farieb je spôsobená rozdielnymi rozmermi príslušných typov dopravných značiek a rozdielnou členitosťou porovnávaných tvarov v rámci danej farebnej skupiny. Nižšia úspešnosť v rozpoznávaní piktogramov je navyše spôsobená ich menšími rozmermi a nízkou rozlišovacou schopnosťou kamerového systému.

Celková úspešnosť rozpoznania dopravných značiek navrhnutého systému bola 88,33%.

TAB. IX. TABUĽKA ÚSPEŠNOSTI NAVRHOVANÉHO SYSTÉMU

Podmienky	Červená	Modrá	Žltá	Čierna	Celkom
Ideálne	100%	100%	100%	90%	97,50%
Zhoršené	90%	100%	80%	80%	87,50%
Noc	85%	90%	75%	70%	80,00%
Celkom	91,66%	96,66%	85,00%	80,00%	88,33%

TAB. X. POROVNANIE ÚSPEŠNOSTI METÓD ROZPOZNÁVANIA DOPRavných značiek

Autor	Metóda	Úspešnosť
Daraghmi	Spájanie oblastí	85,0%
Harasthy	Farebná filtrácia	87,0%
Rakoci	Farebná filtrácia + vyváženie farieb	88,3%
Mathias	Transformácia SIFT	88,9%
Daraghmi	Spájanie oblastí + vektorizácia	96,0%

V Tab. 10 je uvedené porovnanie úspešnosti rozpoznania dopravných značiek navrhnutého inventarizačného systému oproti iným systémom rozpoznávania dopravných značiek s rôznymi metódami spracovania obrazu. Úspešnosť navrhovaného systému je výrazne ovplyvnená zahrnutím experimentov realizovaných v noci a použitím kamerového systému s relatívne nízkou rozlišovacou schopnosťou. Použitím kamerového systému s citlivejšími snímačmi a väčšou rozlišovacou schopnosťou je možné úspešnosť systému zvýšiť.

C. Presnosť určenia pozície dopravných značiek

Presnosť určenia pozície dopravných značiek v navrhnutom systéme závisí od viacerých faktorov. Základom správneho určenia pozície je presnosť GPS súradníc získavaných GPS prijímačom. Jeho presnosť pri statickom meraní je daná výrobcom a pohybuje sa od niekoľkých metrov až po presnosť niekoľkých centimetrov. Presnosť pri meraní GPS súradníc počas pohybu vozidla bola overená experimentálne porovnaním statických súradníc voči súradniciam získaným počas pohybu vo vopred určených bodoch stanovenej trasy pri rôznych rýchlostiach pohybu vozidla.

Sekundárnym faktorom, ovplyvňujúcim presnosť určenia pozície je meranie vzdialenosti dopravnej značky od aktuálnej pozície inventarizačného vozidla v ktorom je umiestnený kamerový systém a GPS prijímač. Meranie vzdialenosti je možné realizovať niekoľkými spôsobmi, no pre tento účel je najvhodnejšie stereoskopické meranie. Presnosť tohto merania bola overená porovnaním zistených hodnôt s hodnotami alternatívneho merania. Alternatívne meranie bolo realizované na základe pomeru skutočnej a obrazovej veľkosti dopravnej značky.

1) Meranie GPS pozície inventarizačného vozidla

Presnosť určenia okamžitej pozície inventarizačného vozidla je ovplyvnená technológiou výpočtu GPS súradníc, ale taktiež rýchlosťou pohybujúceho sa vozidla v ktorom je GPS prijímač umiestnený. Špecifickým problémom určovania

pozície v automatickom inventarizačnom systéme je niekoľko násobne nižšia obnovovacia frekvencia GPS prijímača oproti snímkovej frekvencii kamerového systému. Jediná súradnica je tak priradená viacerým snímkam, ktoré boli kamerovým systémom zaznamenané. Ďalším problémom je oneskorený výstup konkrétnej GPS súradnice zo sériového portu GPS prijímača, následkom čoho vzniká nežiaduci posun priradených súradníc oproti skutočnej pozícii počas záznamu príslušnej snímky. Nasledujúce experimenty overujú účinnosť metód navrhnutých pre elimináciu spomenutých problémov.

a) Určenie GPS pozície bez eliminácie chýb

Prvým experimentom určenia GPS pozície vozidla je meranie chyby, ktorá vzniká pri zázname GPS súradníc priamo z GPS prijímača bez akejkoľvek eliminácie chyby. Každý snímke videozáznamu boli priradené GPS súradnice, ktoré boli získané z prijímača ako posledné. Pri obnovovacej frekvencii GPS prijímača 1 Hz a snímkovej frekvencii 30 Hz je jediná GPS súradnica priradená 30 snímkam. Keďže predpokladom je, že chyba merania so stúpajúcou rýchlosťou bude narastať, meranie je realizované pri 3 rôznych rýchlostiach. Výsledné odchýlky sú získané porovnaním vzdialenosti medzi odmeranými GPS súradnicami a statickými GPS pozíciami.

Zistené hodnoty odzrkadľujú reálnu presnosť merania GPS súradníc pri pohybe. Tieto hodnoty sú pre účely automatickej inventarizácie nepoužiteľné. Pri zvyšujúcej sa rýchlosti pohybu sa chyba merania GPS súradníc zväčšuje. Pri najnižšej rýchlosti 30 km/h bola priemerná chyba 8,08m. Pri rýchlosti 70 km/h predstavovala táto chyba v priemere až 14,28 m.

b) Eliminácia chyby delením obnovovacej periódy GPS prijímača

Algoritmus delenia obnovovacej periódy GPS prijímača spočíva vo výpočte čiastkových rozdielov GPS súradníc pre každú snímku získanú počas tejto periódy. Každý priradený snímke je takýmto spôsobom priradená jedinečná GPS súradnica, ktorá by za predpokladu rovnomerného pohybu mala zodpovedať skutočnosti.

Z porovnania výsledkov z predchádzajúceho experimentu vyplýva, že eliminácia delením obnovovacej periódy má na presnosť určenia pozície výrazne pozitívny vplyv. Presnosť určenia sa vo všetkých prípadoch a pri každej rýchlosti výrazne zvýšila. Presnosť so stúpajúcou rýchlosťou klesá, ale rozdiel je oveľa menej výrazný ako v prípade merania bez eliminácie. Pri rýchlosti 30 km/h bola zaznamenaná priemerná chyba 3,37 m. Priemerná chyba pri najvyššej rýchlosti 70 km/h bola 4,36 m.


c) Eliminácia chyby posunom registra súradníc

Ďalším problémom, ktorý ovplyvňuje presnosť merania GPS súradníc je oneskorený záznam a nesprávne priradenie GPS súradníc príslušným snímkam. Hlavným dôvodom tohto problému je hardvérové oneskorenie medzi meraním GPS pozície a jej vyslaním na sériovú linku GPS prijímača. Tento problém je riešený posunom registra získaných súradníc. Veľkosť tohto posunu je určená rýchlosťou pohybu vozidla

s GPS prijímačom. Závislosť medzi rýchlosťou a potrebnou veľkosťou posunu bola stanovená experimentálne. Výsledky realizovaného experimentu odzrkadľujú súčasné použitie eliminácie delením intervalu a eliminácie posunom registra súradníc.

Algoritmus posunu registra súradníc výrazne prispel k presnosti určenia pozície. Vyššia rýchlosť, podobne ako v predchádzajúcich prípadoch, negatívne ovplyvňuje presnosť merania. Zistené odchýlky sa však aj pri najvyššej rýchlosti pohybujú približne v rozsahu, ktorý bol určený výrobcom použitého GPS prijímača. Túto presnosť je možné zvýšiť iba voľbou presnejšieho typu prijímača. Pri rýchlosti 30 km/h bola priemerná chyba merania 1,58 m. Pri najvyššej rýchlosti 70 km/h priemerná chyba dosiahla úroveň 2,54 m.

Na Obr. 11 sú výsledky jednotlivých metód pre elimináciu odchýlok porovnané graficky. Vyššia rýchlosť vo všetkých prípadoch ovplyvňuje presnosť merania negatívne. Obidve metódy eliminácie však majú na presnosť v každom prípade pozitívny vplyv.



Obr. 11. Porovnanie vplyvu eliminácií chýb na presnosť určenia GPS súradníc

2) Meranie vzdialenosti dopravnej značky od inventarizačného vozidla


Ďalším faktorom ovplyvňujúcim presnosť určenia pozície je meranie vzdialenosti dopravnej značky. Keďže meranie vzdialenosti dopravnej značky od kamerového systému je realizované stereoskopickým meraním, predpokladom je zabezpečenie dokonalej synchronizácie páru kamier tak, aby jednotlivé páry snímok boli získavané v rovnakom momente.

V tomto experimente boli realizované štyri merania pri rôznych rýchlostiach pohybu inventarizačného vozidla. Výsledky stereoskopického merania boli porovnané s alternatívnou metódou merania vzdialenosti, na základe pomeru reálnej a obrazovej veľkosti meraného objektu.

Prvé meranie pri rýchlosti 0 km/h bolo realizované pre ilustráciu dokonalej synchronizácie stereoskopického systému kamier. Ďalšie merania boli realizované za účelom zistenia

vplyvu rýchlosti na presnosť merania vzdialenosti. Porovnanie hodnôt pri rôznych rýchlostiach je znázornené na Obr. 12.

Zo zistených hodnôt je zrejmé, že presnosť merania je pri použití navrhnutej softvérovej synchronizácie vo vysokej miere závislá od rýchlosti pohybu kamerového systému. Posun v umiestnení objektov medzi paralelnými snímkami je počas jednej snímkovej periódy výrazne skreslený a vzniká tak nezanedbateľná chyba v meraní vzdialenosti dopravných značiek od inventarizačného vozidla. Pri statickom meraní bola chyba merania iba na úrovni 0,197 m. Pri rýchlosti 70 km/h však stúpila až na hodnotu 15,197 m. Keďže so stúpajúcou vzdialenosťou rozlišovacia schopnosť klesá, veľkosť chyby bola výraznejšia pri meraní vzdialenejších objektov. Výsledky ukazujú, že softvérová synchronizácia pri použití špecifikovaného kamerového systému nie je vyhovujúca. Jej efektívnosť je možné zvýšiť použitím kamerového systému s vyššou snímkovou frekvenciou, alebo úplne nahradiť kamerovým systémom s možnosťou hardvérovej synchronizácie.



Obr. 12. Porovnanie chýb merania vzdialenosti pri rôznych rýchlostiach pohybu inventarizačného vozidla

D. Spôľahlivosť overenia stavu

Posledným realizovaným typom experimentov bolo zistenie spoľahlivosti overovania stavu dopravných značiek. Overovanie stavu pozostáva z niekoľkých nezávislých krokov, ktorých funkcia a spoľahlivosť závisí od rôznych faktorov. Všetky navrhnuté metódy používajú pre overenie stavu špecifické ukazovatele. Test proporcií je založený na porovnaní pomeru rozmerov reálnej a referenčnej vzorky. Test relatívneho kontrastu spočíva v porovnaní farieb susedných častí dopravnej značky. Parametrom určujúcim homogenitu farebných častí je veľkosť farebných gradientov. Test zhody piktogramov je založený na ich podobnosti s referenčnými vzorkami. Experimenty boli realizované pre každú metódu so sadou 20 vzoriek. Výsledkom experimentov je porovnanie smerodajných parametrov so skutočným stavom dopravných značiek.

1) Test proporcií

Prvým krokom v určovaní stavu dopravnej značky je test proporcií. V tomto experimente boli porovnávané proporcie dopravných značiek zo zaznamenaného obrazu voči proporciám vzoriek z referenčnej databázy. Obrazové rozmery zaznamenaných dopravných značiek sú určené veľkosťou obrazového segmentu po farebnej filtrácii. Obr. 13 znázorňuje príklady dopravných značiek s reálnou poruchou vzhľadom na pozíciu vozidla na vozovke.




Obr. 13. Nesprávne naklonené dopravné značky vzhľadom na smer jazdy

Medzi vzorkami s reálnou poruchou sú zahrnuté aj obrázky správne inštalovaných dopravných značiek, ktoré sú súčasťou iného úseku a z pohľadu inventarizačného vozidla sa javia ako nesprávne naklonené. Rozhodovací prah rozdielu reálnych proporcií voči ideálnym bol stanovený na hodnotu 0,1.

Výsledky tohto experimentu jednoznačne korešpondujú s reálnym stavom dopravných značiek. Hodnoty rozdielu proporcií boli pri dopravných značkách bez poruchy výrazne pod stanoveným prahom. Všetky vzorky dopravných značiek s viditeľnou poruchou mali hodnoty rozdielu proporcií nad týmto prahom. Úspešnosť detekcie poruchy bola v tomto prípade 100%.

2) Test relatívneho kontrastu

Dalšou metódou pre overenia stavu dopravných značiek je test relatívneho kontrastu medzi ich susednými farebnými časťami. Predpokladaným výsledkom tejto metódy má byť detekcia dopravných značiek, ktorých viditeľnosť a čitateľnosť je znížená vyblednutím niektorej z farieb napr. vplyvom UV žiarenia. Príklady týchto dopravných značiek sú zobrazené na Obr. 14. Stav dopravných značiek je v tomto prípade hodnotený na základe vzdialenosti farieb dvoch susedných farebných častí vo farebnom priestore CIE L*a*b*. Rozhodovacia úroveň medzi vyhovujúcim a nevyhovujúcim stavom bola stanovená na hodnotu vzdialenosti 20.



Obr. 14. Dopravné značky s degradovanými farebnými časťami

Zistené hodnoty vzdialenosti farieb susedných častí korešpondujú s reálnym stavom dopravných značiek. Vzorky s nevýraznou vyblednutou farbou mali podstatne menšiu

vzájomnú vzdialenosť ako vzorky s jasnou a výraznou farbou. Keďže reálny stav bol posudzovaný subjektívne, prahovú hodnotu vzdialenosti farieb susedných častí je v praxi možné posunúť na požadovanú úroveň. Úspešnosť tejto metódy overenia stavu dopravných značiek bola 100%.

3) Test farebnej homogenity

Test farebnej homogenity slúži na detekciu nežiaducich elementov na doplnkovej časti dopravných značiek. V rámci experimentálneho overenia spoľahlivosti tohto testu bolo realizované meranie homogenity na vzorkách dopravných značiek, ktoré zahrňali vyhovujúce aj nevyhovujúce prípady. Medzi vzorky s reálnou poruchou patria dopravné značky, ktoré sú poškodené sprejom, začínajúcou koróziou, alebo čiastočným zatienením. Príkladom sú dopravné značky zobrazené na Obr. 15.

Nehomogenitu v obraze tvoria farebné gradienty rôznej strmosti. Stav dopravnej značky je v tomto prípade hodnotený na základe priemernej hodnoty jasu obrazových prvkov po procese spájania hrán nad obrazom analyzovanej plochy dopravnej značky. Nízka hodnota znamená súvislú plochu jedinej farby. Vyššie hodnoty signalizujú stav, kedy je táto plocha narušená nežiaducim elementom.

Výsledky vo väčšine prípadov zodpovedali reálnemu stavu. Rozhodovacia úroveň bola v tomto prípade stanovená na hodnotu priemerného jasu 8. Pri tejto konfigurácii bola zaznamenaná jedna neúspešná detekcia nevyhovujúceho stavu. Neskoršou analýzou bolo zistené, že dopravná značka obsahovala menej výrazný nežiaduci element. Priemerná hodnota jasu v tomto prípade bola podobná ako priemerná hodnota jasu, ktorú spôsobuje šum pri dopravných značkách bez narušenej homogenity. Úspešnosť tejto metódy overovania stavu bola 95%.



Obr. 15. Dopravné značky s narušenou farebnou homogenitou ich doplnkovej časti

4) Test zhody piktogramu

Poslednou metódou pre overenie stavu dopravnej značky je test zhody piktogramu. Táto metóda je súčasťou samotného procesu rozpoznávania dopravných značiek. Jej funkcia bola experimentálne overená na vzorkách, medzi ktorými boli zahrnuté dopravné značky s poškodeným piktogramom. Porucha piktogramu predstavovala jeho znečistenie, neúplnosť, alebo nevhodný doplnok, ako je znázornené na Obr. 16. Prahová hodnota vyhovujúceho stavu bola stanovená na 20%, ako pri overení úspešného rozpoznania dopravných značiek.



Obr. 16. Dopravné značky s poškodeným piktogramom

Zistené hodnoty aj v tomto prípade korešpondovali so skutočným stavom. Percentuálna zhoda s referenčnými vzorkami bola v prípade poruchy pod stanovenou prahovou hodnotou. Medzi všetkými realizovanými meraniami boli zaznamenané dva prípady falošnej detekcie chybného piktogramu. Falošná detekcia bola spôsobená nízkou rozlišovacou schopnosťou kamerového systému. Úspešnosť správnej detekcie poruchy bola v tomto prípade 90%.

V. ZÁVER

Zrýchľujúci sa vývoj dopravnej infraštruktúry vyžaduje čoraz častejšiu údržbu a analýzu stavu dopravných komunikácií. Dôležitou súčasťou dopravnej infraštruktúry je zvislé dopravné značenie, ktoré zabezpečuje plynulosť premávky, navigáciu vodičov a prispieva k celkovej bezpečnosti na cestách. Konvenčná inventarizácia a overovanie stavu dopravného značenia je v súčasnosti na ústupe a táto úloha je delegovaná na automatické inventarizačné systémy.

Navrhovaný automatický inventarizačný systém využíva optický korelátor ako hlavný výpočtový prvok, ktorý vykonáva Fourierovu transformáciu optickou cestou, čím výrazne zvyšuje rýchlosť spracovania v jeho najkritickejšom bode, ktorým je výpočet korelácie medzi zaznamenaným a referenčným obrazom.

Medzi najdôležitejšie výsledky výskumu patrí:

- Návrh novej architektúry systému pre rozpoznávanie dopravných značiek s využitím optického korelátora. V rámci tohto návrhu bolo predspracovanie obrazu farebnou filtráciou doplnené o vyváženie bielej farby na základe kalibračnej vzorky. Manuálna výmena informácií medzi korelátorom a riadiacim počítačom bola nahradená plne automatickou komunikáciou využitím softvérových knižníc, dodávaných spolu s optickým korelátorom.
- Rozpracovanie a implementácia tohto systému do novej architektúry video dohľadového systému pre automatický inventarizačný systém dopravných značiek. Implementácia zahŕňa návrh a realizáciu štruktúry referenčnej databázy a kaskádového spracovania, softvérovej synchronizácie kamerového systému, stereoskopického merania vzdialenosti a eliminácie chyby určenia GPS súradníc.
- Rozpracovanie a implementácia systému evidencie značiek v databáze v rámci ktorých je zahrnutý návrh

štruktúry inventarizačnej databázy a jej aplikácia v navrhnutom inventarizačnom systéme.

- Experimentálne overenie navrhnutého systému. Realizované experimenty boli zamerané na overenie zníženia rozptylu farieb po vyvážení bielej farby, overenie úspešnosti rozpoznávania a overenie presnosti určenia pozície dopravných značiek.

Funkcia a spoľahlivosť navrhnutého inventarizačného systému bola overená experimentálne so zameraním na vplyv vyváženia bielej farby, úspešnosť rozpoznania dopravných značiek, presnosť stanovenia presnej pozície a úspešnosť overenia ich stavu.

Vyváženie bielej farby bolo testované na vzorkách 3 rôznych farieb pri rôznych zdrojoch svetelného žiarenia. Jeho aplikácia mala vo všetkých prípadoch pozitívny vplyv na rozptyl farebnej reprezentácie spôsobený vplyvom rôzneho charakteru dopadajúceho svetla. Algoritmu vyváženia bielej farby mal najmenší vplyv na reprezentáciu objektov modrej farby. Rozptyl bol v tomto prípade znížený o 50%. Naopak, najväčší vplyv bol zaznamenaný pri vzorkách žltej farby, kde aplikácia vyváženia znížila rozptyl až o 67%.

Úspešnosť správneho rozpoznania dopravných značiek bola overovaná v rôznych prostrediach s rôznymi svetelnými podmienkami. Úspešnosť rozpoznania pri ideálnych svetelných podmienkach dosiahla úroveň 97,5%. Zhoršené svetelné podmienky mali na spoľahlivosť rozpoznania negatívny vplyv. Dopravné značky boli v tomto prípade úspešne rozpoznávané v 87,5% prípadoch. Úspešnosť rozpoznania dopravných značiek v noci bola na úrovni 80%. Celková percentuálna úspešnosť rozpoznania dopravných značiek dosiahla hodnotu 88,33%. Potenciálnym riešením pre zvýšenie úspešnosti rozpoznania je použitie kamerového systému s citlivejšími snímačmi a vyššou rozlišovacou schopnosťou a taktiež použitie prídavného reflektora osvetľujúceho snímané objekty pri zhoršených svetelných podmienkach a v noci.

Ďalším typom experimentov bolo overovanie navrhnutých metód pre určenia presnej pozície dopravných značiek. Dva navrhnuté algoritmy na elimináciu chýb merania GPS súradníc. Prvým algoritmom je delenie obnovovacej periódy GPS prijímača a druhým je posun registra súradníc. Aplikáciou oboch algoritmov bola dosiahnutá výrazná eliminácia pôvodne vzniknutej chyby. Pri rýchlosti 30 km/h bola chyba určenia pozície zmenšená z 8,08 m na 1,58 m. Pri rýchlosti 70 km/h bola zmenšená z 10,56 m na 2,54 m. Presnosť stereoskopického merania vzdialenosti pre korekciu GPS súradníc bola vo vysokej miere závislá od rýchlosti inventarizačného vozidla. Kým pri statickom meraní bola chyba na úrovni 0,197 m, pri najvyššej rýchlosti 70 km/h bola táto chyba až 15,197 m. Vzniknutú chybu je možné zmenšiť použitím kamier s vyššou snímkovou frekvenciou, resp. úplne odstrániť použitím kamerového systému s možnosťou hardvérovej synchronizácie.

Posledné experimenty boli venované spoľahlivosti overenia stavu, resp. detekcie poruchy dopravných značiek.

Spoľahlivosť overenia stavu bola testovaná zvlášť pre všetky štyri navrhnuté algoritmy. Test proporcií dopravných značiek a test relatívneho kontrastu ich farebných častí dosahovali úspešnosť 100%. Pri testoch farebnej homogenity bola zaznamenaná jedna falošná detekcia a pri testoch zhody piktogramu dve falošné detekcie zo všetkých testovaných vzoriek. Falošné detekcie boli spôsobené nízkou rozlišovacou schopnosťou kamerového systému, tak ako v prípade rozpoznávania piktogramu v dopravných značkách. Celková úspešnosť overenia stavu dopravných značiek, resp. detekcie ich poruchy bola 96,25%. Túto úspešnosť je možné taktiež zvýšiť použitím kamerového systému s vyššou rozlišovacou schopnosťou.

Zaujímavým zameraním výskumu v oblasti videodohľadových systémov do budúcnosti je 3D rekonštrukcia, vďaka ktorej by sa mohla zvýšiť spoľahlivosť rozpoznania dopravných značiek. Existuje niekoľko potenciálnych metód, ktoré rôznymi spôsobmi získavajú informáciu o tzv. hĺbke z existujúcich dvojrozmerných obrazov. Vďaka 3D rekonštrukcii je tak možné získať obrazy reálnych tvarov dopravných značiek bez ohľadu na ich farebnosť. Táto metóda môže nahrádzať, alebo dopĺňať farebnú filtráciu a zvyšovať pravdepodobnosť úspešného rozpoznania dopravných značiek. Vďaka vzájomnému posunu vzoriek pri stereoskopickom meraní je pre meranie vzdialenosti snímaných objektov možné využiť priamo optický korelátor. Vzdialenosť by v tomto prípade bola určená relatívnou pozíciou korelačných špičiek v korelačnej rovine optického korelátora.

POĎAKOVANIE

Tento článok bol vypracovaný vďaka podpore projektov Rozvoj Centra informačných a komunikačných technológií pre znalostné systémy (ITMS 26220120030) a Centrum excelentnosti integrovaného výskumu a využitia progresívnych materiálov a technológií v oblasti automobilovej elektroniky (ITMS 26220120055).

REFERENCIE

- [1] OVSEŇÍK, L.; KAŽIMÍROVÁ, A.; TURÁN, J. (2010). Video Surveillance Systems. In: Acta Electrotechnica et Informatica, Vol. 10, No. 4, 2010, p. 46-53 – ISSN 1335-8243
- [2] SRI INTERNATIONAL. Computer Vision Technologies R&D [online]. [cit. 2018-02-15]. Dostupné na internete: <<https://www.sri.com/research-development/computer-vision>>
- [3] CHEN, Z.; HUANG, X. (2014). Real-Time Traffic Sign Detection and Recognition Using GPU. In: 2014 IEEE High Performance Extreme Computing Conference (HPEC), Sept. 2014, Waltham, MA, USA, p. 109-110 – ISBN 978-1-4799-6233-4
- [4] DARAGHMI, Y.-A.; HASASNEH, A. M. (2016). Accurate Real-Time Traffic Sign Recognition Based on the Connected Component Labeling and the Color Histogram Algorithms. In: International Journal of Signal Processing Systems Vol. 4, No. 5, October 2016, p. 417-421 - ISSN: 2315-4535
- [5] MIURA, J.; KANDA, T.; SHIRAI, Y. (2000). An Active Vision System for Real-Time Traffic Sign Recognition. In: Proc. 2000 IEEE Int. Conf. on Intelligent Transportation Systems, pp. 52-57, Dearborn, MI, Október 2000

- [6] ZHANG, J.; HUANG, M.; JIN, X.; LI, X. (2017). A Real-Time Chinese Traffic Sign Detection Algorithm Based on Modified YOLOv2. In: *Algorithms* 2017, 10, 127 - EISSN 1999-4893.
- [7] AMATO, A.; LECCE, V. (2011). Semantic Classification of Human Behaviors in Video Surveillance Systems. In: *WSEAS Transactions on Computers*, Issue 10, Volume 10, October 2011, p. 343-352 - ISSN 1109-2750
- [8] FITZSIMONS, J. (2014). Identifying Abandoned, Moved and Removed Objects in Automated Surveillance Systems. Final Thesis, University of Dublin, Trinity College, June 2014.
- [9] KE, S.-R.; THUC, H. L. U.; LEE, Y.-J.; HWANG, J.-N.; YOO, J.-H.; CHOI, K.-H. (2013). A Review on Video-Based Human Activity Recognition. In: *Computers* 2013, No. 2, p. 88-131 - ISSN 2073-421X
- [10] KARUNGARU, S.; NAKANO, H.; FUKUMI, M. (2013). Road Traffic Signs Recognition Using Genetic Algorithms and Neural Networks. In: *International Journal of Machine Learning and Computing*, Vol. 3, No. 3, June 2013, p. 313-317 - ISSN: 2010-3700
- [11] LORSAKUL, A.; SUTHAKORN, J. (2007). Traffic Sign Recognition for Intelligent Vehicle/Drivers Assistance System Using Neural Network on OpenCV. In: *The 4th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI 2007)*
- [12] BLOISI, D.D. (2009). Visual Tracking and Data Fusion for Automatic Video Surveillance. Dottorato di Ricerca in Ingegneria Informatica, SAPIENZA Università di Roma, September 2009
- [13] DEVASENA, C.L. (2011). Video Surveillance Systems – A Survey. In: *IJCSI International Journal of Computer Science Issues*, Vol. 8, Issue 4, No 1, July 2011, p. 635-642 - ISSN 1694-0814
- [14] FERENCZI, T.; DORNER, J. (2008). Videnie mobilného robota pomocou wifi kamery. In: *AT&P journal PLUS1*, p. 50-53
- [15] PASCUAL, J. P. C. (2009). Advanced Driver Assistance System based on Computer Vision using Detection, Recognition and Tracking of Road Signs. Thesis Doctoral. Universidad Carlos III de Madrid, Departamento de Ingeniería de Sistemas y Automática, Leganés, Júl 2009
- [16] BRKIĆ, K.; PINZ, A.; ŠEGVIĆ, S. (2009) Traffic sign detection as a component of an automated traffic infrastructure inventory system. In: *Proc. 33rd OAGM Workshop*, May 2009, Stainz, Austria
- [17] RUŽBARSKÝ, J.; OVSENIK, E.; TURÁN, J. (2013). Traffic Signs Inventory System. In: *Carpathian Journal of Electronic and Computer Engineering* 6/1 (2013), p. 44-49 - ISSN 1844 - 9689
- [18] SUMI, K. M.; A. KUMAR, M. N. (2017). Detection and Recognition of Road Traffic Signs – A Survey. In: *International Journal of Computer Applications*, Volume 160 - No.3, February 2017 - ISSN 0975 - 8887
- [19] TSAI, V. J. D.; CHEN, J.-H.; HUANG, H.-S. (2016). Traffic Sign Inventory from Google Street View Images. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLI-B4, 2016, XXIII ISPRS Congress, 12–19 July 2016, Prague, Czech Republic, p. 243-246 - ISSN 1682-1750
- [20] ŽÍDEK, K.; KOUBEK, T.; PROCHÁZKA, D.; VYTEČKA, M. (2015). Assistance System for Traffic Signs Inventory. In: *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, Volume 63, Number 6, November 2015, p. 2197-2204
- [21] 3M ROADWAY MAINTENANCE SERVICES. Sign Management for Visibility and Safety [online] [cit. 2018-02-15]. Dostupné na internete: <http://solutions.3m.com/my/3MContentRetrievalAPI/BlobServlet?lmd=1259734811000&locale=en_US&assetType=MMM_Image&assetId=180617493728&blobAttribute=ImageFile>
- [22] WOLSHON, B. (2003). Louisiana Traffic Sign Inventory and Management System – Final Report (03/01/02-06/30/03) of LTRC Project No. 01-1SS. Department of Civil and Environmental Engineering, Louisiana State University, Baton Rouge, Louisiana 70803, September 2003
- [23] YOONG, J. (2017). I Saw the Sign: 3 Trends in Traffic Sign Inventory with Street-level Photos [online] [cit. 2018-02-15]. Dostupné na internete: <<https://blog.mapillary.com/tech/2017/03/02/traffic-sign-inventory-with-street-level-photos.html>>
- [24] GREEN, E. R. (2006). Development of a Traffic Sign Inventory System (Sign Click). Research Report, Kentucky Transportation Center, University of Kentucky, Lexington, Kentucky 2006
- [25] GUAN, H.; LI, J.; CAO, S.; YU, Y. (2016). Use of mobile LiDAR in road information inventory: a review. In: *International Journal of Image and Data Fusion*, 7:3, p. 219-242 - ISSN 1947-9832
- [26] LANDA, J.; PROCHAZKA, D. (2014). Automatic Road Inventory Using LiDAR. In: *Enterprise and the Competitive Environment 2014 conference, ECE 2014*, 6–7 March 2014, Brno, Czech Republic, p. 363-370 - ISSN 2212-5671
- [27] AGILE ASSETS. Sign Manager [online] [cit. 2018-02-15]. Dostupné na internete: <<https://www.agileassets.com/products/sign-manager/>>
- [28] ARC GIS. Sign Inventory [online] [cit. 2018-02-15]. Dostupné na internete: <<http://solutions.arcgis.com/local-government/help/sign-inventory/>>
- [29] ELLISON, J. W. P.E. (2008). Tapping into the Power of a Traffic Sign Inventory to Meet the New Retroreflectivity Requirements. In: *Compendium of Technical Papers, Annual Meeting and Exhibit, Institute of Transportation Engineers*, Anaheim, CA, 2008
- [30] KIMLEY-HORN AND ASSOCIATES, INC. (2012). The City of Oak Hill: Citywide Traffic Sign Inventory and Management System. Nashville, Tennessee, September 2012, Nashville, Tennessee. KHA Project Number. 118028005
- [31] THOMAS, G.B. (2001). Traffic Signal Inventory Project – Final Report. Center for Transportation Research and Education, Iowa State University, June 2001, Iowa, USA.
- [32] KOPERNICKÝ, M. (2012). Využitie zariadení pre priradenú interakciu v oblasti počítačového videnia. Študentská vedecká konferencia, Univerzita Pavla Jozefa Šafárika, Prírodovedecká fakulta, Ústav Informatiky, Košice 2012
- [33] RIBEIRO, P. R. A.; RIBEIRO, F.; LOPES, G. (2011). Vision and Distance Integrated Sensor (Kinect) for an Autonomous Robot. In: *Revista Técnico-Científica: Robótica*.pt 85(4), 2011 - ISSN 0874-9019
- [34] THANH, H. N. (2014). Morphological Classification for Traffic Sign Recognition. In: *Electrical and Electronic Engineering 2014*, Vol. 4 No. 2, 2014, p. 36-44. - ISSN 2162-9455
- [35] MA, Y.; HUANG, L. (2015). Hierarchical traffic sign recognition based on multi-feature and multi-classifier fusion. In: *First International Conference on Information Science and Electronic Technology (ISET 2015)*, Wuhan, China on March 2015, p. 56-59 - ISBN 978-94-62520-50-9
- [36] BAGGIO, D. L.; EMAMI, S.; ESCRIVÁ, D.M.; IEVGEN, K.; MAHMOOD, N.; SARAGIH, J.; SHILKROT, R. (2012). Mastering OpenCV with Practical Computer Vision Projects. Packt Publishing Ltd., Birmingham, UK, December 2012 - ISBN 978-1-84951-782-9
- [37] BRADSKI, G.; KAEHLER, A. (2008) Learning OpenCV, O'Reilly Media, Inc., Sebastopol, CA, September 2008 - ISBN: 978-0-596-51613-0
- [38] HOWSE, J. (2013). OpenCV Computer Vision with Python. Packt Publishing Ltd., Birmingham, UK, April 2013 - ISBN 978-1-78216-392-3
- [39] LAGANIÈRE, R. (2011). OpenCV 2 Computer Vision Application Programming Cookbook. Packt Publishing Ltd., Birmingham, UK, May 2011 - ISBN 978-1-849513-24-1
- [40] MORDVINTSEV, A.; K, A. (2017). OpenCV-Python Tutorials Documentation, Release 1, February 28, 2017. [online] [cit. 2018-02-15] Dostupné na internete: <<https://media.readthedocs.org/pdf/opencv-python-tutroals/latest/opencv-python-tutroals.pdf>>
- [41] OOSTENDORP, N.; OLIVER, A.; SCOTT, K. (2012). Practical Computer Vision with SimpleCV. O'Reilly Media, Inc., Sebastopol, CA, August 2012 - ISBN: 978-1-449-32036-2
- [42] BAHLMANN, C.; ZHU, Y.; RAMESH, V. (2005). A System for Traffic Sign Detection, Tracking, and Recognition Using Color, Shape, and Motion Information. In: *Intelligent Vehicles Symposium Proceedings*, June 2005, Las Vegas, USA - ISBN 0-7803-8961-1
- [43] LAGUNA, R.; BARRIENTOS, R.; BLÁZQUEZ, L. F.; MIGUEL, L. J. (2014). Traffic sign recognition application based on image processing techniques. In: *19th IFAC World Congress*, Cape Town, South Africa. August 24-29, 2014, p. 104-109 - ISBN 9781634394567

- [44] SOLUS, D.; OVSEŇÍK, L. (2017). The Vertical Traffic Signs Detection in Different Light Conditions. In: *Journal of Modern Technology & Engineering*. Vol.2, No.2, 2017, p. 167-175 - ISSN 2519-4836
- [45] YAKIMOV, P., FURSOV, V. (2015). Traffic Signs Detection and Tracking using Modified Hough Transform. In: *Proceedings of the 12th International Conference on Signal Processing and Multimedia Applications (SIGMAP-2015)*, p. 22-28 - ISBN: 978-989-758-118-2
- [46] CHOU, T.; CHANG, S.-Y.; VINAY, M.S.; GUO, J.-I. (2017). Triangular Road Signs Detection and Recognition Algorithm and its Embedded System Implementation. In: *Proceedings of the 2017 International Conference on Image Processing, Computer Vision, and Pattern Recognition (IPC'17)*, July 2017, Las Vegas Nevada, USA, p. 71-76 - ISBN 1-60132-464-2
- [47] ELLAHYANI, A.; EL ANSARI, M.; EL JAAFARI, I.; CHARFI, S. (2016). Traffic Sign Detection and Recognition using Features Combination and Random Forests. In: *International Journal of Advanced Computer Science and Applications*, Vol. 7, No. 1, 2016, p. 686-693 - ISSN 2156-5570
- [48] GARCÍA-GARRIDO, M. A.; OCANA M.; LLORCA, D. F.; ARROYO, E.; POZUELO, J.; GAVILÁN, M. (2012). Complete Vision-Based Traffic Sign Recognition Supported by an I2V Communication System. In: *Sensors* 2012, 12, p. 1148-1169 - ISSN 1424-8220
- [49] HATZIDIMOS, J. (2004). Automatic Traffic Sign Recognition in Digital Images. In: *Proceedings of the International Conference on Theory and Applications of Mathematics and Informatics – ICTAMI 2004*, Thessaloniki, Greece, p. 174-184
- [50] HOFERLIN, B.; ZIMMERMANN, K. (2009). Towards Reliable Traffic Sign Recognition. In: *Intelligent Vehicles Symposium*, Xi'an, China June 2009 - ISSN 1931-0587
- [51] HOSSAIN, S.; HYDER, Z. (2015). Traffic Road Sign Detection and Recognition for Automotive Vehicles. In: *International Journal of Computer Applications*, Volume 120 – No.24, June 2015, p. 10-15 - ISSN 0975 – 8887
- [52] KESER, T.; KRAMAR, G.; NOŽICA, D. (2016). Traffic Signs Shape Recognition Based on Contour Descriptor Analysis. In: *2016 International Conference on Smart Systems and Technologies (SST)*, Oct. 2016, Osijek, Croatia, p. 199-204. - ISBN 978-1-5090-3720-9
- [53] PUTHON, A.-S.; MOUTARDE, F.; NASHASHIBI, F. (2013). Recognition of Supplementary Signs for Correct Interpretation of Traffic Signs. In: *IEEE Symposium on Intelligent Vehicles (IV'2013)*, Jun 2013, Gold Coast, Australia. 2013. - ISBN 978-1-4799-0795-3
- [54] RADZAK, M. Y.; ALIAS, M. F.; AROF, S.; AHMAD, M. R.; MUNIANDY, I. (2015). Study on Traffic Sign Recognition. In: *International Journal of Research Studies in Computer Science and Engineering*, Volume 2, Issue 6, June 2015, p. 33-39 - ISSN 2349-4840
- [55] TU, K.-H.; FUH, C.-S. (2016). The Speed-Limit Sign Detection and Recognition System. In: *Computer Vision Graphics, and Image Processing* 2016, August 2016, Keelung, p. 69-76
- [56] ZABIHI, S. (2017). Detection and Recognition of Traffic Signs Inside the Attentional Visual Field of Drivers. In: *Electronic Thesis and Dissertation Repository*, The University of Western Ontario, March 2017
- [57] ESCALERA, A.; ARMINGOL, J.M.; MATA, M. (2003). Traffic sign recognition and analysis for intelligent vehicles. In: *Image and Vision Computing* 21 (2003) p. 247–258 – ISSN 0262-8856
- [58] GONZÁLEZ, Á.; GARCÍA-GARRIDO, M. Á.; LLORCA, D. F.; GAVILÁN, M.; FERNÁNDEZ, J. P.; ALCANTARILLA, P. F.; PARRA, I.; HERRANZ, F.; BERGASA, L. M.; SOTELO, M. Á.; DE TORO, P. R. (2011). Automatic Traffic Signs and Panels Inspection System Using Computer Vision. In: *IEEE Transactions on Intelligent Transportation Systems*, Vol. 12, No. 2, June 2011, p. 485-498 – ISSN 1524-9050
- [59] HIENONEN, P. (2014). Automatic Traffic Sign Inventory- and Condition Analysis. Master's Thesis, Lappeenranta University of Technology, School of Industrial Engineering and Management, Degree Program in Computer Science, September 2014
- [60] HU, Z. (2011). Intelligent Road Sign Inventory (IRSI) with Image Recognition and Attribute Computation from Video Log, Kyoto, Japan, 2011
- [61] TÓTH, Š. (2010). Rozpoznávanie a lokalizácia dopravných značiek. Diplomová práca, Fakulta riadenia a informatiky, Žilinská univerzita v Žiline, Máj 2010
- [62] AI, C. (2013). A Sensing Methodology for an Intelligent Traffic Sign Inventory and Condition Assessment Using GPS/GIS, Computer Vision and Mobile Lidar Technologies. A Ph.D. Dissertation, Georgia Institute of Technology, May 2013
- [63] BALALI, V.; RAD, A.A.; GOLPARVAR-FARD, M. (2015). Detection, classification, and mapping of U.S. traffic signs using google street view images for roadway inventory management. In: *Visualization in Engineering* 2015 3:15, SpringerOpen Journal, November 2015
- [64] BALETKA, T. (2012). Pokročilá segmentace obrazu pro 3D zobrazení. Diplomová práce, Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav radioelektroniky, Květen 2012
- [65] CAVEGN, S.; NEBIKER, S. (2012). Automated 3D Road Sign Mapping with Stereovision-based Mobile Mapping Exploiting Disparity Information from Dense Stereo Matching. In: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XXXIX-B4, 2012 XXII ISPRS Congress, August 2012, Melbourne, Australia. – p. 61-66 - ISSN 1682-1750
- [66] HARASTHY, T. (2014). Systém rozpoznávania dopravných značiek s využitím optického korelátoru. Dizertačná práca. Technická univerzita v Košiciach, Košice 2014.
- [67] KIRILLOV, A. (2009). Making a step to stereo vision January 2009. [online] [cit. 2018-02-15] Dostupné na internete: <http://www.aforgenet.com/articles/step_to_stereo_vision/>
- [68] MADEIRA, S. R.; BASTOS, L. C.; SOUSA, A. M.; SOBRAL, J. F.; SANTOS, L. P. (2005). Automatic traffic signs inventory using a mobile mapping system. In: *GIS PLANET 2005*, International Conference and Exhibition on Geographic Information
- [69] MAHAMMED, M. A.; MELHUM, A. I.; KOCHERY, F. A. (2008). Object Distance Measurement by Stereo Vision. In: *International Journal of Science and Applied Information Technology (IJSAIT)*, Vol. 2, No. 2, p. 5-8 – ISSN 2278-3083
- [70] MATHIAS, M.; TIMOFTE, R.; BENENSON, R.; VAN GOOL, L. (2013). Traffic sign recognition: how far are we from the solution? In: *The International Joint Conference on Neural Networks (IJCNN)*, p. 1–8, 2013.
- [71] MROVLJE, J.; VRANCIC, D. (2008). Distance measuring based on stereoscopic pictures. In: *9th International PhD Workshop on Systems and Control: Young Generation Viewpoint*, October 2008, Izola, Slovenia
- [72] PAR, K.; TOSUN, O. (2012). Real-time Traffic Sign Recognition with Map Fusion on Multicore/Many-core Architectures. In: *Acta Polytechnica Hungarica* Vol. 9, No. 2, 2012, p. 231-250 – ISSN 1785-8860
- [73] ŠEGVIČ, S.; BRKIĆ, K.; KALAFATIĆ, Z.; STANISAVLJEVIĆ, V.; ŠEVROVIĆ, M.; BUDIMIR, D.; DADIĆ, I. (2010). A computer vision assisted geoinformation inventory for traffic infrastructure. In: *13th International IEEE Conference on Intelligent Transportation Systems*, Funchal, Portugal, November 2010 - ISBN 978-1-4244-7659-6
- [74] SHINOHARA, Y.H.L.; SATOH, T.; TACHIBANA, K. (2016). Road Signs Detection and Recognition Utilizing Images and 3D Point Cloud Acquired by Mobile Mapping System. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLI-B1, 2016, XXIII ISPRS Congress, July 2016, Prague, Czech Republic, p. 669-673
- [75] TOTH, Š. (2011). Rozpoznávanie dopravných značiek a ich použitie v mapových aplikáciách. In: *GIS Ostrava 2011*, Ostrava, Januar 2011 - ISBN 978-80-248-2366-9

Optický korelátor v systémoch spracovania obrazu a videa

Dávid Solus

Katedra elektroniky a multimediálnych telekomunikácií,
Fakulta elektroniky a informatiky
Technická Univerzita v Košiciach
Slovenská Republika
david.solus@tuke.sk

Ľuboš Ovseník

Katedra elektroniky a multimediálnych telekomunikácií,
Fakulta elektroniky a informatiky
Technická Univerzita v Košiciach
Slovenská Republika
lubos.ovsenik@tuke.sk

Abstrakt—Tento článok je venovaný systému pre spracovania obrazu a videa pomocou optického korelátora. Hlavným cieľom je využitie najnovších poznatkov z oblasti číslicového spracovania signálov (obrazu a videa) a optickej korelácie pri návrhu inventarizačného systému zvislých dopravných značiek. Úvodné kapitoly sa venujú optickej Fourierovej transformácii a optickým korelátormi, hlavne optickému korelátoru typu Cambridge, ktorý tvorí základ navrhnutého inventarizačného systému zvislých dopravných značiek. V navrhnutom systéme sa Cambridge optický korelátor využíva na porovnávanie obrazov vo fáze rozpoznávania, kde porovnáva detegované dopravné značky s referenčnými.

Abstract—This article is devoted to the image and video processing system using an optical correlator. The main objective is the use of the latest knowledge in the field of digital signal processing (video and video) and optical correlation in the design of the vertical traffic signs inventory system. The introductory chapters deal with the optical Fourier transform and the optical correlator, especially with the Cambridge optical correlator, which forms the basis of the proposed vertical traffic signs inventory system. In the proposed system, the Cambridge optical correlator is used to compare images in the recognition phase, where it compares the detected traffic signs with the reference ones.

Kľúčové slová—Cambridge korelátor, detekcia hrán, farebný model, optická Fourierova transformácia, spracovanie obrazu

I. ÚVOD

Súčasnú modernú smart elektronickú systémy využívajú rôzne druhy signálov na prenos informácií, pre ktoré je najkritickejší proces spracovania. Do popredia sa dostáva optické spracovanie signálov, ktoré postupne nahrádza alebo je kombinované s elektronickým spracovaním signálov. Hlavnou výhodou optických systémov je rýchlosť, ktorou dokážu spracovať veľké množstvo dát, pričom využívajú svetlo nie len ako prenosové médium. Medzi optické systémy patria aj optické korelátory, ktoré využívajú optické vlastnosti

Tento článok bol vypracovaný vďaka podpore projektov Rozvoj Centra informačných a komunikačných technológií pre znalostné systémy (ITMS 26220120030) a Centrum excelentnosti integrovaného výskumu a využitia progresívnych materiálov a technológií v oblasti automobilovej elektroniky (ITMS 26220120055).

šošoviek v procese korelácie.

Na ochranu majetku a osôb sa pri vývoji technológií nikdy nezabúda. Neustále sú vyvíjané nové techniky a technológie, vďaka ktorým sa zvyšuje úroveň bezpečnosti. Jedným zo spôsobov ochrany sú aj video-dohľadové systémy. Video-dohľadové systémy sú nasadzované na miestach, kde má bezpečnosť vysokú prioritu ako banky, vládne budovy, letiská, autobusové a železničné stanice, metrá, ale aj verejné miesta ako sú námestia, rušné ulice, nákupné centrá či parkoviská. Tieto systémy „komplikuju“ páchanie trestnej činnosti, napomáhajú pri usvedčovaní páchateľov alebo slúžia na monitorovanie neočakávaných udalostí sledovaného (skúmaného) okolia.


Príbuzné systémy k video-dohľadovým systémom sú video-kontrolné systémy. Využívajú sa v rôznych výrobných procesoch, napr. kontrola kvality. Kamera je väčšinou inštalovaná pri pásovej výrobnej linke a sníma produkt. Ak systém vyhodnotí, že produkt nespĺňa špecifické parametre, tak produkt bude vyradený. Video-dohľadové aj video-kontrolné systémy využívajú kameru ako vstupné zariadenie pre mnohé techniky a technológie na spracovanie a analýzu obrazu či videa. Medzi tieto techniky a technológie patrí skenovanie, sledovanie pohybu, biometrický systém, termovízia, infračervené videnie či rôzne databázové systémy. Dôležitou časťou týchto systémov je spracovanie obrazu a videa, ktoré je potrebné pri detekcii a rozpoznávaní objektov a osôb. Práve implementácia optických korelátorov do monitorovacích systémom by zvýšila rýchlosť, presnosť, možnosť spracovávať veľké množstvo dát či porovnávať, prehľadávať dáta v databázach na základe zhody.

II. OPTICKÁ FOURIEROVA TRANSFORMÁCIA

Amplitúda svetelnej vlny vychádzajúca zo zobrazovaného predmetu sa dokáže rozložiť na jednotlivé priestorové harmonické zložky. Tieto zložky nezávisle prechádzajú cez optické zobrazovacie prvky, teda ich je možné jednotlivito spracovať, či prípadne úplne odstrániť. Jedna priestorová rovina je pridelená ku každému bodu Fourierovej roviny.


Šírenie svetelných vln je opísané optickou Fourierovou transformáciou založenou na harmonickej analýze a lineárnych systémoch. Základom harmonickej analýzy je rozvoj

Ľubovoľnej funkcie času $f(t)$, ktorá sa prekrýva s rôznymi harmonickými funkciami času v rozdielnych frekvenciách, počiatkových fázach a amplitúdach. Harmonická funkcia $F(f)exp(j2\pi ft)$ s frekvenciou f a amplitúdou $F(f)$ je základom tejto teórie. Funkcia $f(t)$ (Obr. 1) je vytvorená danými rôznymi funkciami.




Obr. 1 Rozloženie funkcie na rad harmonických funkcií

Dôležitým faktorom je skutočnosť, že aj jednoduchá šošovka je schopná vykonať Fourierovu transformáciu v reálnom čase. Obraz, ktorý je umiestnený v ohniskovej vzdialenosti šošovky, osvetlíme laserovým lúčom (koherentné svetlo). V ohnisku druhej šošovky je umiestnené nepriehľadné sklo. Na vstupnom obraze je vykonaná automaticky Fourierova transformácia a výstup je zobrazený na nepriehľadnom skle. V prípade umiestnenia sínusovej mriežky na vstup (Obr. 2), bude na výstupe znázornená škrvna spolu s dvoma sprievodnými bodmi po oboch stranách. Daná škrvna reprezentuje DC (DirectCurrent) zložku a vzdialenosť sprievodných bodov od stredu je závislosť frekvencie.



Obr. 2 Optická Fourierova transformácia

Princíp optickej Fourierovej transformácie znázorňuje Obr. 3. Dôsledkom umiestnenia obrazu v ohnisku šošovky sa každým bodom na vstupe šíria kužeľovité lúče. Dané lúče sa lámu a vytvárajú paralelný lúč, pričom osvetľujú obraz na nepriehľadnom skle. Fourierovým obrazom sa rovnomerne šíria jednotlivé body vstupného obrazu, a tým sa vytvára správne Fourierovo zobrazenie (Obr. 3(a)). V opačnom prípade sa paralelné lúče z celého vstupného obrazu sústreďujú do jedného centrálného bodu Fourierovho obrazu. Daný bod definuje centrálnu DC zložku s priemerným jasom vstupného obrazu. Zmenou znamienka mínus sa obracia smer výpočtu a dostávame inverznú optickú Fourierovu transformáciu (Obr. 3(b)). Pomocou inverznej Fourierovej transformácie sa konvertuje Fourierovo zobrazenie späť do pôvodného priestorového jasového obrazu [1][2][3].




Obr. 3 Priama (a) a spätná (b) Fourierova transformácia

III. OPTICKÝ KORELÁTOR

Optický korelátor je zariadenie, ktoré využíva Fourierove transformačné vlastnosti šošoviek na porovnávanie dvoch alebo viacerých signálov. Využíva sa hlavne na sledovanie a identifikáciu objektov. Identifikuje a rozpoznáva obsah vstupného obrazu vzhľadom na referenčný obraz, pričom miera podobnosti je určená veľkosťou intenzity zväzku svetelných lúčov. Rýchlosť rozpoznávania optického korelátora je podstatne vyššia ako pri iných softvérom riadených elektronických systémoch. Dostupné korelátory dosahujú podobné výsledné hodnoty aj keď ich spôsob spracovania je veľmi odlišný. Práve podľa spôsobu spracovania informácií môžeme dané korelátory rozdeliť do dvoch skupín: korelátor využívajúci prispôbený filter – Matched Filter (MF) a korelátor využívajúci spojitú transformáciu – JointTransformCorrelator (JTC) [4][5].

A. Korelátor využívajúci prispôbený filter


Základom korelátora využívajúci prispôbený filter je dvoj-šošovkový zobrazovací 4-f systém, pričom využíva Van der Lugtov filter. MF korelátor patrí medzi najrozšírenejší typ korelátorov, avšak jeho konštrukcia je veľmi citlivá vzhľadom na umiestnenie šošoviek. Obr. 4 znázorňuje princíp MF korelátora. Proces korelácie je tvorený dvoma nezávislými Fourierovými transformáciami vstupného a referenčného obrazu. V obrazovej rovine prvej šošovky sa vykonáva prvá Fourierova transformácia vstupného obrazu, ktorý je znázornený na priestorovom modulátore svetla (SpatialLightModulator - SLM). Do obrazovej roviny prvej šošovky je vložený aj komplexne združený Fourierov transformovaný obraz referenčnej roviny. Daný obraz je vynásobený transformovaným obrazom vstupnej roviny. Pomocou Fourierovej transformácie sa elektronicky transformuje referenčný obraz a na SLM sa zobrazí referenčná rovina. Pomocou druhej šošovky sa realizuje druhá Fourierova transformácia, a to transformácia súčinu transformovaných obrazov vstupnej a referenčnej roviny. Výstupom transformácie je výstupná rovina reprezentujúca vzájomnú koreláciu vstupnej a referenčnej roviny. Vysoká priestorová šírka pásma a krátky čas spracovania informácií patria medzi hlavné výhody daného systému [4][6][7].



Obr. 4MF korelátor

B. Korelátor využívajúci spojitú transformáciu


Architektúra JTC korelátoru je znázornená na Obr. 5. Ide o koherentný optický systém, ktorého vstupná rovina je tvorená referenčným a vstupným obrazom, pričom sú umiestnené a zobrazené vedľa seba. Ďalej je umiestnená prvá transformačná šošovka a v jej ohniskovej vzdialenosti je umiestnený polohovo citlivý detektor intenzity. Koherentné svetlo osvetľuje vstupnú rovinu, ktorá je pomocou prvej šošovky transformovaná Fourierovou transformáciou. Detektor zosníma veľkosť intenzity a Fourierovou transformáciou sa vytvorí spojitý výkonové spektrum (JointPowerSpectrum - JPS) vstupnej roviny. Dané JPS sa zobrazí vo Fourierovej rovine detektora intenzity, ktoré sa nelineárnou bodovou transformáciou preniesie na Fourierovu rovinu SLM. Na realizáciu transformácie je najvhodnejšie opticky adresovateľný priestorový modulátor svetla. Za Fourierovou rovinou sa nachádza druhá šošovka. V jej zadnej ohniskovej vzdialenosti je umiestnený elektronicky čitateľný polohový detektor intenzity. Tým, ako koherentné svetlo osvetľuje Fourierovu rovinu na SLM, získavame žiarenie na výstupnej korelačnej rovine. Veľkosť a poloha intenzity špičky vyjadruje vzájomnú podobnosť a polohu obrazov na vstupnej rovine [4][8][9].



Obr. 5JTC korelátor

C. Cambridge optický korelátor


Cambridge optický korelátor (Obr. 6) patrí medzi korelátor, ktoré využívajú pri procese spracovania informácie spojenú transformáciu. Je vyvinutý súkromne financovanou spoločnosťou CambridgeCorrelators (CC), ktorá spolupracuje s technickým oddelením Cambridge Univerzity vo Veľkej Británii. Je to partnerstvo medzi univerzitou, súkromnými spoločnosťami a firmou PhotonicsConsultancy. Jedinečná, kompaktná a veľmi výkonná súprava FourierTransformEngine © na spracovanie dát tvorí základ CC korelátoru. Daná súprava je postavená na difrakčných princípoch OFT a špeciálnom usporiadaní optoelektronických súčastí pripomínajúc písmeno „W“. Vďaka tomuto usporiadaniu sa optimalizuje čas na spracovanie a zároveň sa minimalizuje vzdialenosť prenášaných elektrických signálov.



Obr. 6 Cambridge optický korelátor

1) *Princíp činnosti*: Do optického systému sú vložené obrazové dáta, ktoré sú počas korelácie porovnávané, pričom sa sleduje veľkosť podobnosti a ich vzájomná poloha. Porovnávanie sa zväčša realizuje medzi referenčným obrazom, ktorý je uložený v databáze, a vstupným obrazom zachyteným externou kamerou. Počas korelácie je možné porovnávať viacero obrazov súčasne bez akéhokoľvek zvýšenia zaťaženia systému, avšak je tu obmedzenie na rozlíšenie vstupných obrazov.

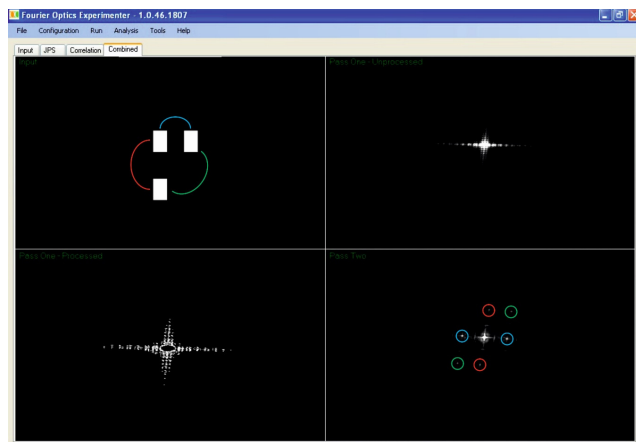
Optický výstup (Obr. 7) je tvorený z vysoko lokalizovanej korelačnej funkcie alebo špičky. Veľkosť korelačnej špičky reprezentuje mieru podobnosti medzi vstupným a referenčným obrazom. Mieru podobnosti znázorňuje intenzita I , kým pozícia $[x, y]$ vyjadruje vzájomnú polohu porovnávaných obrazov na výstupnej rovine.



Obr. 7 Princíp činnosti CC

2) *Softvérové vybavenie*: Softvér „Fourier Optic Experimenter.exe“, dodávaný spolu s CC korelátorom, bol vyvíjaný pre operačný systém Windows. Demonštračný softvér je možné spustiť v dvoch režimoch, a to režim optickej Fourierovej transformácie alebo v režime JTC v jednoduchom grafickom rozhraní. V režime OFT máme k dispozícii dve okná, kde prvé okno reprezentuje vstup a druhé Fourierovu transformáciu vstupu. Pri režime JTC pracujeme s tromi oknami, ktoré reprezentujú vstup, JPS a výslednú koreláciu.

Daný režim poskytuje aj zobrazenie všetkých troch okien v jednom samostatnom okne nazývanom „Combined“. Vstupná rovina je tvorená viacerými blokmi, do ktorých je možné nahráť obrázky, videá alebo prenesené údaje z USB kamery. Do jedného bloku je možné nahráť viacero súborov, čím dostaneme sekvenčnú koreláciu obrazov alebo ich Fourierovu transformáciu. K dispozícii je viacero nastavení vstupných obrazov, ako spôsob ich spracovania či definovanie konkrétnej oblasti obrazu pre analýzu. Taktiež je možné upraviť niektoré parametre kamery, ako napríklad „Shutter Time“ – nastavenie množstva svetla zachyteného senzom. „Noise Offset“ slúži na elimináciu šumových vzoriek zo senzora, „Analog Gain (dB)“ pre nastavenie zisku a „Delay“ pre nastavenie veľkosti oneskorenia v milisekundách na zvýšenie stability obrazu.



Obr. 8 Okno „Combined“ pri režime JTC

Obr. 8 znázorňuje kombinované okno režimu JTC. Vstupná rovina je tvorená troma zhodnými obrazmi. Proces korelácie sa vykonáva medzi každou dvojicou obrazov, preto aj na výstupnej rovine je tvorená troma párami korelačných špičiek. Poloha jednotlivých korelačných špičiek súhlasí s polohou vstupných obrazov [4][10].

IV. NÁVRH SYSTÉMU NA SPRACOVANIE OBRAZU A VIDEA POMOCOU OPTICKÉHO KORELÁTORA

Vizuálna detekcia a rozpoznávanie objektov patrí v poslednom desaťročí medzi najväčšie výzvy počítačového videnia. Potenciálne uplatnenie systémov detekcie a rozpoznávania objektov je veľmi široké, od bezpečnostných systémov (napr. identifikácia oprávnených osôb), cez medicínske techniky (napr. detekcia tumorov), priemyselné aplikácie (napr. vizuálna inšpekcia výrobkov), robotiku (napr. navigácia robota v nedostupnom teréne) až po rozšírenú realitu a mnohé ďalšie. Každý systém vizuálneho rozpoznávania objektov musí byť najskôr naučený na úlohu, pre ktorú je určený. Definovanie rozhodovacej úlohy pomocou súboru deterministických podmienok sa používa skôr zriedkavo. Príkladom môžu byť niektoré systémy priemyselnej inšpekcie,

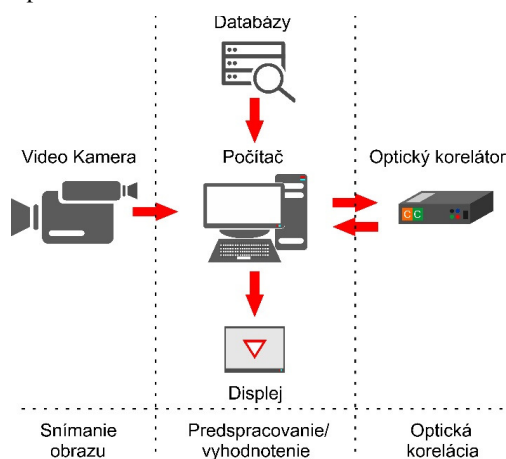
kde v reprodukovateľných podmienkach systém vyhodnotí namerané veličiny, napr. rozmery objektu.

V procese rozpoznávania bude implementovaný optický systém - optický korelátor. Optický korelátor dokáže porovnávať obrázky pomocou optickej korelácie, ktorá je vykonávaná rýchlosťou svetla a tým môžu byť spracovávané enormné množstvo dát za veľmi krátky časový okamih. Vstupné dáta, ktoré prichádzajú na vstup optického korelátora, musia byť náležite upravené. Proces spracovania či predspracovania je teda veľmi dôležitou časťou systému [12][13][14].

A. Hardvérový návrh inventarizačného systému zvislých dopravných značiek

Hlavnou časťou systému inventarizačného systému zvislých dopravných značiek (VTSIS - VerticalTrafficSignsInventorySystem) bude Cambridge optický korelátor, ktorý sa bude podieľať na procese rozpoznávania objektov v obraze. Základný hardvérový návrh systému VTSIS je znázornený na Obr. 9 spolu s popisom základných hardvérových komponentov. Tieto komponenty môžeme rozdeliť podľa využitia na tri základné skupiny:

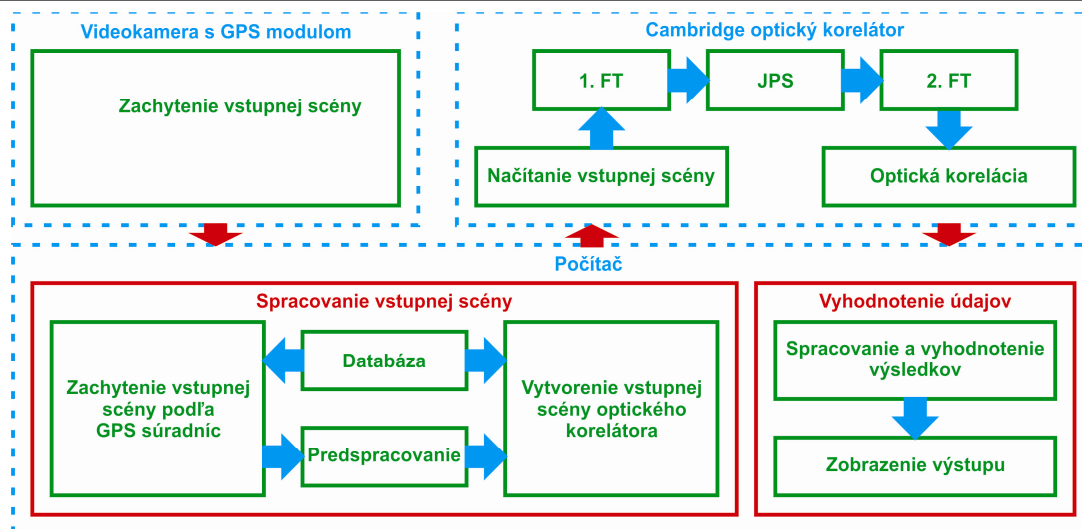
- snímanie obrazu,
- predspracovanie obrazu a vyhodnotenie optickej korelácie,
- optická korelácia.



Obr. 9 Hardvérový návrh systému VTSIS

B. Bloková schéma inventarizačného systému zvislých dopravných značiek

Úlohou navrhnutého systému VTSIS je detekcia dopravnej značky zo vstupnej scény na základe GPS súradníc (GlobalPositioningSystem) a jej následné porovnanie s experimentálnou databázou referenčných dopravných značiek. Blokovaná schéma daného systému je znázornená na Obr. 10.



Obr. 10 Hardvérový návrh systému VTSIS

1) *Videokamera s GPS modulom*: Dopravné značenie je umiestnené na presne stanovenej pozícii, teda ako vstupné zariadenie navrhnutého systému bola zvolená videokamera s GPS modulom. Daný modul nám umožnil získať informácie o polohe jednotlivých dopravných značiek. V našom prípade na zachytenie LS460W (Obr. 11) s danými technickými špecifikáciami [11]:

- Rozlíšenie: Full HD
- Veľkosť videa: 1920x1080 pri 30fps
- Formát videa: .MOV
- Veľkosť LCD: 2,7"
- Objektív: 140° Výstup: HDMI
- Citlivosť: ISO 3200
- Pamäťová karta: Micro SD do 32 GB
- Ďalšie funkcie: GPS, G-senzor, detekcia pohybu



Obr. 11 Autokamera DOD LS460W a jej komponenty

Videokamera bola pripevnená na čelné sklo motorového vozidla tak, aby snímala scénu pred sebou (vozovka). Daná videokamera patrí k prvotriednym autokamerám určeným na snímanie a zachytávanie bezpečnostných záznamov jazdy vodiča. Súčasťou balenia je aj aplikácia (Obr. 12), ktorá umožňuje prehrávať a editovať zachytený videozáznam a poskytuje informácie ako GPS súradnice, rýchlosť vozidla,

záznam G senzora, dátum a čas. Dôležitou funkciou je možnosť generovania .txt súboru, ktorý obsahuje jednotlivé GPS súradnice.




Obr. 12 Aplikácia autokamery DOD LS460W

2) *Spracovanie vstupnej scény*: Funkčný blok *Spracovanie vstupnej scény* pozostáva zo štyroch blokov. Prvým blokom je *Databáza* obsahujúca referenčné obrazy (dopravné značenie) spolu s prislúchajúcimi údajmi o ich polohe (GPS súradnice). Nasledujúcim blokom je *Zachytenie vstupnej scény podľa GPS súradníc*. Ako bolo spomenuté, vstupným zariadením je autokamera obsahujúca GPS modul, ktorá dokáže generovať .txt súbor s GPS súradnicami. *Databáza* je prehľadávaná a hľadá sa zhoda medzi vygenerovanými a jednotlivými GPS súradnicami referenčných obrazov. Ak nastane zhoda, vstupná scéna sa zachytí štyrikrát v závislosti od nastaveného časového intervalu, tým sa získajú štyri snímky, ktoré prejdú blokom *Predspracovania*. Rozlíšenie vstupnej scény je 1366x786 pixelov, pričom do bloku predspracovania je poslaný len výrez z ľavej časti snímky o veľkosti 550x550 pixelov (Obr. 13). Referenčný obraz je odoslaný do bloku – *Vytvorenie vstupnej scény optického korelátora*.



Obr. 13 Zachytená scéna – 4 snímky

Najdôležitejším blokom je blok *Spracovanie*, ktorého úlohou je predspracovanie (úprava) vstupnej scény tak, aby bolo čo najjednoduchšie získať potrebné informácie – ROI (Region of Interest – oblasť záujmu). Proces spracovania VTSIS pozostáva zo siedmich podblokov a jeho bloková schéma je znázornená na Obr. 14.



Obr. 14 Bloková schéma predspracovania systému VTSIS

a) *Gama korekcia*: Prvým podblokom v procese spracovania je *Gama korekcia*. Jeho úlohou je úprava niektorých vlastností zachytenej snímky a to: saturácia a jas. Knižnica AForge.NET obsahuje niekoľko dopredu definovaných filtrov, ktorých hodnoty sa dajú meniť v určitom rozmedzí. Rozsah filtra pre saturáciu sa dá meniť v rozsahu [-1;1], pričom hodnota 0.1 zodpovedá 10%. Rozsah pre jas je v rozmedzí [-255; 255]. Hodnoty pre nastavenie jednotlivých filtrov sa získali experimentálne pri testovaní jednotlivých vstupných scén zachytených v rôznom časovom období a pri rôznych svetelných podmienkach: saturácia – 0.15, jas - 100.

b) *Farebná filtrácia*: Úlohou *Farebnej filtrácie*, ako už vyplýva z názvu, je proces odfiltrovania obrazových prvkov, ktoré nepatria do rovnakého rozsahu farieb daného filtra. Farby používané pre dopravné značenie sú zvolené tak, aby bolo ľahko rozpoznateľné zo strany vodiča. Dopravné značenie sa vyznačujú hlavne červenou, modrou a žltou farbou, teda farebná filtrácia je založená na základe týchto farieb. Jednotlivé farebné filtre sú založené na základe HSL farebného modelu. Vytvorené farebné filtre sú postupne aplikované na upravené snímky. Hodnoty jednotlivých parametrov farebného modelu (H - farebný odtieň, S - saturácia alebo tiež sýtosť farby, L - svetlosť) sú znázornené v Tab. 1 a boli získané experimentálnym spôsobom. Ukážka farebnej filtrácie podľa jednotlivých farebných filtrov je znázornená na Obr. 15.

Tab. 1 Použité Hodnoty Jednotlivých Filtrov

Filter HSL	H[0°; 360°]	S[0; 1]	L[0; 1]
Červený	[325; 18]	[0.1; 1]	[0; 0.85]
Modrý	[215; 265]	[0.1; 1]	[0.2; 0.75]
Žltý	[30; 80]	[0.2; 1]	[0.2; 0.5]



Obr. 15 Aplikácia jednotlivých farebných filtrov

c) *Transformácia do odtieňov sivej a prahovanie*: Ďalším krokom je transformácia obrazov pozostávajúcich len čiernej farby a farby jednotlivých farebných filtrov do odtieňov sivej. Takto transformovaný obraz obsahuje len informácie o jase, informácie o farbách neobsahuje. Najjednoduchšou metódou segmentácie je konvertovanie obrazu transformovaného do odtieňov sivej na binárny obraz pomocou procesu prahovania. Biele obrazové body reprezentujú body obrazu, ktorých hodnota je v rámci prahovacej hodnoty a čierne obrazové body reprezentujú hodnoty mimo prahovacej hodnoty.

d) *Vyplnenie objektov a dilatácia*: V nasledujúcom kroku sa aplikuje filter na vyplnenie zostávajúcich objektov bielou farbou a morfológická operácia – dilatácia, ktorá umožňuje objektom expandovať cez vyplňanie malých otvorov a spájanie disjunktných objektov.

e) *Odstránenie zhlukov*: Jednotlivé snímky obsahujú okrem samotného dopravného značenia aj iné malé objekty, ktoré prešli jednotlivými farebnými filtrami. Úlohou daného podbloku je práve odstránenie týchto neželaných objektov, ktoré sú príliš malé alebo veľmi veľké. Sú definované minimálne a maximálne rozmery objektov, ktoré nie sú filtrom odstránené. Rozmery sú definované v rozmedzí od 40x40 do 160x160 pixelov.

f) *Detekcia tvarov*: Dopravné značenie je navrhnuté tak, aby sa dalo odlíšiť od prírodného alebo zastaveného prostredia. Sú charakterizované mnohými vlastnosťami, ktoré ich robia rozpoznateľnými. Sú navrhnuté v štandardných geometrických tvarov ako je trojuholník, kruh, štvorec a osemuholník, preto sa v danom kroku aplikuje algoritmus na hľadanie týchto známych tvarov. Jednotlivé geometrické tvary sú navzájom farebne rozlíšené.

g) *Nájdenie a extrakcia ROI*: Úlohou posledného podbloku je nájdenie ROI, teda oblasť, kde by sa potencionálne mala nachádzať dopravná značka a jeho následná extrakcia. Predtým sú však aplikované farebné filtre na nájdenie a odlíšenie jednotlivých geometrických tvarov. V prvej časti – nájdenie ROI, algoritmus ohraničí najväčší objekt na spracovanej scéne. Druhou časťou je následná extrakcia


ROI. Jej úlohou je vyextrahovať ROI zo snímky (výstupu) z podbloku *Gama korekcia* na základe súradníc ohraničenia.

Úlohou bloku *Vytvorenie vstupnej scény optického korelátora* je vytvorenie vstupnej scény, ktorá pozostáva s referenčnej snímky (dopravné značenie) uloženej v databáze a výstupu z bloku *Predspracovanie*. Výstup bloku *Predspracovanie* zodpovedá ROI, teda oblasť kde by sa malo nachádzať dopravné značenie. Na základe GPS súradníc sú na vstupe zachytené štyri snímky, ktoré prejdú blokom spracovania, teda sú získané štyri k nim prislúchajúce ROI. Rozhodujúcim kritériom pre výber výsledného ROI sú rozmery, rozmerovo najväčší ROI zodpovedá vstupnej snímke. Vytvorená vstupná scéna je následne odoslaná na vstup CC.

3) *Vyhodnotenie údajov*: Funkčný blok *Vyhodnotenie údajov* pozostáva z dvoch blokov. Prvým je *Spracovanie a vyhodnotenie výsledkov*, ktorý spracováva údaje optickej korelácie ako je intenzita korelačných špičiek. Zo získaných hodnôt intenzít korelačných špičiek sa určí percentuálna zhoda porovnávaných snímok (získané ROI a prislúchajúca referenčná snímka). Pomocou vopred stanovenej prahovej hodnoty sa určí, či sú porovnávané obrazy zhodné. Druhým blokom je *Zobrazenie výstupu*, ktorého výsledná reakcia je v jednotlivých podsystemoch odlišná v závislosti od zamerania systému. V systéme VTSIS je výslednou reakciou zobrazenie referenčnej dopravnej značky na výstupnom displeji, ktorej zhoda prekročila stanovenú prahovú hodnotu [12][15][16][17][18][19][20][21][22].

V. EXPERIMENTÁLNE OVERENIE NAVRHNUTÉHO INVERIZAČNÉHO SYSTÉMU ZVISLÝCH DOPRAVNÝCH ZNAČIEK

Úlohou navrhnutého systému VTSIS je detekcia dopravnej značky zo vstupnej scény na základe GPS súradníc a jej následné porovnanie s experimentálnou databázou referenčných dopravných značiek. Na experimentálne overenie daného systému boli použité tri videozáznamy získané pomocou kamery do auta, a to DOD LS460W. Jednotlivé videozáznamy (Video_1, Video_2 a Video_3) boli získané v rôznom časovom období, pri rôznych svetelných podmienkach, zaznamenávajú rôzne dopravné úseky a sú rôznej dĺžky (Obr. 16). K nim prislúchajú aj jednotlivé .txt súbory, ktoré obsahujú GPS súradnice a databázy referenčných dopravných značiek. Jednotlivé videozáznamy boli analyzované vytvoreným programom, a tým boli získané tri sady ROI, ktoré reprezentujú oblasť, kde by sa mala potencióálne nachádzať dopravná značka. Na základe GPS súradníc boli jednotlivé ROI porovnávané pomocou CC s prislúchajúcimi referenčnými dopravnými značkami, ktoré sú uložené v databáze. Výsledné hodnoty intenzít a percentuálne zhody porovnávaných obrazov sú zobrazené v jednotlivých tabuľkách.



Obr. 16 Ukážka jednotlivých videozáznamov

Po analyzovaní videozáznamu Video_1, systém na základe GPS súradníc detegoval a vyextrahoval 32 ROI predstavujúcich oblasť, kde by sa mala potencióálne nachádzať dopravná značka. Prislúchajúca databáza referenčných značiek obsahuje 33 záznamov, teda úspešnosť detegovania ROI na základe GPS súradníc je 96,97%. Na Obr. 17 je znárodnená vstupná rovina optického korelátora a prislúchajúci optický výstup. ROI na vstupnej scéne prislúcha trinásť pozícií v referenčnej databáze.



Obr. 17 Vstupná rovina a optický výstup (Video_1)

Výsledné hodnoty intenzít ROI a referenčnej dopravnej značky sa vypočítajú ako priemerná hodnota všetkých nameraných hodnôt intenzít (rovnicu 3). Výsledná percentuálna hodnota zhody porovnávaných obrazov sa vypočíta pomocou rovnice 1.

$$Zhoda_i(\%) = \frac{\bar{I}_i}{255} \cdot 100, \tag{1}$$

$$\bar{I}_i = \frac{I_1 + I_2}{2}, \tag{2}$$

$$\bar{I}_N = \frac{\sum_{n=1}^{100} I_n}{100}, \tag{3}$$

kde index *i* predstavuje pozíciu detegovaného ROI a index *N*, ktorý môže nadobúdať hodnoty 1 a 2, určuje či ide o intenzitu *I*₁ alebo *I*₂. Tab. 2 obsahuje výsledné hodnoty intenzít a percentuálne zhody porovnávaných obrazov (detegované ROI z videozáznamu Video_1 a prislúšné referenčné obrazy).

Tab. 2 Výsledné hodnoty - Video_1

Poradie záznamu	Výsledná hodnota intenzity	Percentuálna zhoda	Poradie záznamu	Výsledná hodnota intenzity	Percentuálna zhoda
-----------------	----------------------------	--------------------	-----------------	----------------------------	--------------------

	<0; 255>	(%)		<0; 255>	(%)
1.	241,5	94,71	23.	178,5	70,00
2.	218,5	85,69	24.	206	80,78
3.	241	94,51	25.	241,5	94,71
4.	240	94,12	26.	238,5	93,53
5.	225,5	88,43	27.	0	0,00
6.	206	80,78	28.	234	91,76
Poradie záznamu	Výsledná hodnota intenzity <0; 255>	Percentuálna zhoda (%)	Poradie záznamu	Výsledná hodnota intenzity <0; 255>	Percentuálna zhoda (%)
7.	229	89,80	29.	130,5	51,18
8.	201	78,82	30.	176	69,02
9.	216	84,71	31.	226	88,63
10.	197	77,25	32.	237	92,94
...	33.	248	97,25
Priemerná hodnota intenzity <0;255>					216,4
Priemerná percentuálna zhoda (%)					84,86

Výsledná priemerná hodnota intenzity všetkých detegovaných ROI z videozáznamu Video_1 je na úrovni 216,4, čo predstavuje 84,86%. Ak percentuálna zhoda medzi detegovaným ROI a príslušnou referenčnou značkou presiahne nastavenú prahovú hodnotu, systém bude dané obrazy považovať za totožné a zobrazí referenčnú dopravnú značku. V prípade, ak prahová hodnota je nastavená na 90%, z celkového počtu 33 detegovaných ROI, by bolo za dopravnú značku považovaných 19 (57,58%). Pri hodnote 80% by to bolo 26 (78,79%) a pri hodnote rovnej priemernej percentuálnej zhode (84,86%) by to bolo 23(69,7%).Jednotlivé údaje sú zobrazené v Tab. 5. spolu s jednotlivými prahovými hodnotami.

Tab. 3 Štatistické hodnoty – Video_1

Prahová hodnota	90		80		84,86	
Úspešne rozpoznané ROI	Počet	%	Počet	%	Počet	%
		19	57,58	26	78,79	23

Druhým analyzovaným videozáznamom bol videozáznam Video_2. Systém na základe GPS súradníc detegoval a vyextrahoval 31 ROI predstavujúcich oblasť, kde by sa mala potencionálne nachádzať dopravná značka. Príslúchajúca databáza referenčných značiek obsahuje 34 záznamov, teda úspešnosť detegovania ROI na základe GPS súradníc je 91,18%.Výsledná priemerná hodnota intenzity všetkých detegovaných ROI z videozáznamu Video_2 je na úrovni 214,88, čo predstavuje 84,27%. V prípade, ak prahová hodnota je nastavená na 90%, z celkového počtu 34 detegovaných ROI, by bolo za dopravnú značku považovaných 25 (73,53%). Pri hodnote 80% by to bolo 29 (85,27%) a pri hodnote rovnej priemernej percentuálnej zhode (84,27%) by to bolo 28 (82,35%). Jednotlivé údaje sú zobrazené v Tab. 4.

Tab. 4 Štatistické hodnoty – Video_2

Prahová hodnota	90		80		84,27	
Úspešne rozpoznané	Počet	%	Počet	%	Počet	%

ROI	25	73,53	29	85,27	28	82,35
-----	----	-------	----	-------	----	-------

Videozáznam Video_3 bol posledným analyzovaným videozáznamom. V tomto prípade systém detegoval a vyextrahoval 54 ROI predstavujúcich oblasť, kde by sa mala potencionálne nachádzať dopravná značka. Príslúchajúca databáza referenčných značiek obsahuje 56 záznamov, teda úspešnosť detegovania ROI na základe GPS súradníc je 96,43%.Výsledná priemerná hodnota intenzity všetkých detegovaných ROI z videozáznamu Video_3 je na úrovni 225,46, čo predstavuje 88,42%. V prípade, ak prahová hodnota je nastavená na 90%, z celkového počtu 56 detegovaných ROI, by bolo za dopravnú značku považovaných 41 (73,21%). Pri hodnote 80% by to bolo 50 (89,29%) a pri hodnote rovnej priemernej percentuálnej zhode (88,42%) by to bolo 47 (82,93%). Jednotlivé údaje sú zobrazené v Tab. 5.

Tab. 5 Štatistické hodnoty – Video_3

Prahová hodnota	90		80		84,86	
Úspešne rozpoznané ROI	Počet	%	Počet	%	Počet	%
		19	57,58	26	78,79	23

Jednotlivé videozáznamy (Video_1, Video_2 a Video_3), ktoré boli získané v rôznom časovom období, pri rôznych svetelných podmienkach, zaznamenávajú rôzne dopravné úseky a sú rôznej dĺžky, boli analyzované vytvoreným programom. Úspešnosť detegovania a vyextrahovania ROI v pri jednotlivých videách je na vysokej úrovni. Ak percentuálna zhoda medzi detegovaným ROI a príslušnou referenčnou značkou presiahne nastavenú prahovú hodnotu, systém dané obrazy považoval za totožné a zobrazil referenčnú dopravnú značku. Uvažovali sme tri prahové hodnoty, a to: 90%, 80% a hodnotu rovnej priemernej percentuálnej zhode jednotlivých videozáznamov. Úspešnosť rozpoznania pri jednotlivých prahových hodnotách je pri jednotlivých videozáznamoch na rovnakej úrovni. Celkový prehľad analýzy je znázornený v Tab. 6.

Tab. 6 Celkový prehľad analýzy

Videozáznam	Celkový počet záznamov	Počet detegovaných ROI	Úspešnosť detekcie (%)	Prahová hodnota (%)	Úspešne rozpoznané ROI	
					Počet	%
Video_1	33	32	96,97	90	19	57,58
				80	26	78,79
				84,86	23	69,7
Video_2	34	31	91,18	90	25	73,53
				80	29	85,29
				84,27	28	82,35
Video_3	56	54	96,43	90	41	73,21
				80	50	89,29
				82,93	47	82,93
Priemerná úspešnosť detekcie (%)					94,86	
Priemerná úspešnosť rozpoznávania pri prahovej hodnote 80 (%)					84,46	

Okrem svetelných podmienok mala na detekciu vplyv aj kvalita zachytanej scény, ktorá závisí od rozlíšenia použitej

kamery. Taktiež aj povrch samotných dopravných značiek mohol byť znečistený, obsah nečitateľný a ich tvar zdeformovaný, čo malo taktiež veľký vplyv na detekciu ROI zo vstupnej scény. Systém VTSIS možno využiť ako kontrolný (inventarizačný) systém, ktorý sleduje cestnú komunikáciu a kvalitu dopravného značenia.

VI. ZÁVER

Spojenie optických vlastností šošoviek a elektroniky dokáže urýchliť proces spracovania informácií, čo je v dnešnej dobe považované za veľmi dôležité. Využitie optických korelátorov v systémoch spracovania obrazu a videa má veľký potenciál v rôznych odvetviach.

Inventarizačný systém zvislých dopravných značiek (VTSIS) slúži na detekciu dopravnej značky zo vstupnej scény na základe GPS súradníc. Na experimentálne overenie daného systému boli použité tri videozáznamy (Video_1, Video_2 a Video_3), ktoré boli získané v rôznom časovom období, pri rôznych svetelných podmienkach, zaznamenávajú rôzne dopravné úseky a sú rôznej dĺžky. Úspešnosť detekcie ROI presahuje 91% a najvyššia úspešnosť správne rozpoznávaných ROI je pri prahovej hodnote 80%. Celkový počet experimentov vykonaných pri danom podsystéme bol 11700.

M. Schneier [12] navrhol detekčný systém dopravných značiek, ktorý využíva farebnú filtráciu, tvarovú detekciu a predpoklad výskytu dopravnej značky na snímanej scéne. Detekcia je založená na porovnávaní ROI s referenčnými vzorkami uloženými v databáze a sledovaním sekvencií snímok. M. TahaKhan [23] vo svojom systéme vytvoril nový grafický filter v HSV farebnom modeli (segmentácia, hľadanie homogénnych oblastí, označovanie...). Rozpoznávanie dopravných značiek zahŕňa prispôbenie tvaru ROI k referenčnej vzorke. J. Miura a spol. [24] vytvoril systém využívajúci dvojicu kamier. Prvá, so širokým objektívom, sa používa na detekciu ROI pomocou farby, jasu a tvaru. Druhá, vybavená teleobjektívom, sa zameriava na získanie kvalitnejšieho predikovaného ROI. K. Dyczkowski a spol. [25] vytvoril systém, ktorý na detekciu dopravných značiek využíva znalostnú databázu a detekcia sa vykonáva vo farebnom priestore HSV pomocou fuzzy segmentácie farieb. Rozpoznávanie zahŕňa porovnávanie ROI s referenčnými vzorkami. Tab. 7 obsahuje detailné porovnanie jednotlivých systémov.

Tab. 7 Porovnanie systémov

Systém	Detekcia (%)	Rozpoznávanie (%)
<i>M. Schneier</i>	88	78
<i>M. TahaKhan a spol.</i>	-	95
<i>J. Miura a spol.</i>	97	42
<i>K. Dyczkowski a spol.</i>	83	84,4
<i>Náš systém</i>	94,86	84,46

Pre rozpoznávanie získaných objektov zo skúmaného obrazu či videa, má z nášho pohľadu veľký význam uvažovať použitie optického korelátora, ktorý dokáže porovnávať skúmané obrazy rýchlosťou svetla.

LITERATÚRA

- [1] B. E. A. Saleh, M. C. Teich "Základy fotoniky". Matfyzpress, Praha, 1994.
- [2] F. T. S. Yu, X. Yang "Introduction to Optical Engineering". Cambridge University Press, ISBN: 0-521-57493-5, 1997.
- [3] J. W. Goodman, R. M. Gray, "Fourier Transform: An Introduction for Engineers". Kluwer Academic Publishers, Norwell, MA, 1995.
- [4] Cambridge Correlators [online]. Dostupné: <http://www.cambridgecorrelators.com/>.
- [5] Optical Correlator [online]. Dostupné: <http://www.timbercon.com/Optical-Correlator.html >.
- [6] P.AMBS. "Optical Computing, A 60-Year Adventure". Advances in Optical Technologies Journal, 2010. [online]. Dostupné:<http://www.hindawi.com/journals/aot/2010/372652.html >.
- [7] R. Caprari "Use of Joint Transform Optical Correlators for Precision Image Registration". [online] Dostupné: <http://www.dtic.mil/cgi-bin/GetTRDoc?AD=ADA311651>.
- [8] T. Naughton "Joint Transform Correlation [online]. Dostupné: < http://www.cs.may.ie/~tomn/pres/NUIMJtc/sld001.htm>.
- [9] T. Naughton, M. Klíma, J. Rott "Improved Joint Transform Correlation Performance Through Spectral Domain Thresholding", 1998 [online]. Dostupné:<http://www.cs.nuim.ie/~tomn/pubs/varasto/tjn199809oesjtc.pdf>.
- [10] Cambridge Correlators, Fourier Optics Experimenter: User guide, version: 1.0.46. 27.5.2010.
- [11] DOD [online]. Dostupné na internete < http://www.dod-tec.com/index.php/product/detail/71>.
- [12] D. Soendoro, I. Supriana, Traffic sign recognition with Color-based Method, Shape-arc estimation ond SVM. International Conference on Electrical Engineering and Informatics (ICEEI), pp. 1-6, 17-19 Júl 2011.
- [13] C. Bahlmann, Y. Zhu a spol. A system for traffic sign detection, tracking, and recognition using color, shape, and motion information, Proceedings. IEEE Intelligent Vehicles Symposium, 2005, pp. 255-260, 6-8 Jún 2005.
- [14] Z. Song, B. Zhaoa spol. Research on Recognition Methods for Traffic Signs. FGCN '08. Second International Conference on Future Generation Communication and Networking, 2008, pp. 387-390, 13-15 Dec. 2008.
- [15] Š. Toth, E. Kršák Traffic Sign Recognition and Localization for databases of Traffic Signs. Acta Electrotechnica et Informatica, Vol. 11, No. 4, 2011, 31-35, DOI: 10.2478/v10198-011-0039-2.
- [16] D. Solus, L. Ovseník, J. Turán Inventory System of Vertical Traffic Signs. Radioelektronika 2015. - Piscataway, IEEE, 2015 P. 121-124. - ISBN 978-1-4799-8117-5.
- [17] D. Solus, L. Ovseník, J. Turán Signal Processing - Object Detection Methods with Usage of Optical Correlator. Radioelektronika 2016. - Danvers : IEEE, 2016 S. 315-318. - ISBN 978-1-5090-1673-0 .
- [18] D. Solus, L. Ovseník, J. Turán Impact of Light Conditions on the Vertical Traffic Signs Detection in Vertical Traffic Signs Recognition System. MIPRO 2016. - Rijeka : MIPRO, 2016 P. 1485-1489. - ISBN 978-953-233-087-8.
- [19] D. Solus, L. Ovseník, J. Turán Optical Correlator in Vertical Traffic Signs Inventory System. Informatics 2015. - Danvers : IEEE, 2015 P. 247-251. - ISBN 978-1-4673-9867-1.
- [20] D. Solus, L. Ovseník, J. Turán Usage of Optical Correlator in Video Surveillance System for Abandoned Luggage. Informatics 2017. - Danvers : IEEE, 2017 S. 349-352. - ISBN 978-1-5386-0888-3.
- [21] D. Solus, L. Ovseník, J. Turán The Vertical Traffic Signs Detection in Different Light Conditions. Journal of Modern Technology and Engineering. Vol. 2, no. 2 (2017), p. 167-175. - ISSN 2519-4836.
- [22] D. Solus, L. Ovseník, J. Turán Image Processing System With Usage Cambridge Optical Correlator. Scientific Letters of Academic Society of Michal Baludansky. Roč. 4, č. 6A (2016), s. 99-101. - ISSN 1338-9432.
- [23] M. Taha Khan "Real-time recognition system for traffic signs," Master's thesis, Department of Computer Engineering, Dalarna University, 2008.

-
- [24] J. Miura, T. Kanda, Y. Shirai An active vision system for real-time traffic sign recognition, Proc. of Intelligent Transportation Systems, 2000, pp. 52-57, 2010.
- [25] K. Dyczkowski, P. Gadecki, A. Kulakowski Traffic Sign recognition System, World conference on soft computing, San Francisco, USA, May 23-26, 2011.

Searching for Malware Markers and Malware Behavioural Patterns

Jana Šťastná

Department of Computers and Informatics
Technical University of Košice, Košice, Slovakia
jana.stastna@tuke.sk

Martin Tomášek

Department of Computers and Informatics
Technical University of Košice, Košice, Slovakia
martin.tomasek@tuke.sk

Abstract—Malware is heavily obfuscated with goal to keep it undetected for as long as possible. While obfuscation techniques are known, detection systems using traditional malware signatures reveal weaknesses when new obfuscated variant of malware is discovered. It has to be analysed so that new detection signature could be written and distributed to users of the detection system. This approach does not represent ideal solution for protecting against new malware instances. For that reason, current malware research focuses on detection methods employing behavioural aspects of malicious programs and exploring various levels of abstraction on which behaviour of malware can be defined.

This paper presents contributions in the field of malware research in accord with current trends.

First, our experiments disproved the assumption that packing always prevails in malware. We showed that it is present significantly also in harmless software, and distinguishing malicious usage of packer from harmless is not feasible with only several syntactic characteristics observed.

Second, we found that untraditional high level of abstraction comprising quantity of executed actions in 12 behavioural categories is employable for defining malware behaviour. We managed to show patterns which occur among these behavioural data and implement a tool which is able to extract them.

Abstract—Malvér je v značnej miere zahmlievajú, s cieľom udržať ho nedetegovaný čo najdlhšie ako je len možné. Zatiaľ čo zahmlievacie techniky sú známe, detekčné systémy využívajúce tradičné malvérové signatúry odhaľujú nedokonalosti v momente, keď natrafia na nový, zahmlievaním upravený variant malvéru. Ten musí prejsť analýzou, aby nová detekčná signatúra mohla byť vytvorená a distribuovaná používateľom detekčného systému. Tento prístup nepredstavuje ideálne riešenie pre obranu pred novými malvérovými inštanciami. Z toho dôvodu sa súčasný výskum malvéru zameriava na detekčné metódy využívajúce aspekty správania škodlivých programov a skúmanie rôznorodých úrovní abstrakcie, na ktorých je možné správanie malvéru definovať.

Tento článok prezentuje prínosy v oblasti výskumu malvéru v súlade s aktuálnymi trendmi.

Po prvé, naše experimenty vyvrátili domnienku, že zaobaľovanie prevažuje vždy u malvéru. Ukázali sme, že sa vyskytuje významne aj u neškodného softvéru a rozlíšenie škodlivej aplikácie zaobaľovania od neškodnej nie je uskutočniteľné pozorovaním len niekoľkých syntaktických charakteristík.

Po druhé, zistili sme, že netradičná vysoká úroveň abstrakcie, pozostávajúca z kvantít vykonaných akcií v rámci 12 kategórií správania, je uplatniteľná pre definovanie správania malvéru. Podarilo sa nám ukázať vzory, ktoré sa vyskytujú medzi týmito údajmi o správaní, a implementovať nástroj, ktorým je možné ich extrahovať.

Index Terms—Abstraction, malware analysis, malware behaviour, malware signature, high-level pattern.

I. INTRODUCTION

At the beginning of malware's history, when perhaps several thousand malware instances spread between computers, it was quite enough to look for specific fragments of code in malware samples to detect their presence. Since then, malware creators rapidly evolved their strategies of obscuring malicious code and hiding its presence on infected system. Malware analysts that worked hard to unveil incriminating parts of malicious code had to adjust their strategy and search for different approaches to detect malware.

Nowadays, anti-virus products still use traditional syntax-based detection systems at their core. While these suffice to catch majority of threats, malware modified with mutation and obfuscation techniques can slip by. Traditional signature-based detection can only achieve *reactive* protection against malicious instances. The creation of malware detection signature is preceded by analytical process which goal is to find such fragments of executable code which are unique for that malicious instance (or several other, closely related), and thus can be employed to recognise it with certain level of confidence. The process of analysis may take several hours during which malware may fulfil the goals of its creator and substantial damage may be caused.

To achieve *proactive* protection against malware and eliminate or mitigate its harmful effects, researchers focus on novel approaches to analyse and describe what features will distinguish malware from goodware more effectively, and solve issues that stem in obfuscation and various mutations of malware's code. Researchers turn to behaviour-based techniques since mutation of malware in terms of behaviour is intricate to implement and therefore less probable. However, the levels of abstraction on which behaviour of malware can be examined are not solidly defined in malware research area.

Research Goals of our Work

From a broad perspective, our goal was to investigate malware behaviour and its various characteristics on high level of abstraction with the focus on finding such malware features which would not be dependent on specific syntactic representation of malicious samples. We deliberately aim to avoid replicating principles of traditional malware signatures.

The general goal is mirrored into 3 more specific goals, which directed primary focus of our work:

- 1) *Studying characteristics related to packing and occurrence of packing in harmless and malicious software*, in order to find out whether such typical malware's characteristic can contribute to distinguishing malware from harmless software.
- 2) *Experimenting with representation of behaviour captured from malware* with the aim to find such high level of abstraction which would potentially allow to withstand syntactic mutations of malware and, at the same time, would not be bound to executable code of specific samples from which the representation was extracted.
- 3) *Analysing behavioural data on high level of abstraction* in order to determine whether repeating patterns are present among behavioural descriptions of various samples, and design a procedure for extracting such behavioural patterns in case they are found.

A. Characteristics and Behaviour of Malware

Before we start exploring characteristics and behaviour of malware, we need to clearly state meaning of these terms.

According to Merriam-Webster dictionary, *behaviour* can be explained in several ways, from which we choose

- *"anything that an organism does involving action and response to stimulation"*,
- *"the response of an individual, group, or species to its environment"*, and
- *"the way in which something functions or operates"*¹.

These definitions can be adjusted to the domain of malware, so *behaviour* of malware would be broadly described as *anything that malware performs involving action and response to various inputs, response to its execution environment, and the way in which malware functions or operates*. A sequence of operational code can represent malware's *potential behaviour*, when such sequence is extracted from its executable code statically, or *actual behaviour*, when the sequence of code is extracted dynamically, by techniques of instrumentation.

Malware behaviour can be, e.g., verifying type of execution environment and adjusting execution flow of program according to it: When it resembles basic user's system, execution is unchanged and malicious payload is delivered. Or, when special defences, detection systems and analytic tools are found, as typically present in analytic system of malware researcher, execution flow is directed to early termination of program or to perform harmless actions to avoid suspicion.

Characteristic is defined as *"distinguishing trait, quality, or property"*². Basically, it describes attribute or feature that does not belong to *behaviour*. Concerning malware, an example would be information which anti-detection measures have been applied on malicious program, or names of sections comprising the program.

¹*Behaviour* defined by Merriam-Webster dictionary, online at <https://www.merriam-webster.com/dictionary/behavior>

²*Characteristic* defined by Merriam-Webster dictionary, online at <https://www.merriam-webster.com/dictionary/characteristic>

Although characteristics deal with static aspects of a program, they can be obtained with methods of both static (without executing the program) and dynamic analysis (requires program execution). For example, to gain information about all levels of protection which hide incriminating malicious code, one may need to execute the program so that one level of protection after the other would be revealed.

II. OUTLINE OF ISSUES REGARDING MALWARE RESEARCH

To make malware undetectable as long as possible, malware writers use techniques for obfuscation of incriminating malicious code and mutation of already existing malware samples which help them defeat traditional reactive detection systems. The main motivation of our work is *the problem that traditional malware detection is based on syntactic representation of malicious features taken from analysed samples*. The question is how should malware researchers cope with weaknesses of current analytic and detection methods.

When we look at mutations of malware from broad view, they can be implemented on two main levels: *syntactic* and *semantic*.

Mutations on the level of syntax change program's instructions by various, mainly obfuscating, techniques. It means that instructions may appear in somewhat changed order, new branches in program execution may be introduced, or useless code may be added, just to avoid detection by traditional malware signatures and to dramatically slow down analysis of such code which could have led to creation of new detection signature. While these mutations change malware sample syntactically, its semantics—especially actual behaviour expressed when the sample is executed—is preserved.

Mutations on the level of semantics are aimed at changing functionality of malicious program, and consequentially, also its syntactic form. This kind of mutation may be considered an evolution of malware, since it practically leads to new generations of malware with different behaviour. However, implementing mutation on semantic level is intricate and may lead to many fails, therefore (luckily) it is rare.

Even if obfuscation techniques which lead to syntactic mutations are well known and documented, they are still applied on a large amount of malware and this is not likely to change in the future. Semantic mutation seems as more powerful method for avoiding detection, but it is apparently too sophisticated to implement in mutation-automating tools. All in all, malware mutations modifying syntax are easier to implement (automatically generate) while still successfully avoiding detection, at least for amount of time which suffices malware creators to reach their objectives.

A. Detection Based on Malware Signatures

Malware signatures are currently irreplaceable as a concentrated representation of malicious code, used in traditional anti-virus (AV) detection engines. These signatures are formed by sequences of executable code that was found to be unique to certain malware. Olav Lysne further explains in chapter 7 of

his book [1] that simple signatures improved as a response to malware evolution and employ also more advanced structures.

Improvements to detection signatures are mentioned also by Abbas and Srikanthan who present an approach for automatic generation of simplified, *lightweight* signatures that represent several malware types in one signature, not only one signature per malware [2]. What is different in their work is that they do not employ sequences of bytes or strings that are characteristic to specific infiltrations, but they utilise short sequences of 2 to 5 system calls that are unique to group of several related malware samples.

Traditional signatures' weaknesses manifest with malicious samples concealed and morphed by techniques that alter syntactic form of a program, e.g. encryption, dead-code insertion, register reassignment, subroutine reordering, code transposition, instruction substitution. Signatures' drawbacks lead researchers to looking for improved or novel representation of malicious code which should be obfuscation-resistant. Bonfante *et al.* mention that a "*next generation of malware detectors based on semantic aspects*" [3] needs to be designed. In this manner they distinguish new, improved malware signatures from the traditional ones, which they call *string signatures*. Except for the problem with malware concealment techniques, they also name two other issues:

- It takes some time to form new malware signature. This task depends on malware analysts and currently cannot be performed fully automatically. Moreover, until the signature is created, malicious sample is free to spread in the wild.
- Malware analysts try to cover as many samples (malware variants) as possible with just one signature, however, it is difficult to maintain low false-positives ratio with the amount of malware growing so rapidly. Signature databases are also growing, but even old signatures cannot be removed from them without a risk that one day malware writers reimplement an old type of attack.

Also Lysne summarises issues tied with traditional malware signatures [1]:

- Presence of new malware in the wild must be discovered and malicious instances have to be sampled for analysis.
- Signatures are usually created manually by malware analysts, as also Egele *et al.* pointed out [4] several years before Lysne.
- To keep the detection system efficient, signatures for new malware have to be created and delivered to users perpetually.

B. Towards Behaviour-Based Detection

The process preceding and tied with signature creation causes that detection systems employing these signatures work as *reactive* systems. The presence of new malware has to be discovered, its samples analysed, following with signature creation and distribution to end users. This process delays effective protection against new threats, which are often syntactically modified versions of older malware. Researchers therefore shift their attention towards more *proactive*

approaches, promised by utilising behaviour of malware rather than its syntactic representation.

There are several techniques for malware analysis and detection based on rather behavioural aspects, which are described in a survey by Egele *et al.* [4]:

- *Function call monitoring* allows to record which specific functions (e.g. Windows API and Windows Native API functions, system calls) were called by analysed sample.
- *Function Parameter Analysis* is focused on current values of parameters of called functions, and their relationship with return values of functions called previously.
- *Information Flow Tracking* examines usage or manipulation of specified data that are *tainted* with labels during execution of analysed program.
- *Instruction trace* allows to examine details in behaviour of the sample at the level of machine instructions.

Mohd Shaïd and Maarof summarised methods of observing malware behaviour [5], specifically as monitoring changes in resources of operating system at the time of malware execution, extraction of system call sequences, input and output requests initiated by malware, and network activity. They point out that some malware samples perform minimum network actions or do not exhibit them at all. That is why malware detection should not depend solely on one specific type of behaviour, because it would risk being inhibited on missing data.

It is noticeable also in research papers that preferences regarding malware analysis are shifting from static towards dynamic analysis, and various combinations of both methods, while focusing on malware's semantic aspects. Opinions emphasizing that malware researchers should focus on behavioural aspects of malware, not just its syntactic features, are appearing. Gradually, malware samples are not viewed as some kind of text that needs to be analysed for typical string patterns. Analysts inspect operations performed by analysed samples—*actual behaviour*—and their broader impact on a host system.

The change of approach is apparent: Researchers strive for novel—behavioural malware signatures. The crucial question is, however, how do we form such malware signatures? Despite the shift towards malware semantics, looking at malware on syntactical level is still needed at some point. We cannot blindly leave out useful information that are contained in malware's code, but also we cannot depend solely on the level of code when designing approaches that should withstand its mutations. With this in mind, the level of abstraction on which useful information about malware are utilised may bring the desired change. Observation of potential malware behaviour may be performed statically through its code, and its actual behaviour may be examined through captured execution while analysed dynamically. Regardless of the method used, abstraction can aid in shifting the perspective on which malware behaviour is examined, e.g. utilising low-level code instruction sequences to figure out what high-level actions may be executed.

III. SUMMARY OF OUR WORK AND CONTRIBUTIONS

The research presented in this paper is focused on malicious software and its characteristics and behaviour that are extractable by means of static and dynamic analysis, accessible and traditionally used by researchers or professional malware analysts. From broad perspective, we aimed at researching such level of abstraction for describing malware, which is unusually high and has not been sufficiently explored in research yet.

A. Study on Malware Packing

Our work commenced with examining features that malicious software may bear and their employability in research. We performed a study to find out how the characteristic that software is packed can contribute to distinguishing malware from harmless software. The results of the study refuted several assumptions about packing, and sparked some future work ideas.

The study was performed on two sets of samples—100 malicious samples and 100 harmless samples, deliberately selected from usage domain of system maintenance tools and utilities, used e.g. for tasks management, deleting temporary files, broken links removal, memory optimization, files encryption. In both sets separately, we observed several characteristics on syntactic level of programs, namely program's density and entropy, names and quantity of program sections, and distribution of bytes in programs. We also observed how many anti-virus engines (from around 50) detected each sample as a threat. Part of the study is provided in our research paper [6] that was published earlier.

We found that harmless software indeed possesses typical malware's feature—packing—concerning specialised usage domain that we selected. A look at distribution of values regarding amount of packers detected in both malicious and harmless samples (Fig. 1) shows that for malware the value of median matches the lower quartile (value 0), and in case of harmless software median matches the upper quartile (value 2). We used two-sample Wilcoxon rank sum test (U test) for comparing the data sets, with confidence level 95% ($\alpha = 0.05$). For statistical test verifying a hypothesis that occurrence of packers *prevails in malware*, the resulting p-value by far exceeded the significance level. For the second statistical test, verifying a hypothesis that occurrence of packers *prevails in harmless* software, the p-value was < 0.001 which is far below the significance level, so we could accept the hypothesis.

We also found that right now it is not possible to distinguish malicious usage of a packer from harmless one by analysing only several program's features, mentioned earlier, on the syntactic level.

Packing is considered a typical feature of malware and is often used as one of the first indicators for identifying analysed sample as potentially malicious. In our study on malware packing we deem contributory the following:

- We experimentally verified that packing is not exclusively prevalent in malware, and its occurrence was higher in




Fig. 1. Boxplots for amounts of packers detected in harmless samples and malicious samples. Outliers are not shown in the figure.

harmless software, with statistical significance level $p < 0.001$.

- Our research study showed that harmless software from specific usage domain may exhibit features (modification by packing and syntactic characteristics related to it) that are expected rather in malicious software.
- We showed that distinguishing malicious usage of packer from harmless one is not possible when only several program's syntactic features related to packing are considered.
- We presented an untraditional approach in which harmless samples are targeted for searching features that are considered typical for malicious samples.

B. Malware Behaviour on High Level of Abstraction

The next major part of our work builds upon data obtained by our tool *TH Downloader*³ with a goal to address the problem of malware's behavioural characteristics on high level of abstraction. From data we collected we observed quantity of actions executed per sample concerning 12 behavioural categories: *DNS requests*, *file creations*, *file deletions*, *flows in TCP*, *HTTP get* and *HTTP post* requests, *mutex creations*, *process creations*, *registry entries* manipulated, *service creations*, *services started*, and *Winsock DNS* operations.

At first, 34 099 entries containing these behavioural data were available for our experiments. By analysing quantity of these operations, we figured out that there are distinct samples, belonging to the same infiltration type (malware signature), which quantity of executed actions corresponds to a pattern. These findings are published in our earlier conference paper [8]. Gradually, the amount of data describing behaviour of malware and harmless samples expanded to 303 958 samples.

We showed that *behavioural patterns on high level of abstraction* that comprise quantity of executed actions in 12 behavioural categories are present among malware samples. One of such patterns is illustrated in graphical form in Fig. 2. These behavioural patterns have, by their nature and level of abstraction, potential to withstand mutations of malicious programs on syntactic level, and thus allow to detect variants of malware created by various obfuscation techniques. Overall, this contributes to the research field of malware and may

³The tool is described in our published conference paper [7].




Fig. 2. An example of a chart that visualises behaviour of malware samples on high level of abstraction, belonging to the same malware signature. The chart originally appeared in one of our published papers [9].

facilitate reaching malware detection techniques with *proactive* nature.

The level of abstraction on which behaviour of malware can be examined was studied experimentally. This part of our work forms core of our research since the remaining experiments and observations are heavily based on it. Contributions in this part of our work are identified as follows:

- We presented untraditional high level of abstraction for describing malware behaviour that comprises quantity of executed actions in 12 behavioural categories.
- We experimentally verified that the high level of abstraction we outlined is employable for observing patterns among samples of the same malware signature.
- We defined *high-level malware behavioural patterns* and formulated a preliminary formal notation. Also, we outlined how evaluation of patterns' relevance can be approached in the future and which variables may play key role in such evaluation. The patterns we defined have potential to withstand mutations of malware on syntactic level and thus combat obfuscation techniques.

C. Patterns of Malware Behaviour

In our work we had to face a problem concerning inconsistency of malware signatures labels between anti-virus vendors. As it turned out, it is a long-known persisting problem, caused by, we suppose, varying detection ability and labelling granularity of AV products. While the differences in detection and malware labelling are used for diverging from the others on the AV market, the solution is far from emerging. To *mitigate* influence of the issue on our work, we searched for options to adjust analysis of behavioural patterns so that it will work with data about malware samples separately with respect to each AV's labelling. This led to major implementation changes which gave rise to our system *AMAARA*.

Project *AMAARA* was implemented as Python application with several modules dedicated to various functionalities. It allowed

- collecting reports from malware analysis provided by online analytic service *Totalhash* with improved efficiency,




Fig. 3. An example of a plot produced from exploratory analysis of behavioural data of malware. It visualises correlation discovered between amounts of *files created* and *files deleted* among malicious samples.

- parsing more entries from reports and also adapt to varying content of reports, in comparison to older tool *TH Downloader* that we used in the past,
- utilising search and analytic engine *Elasticsearch* for handling backup of collected reports, storing data parsed from new reports and data originally obtained by *TH Downloader*, and searching the data with high speed,
- performing exploratory data analysis to gain useful overview about assembled data and visualising data in charts and diagrams (e.g. Fig. 3),
- extracting high-level behavioural patterns to provide future research with resources for studying outcomes that stem in differences of AV engines detection accuracy and labelling granularity.

We expanded our work on high-level malware behavioural patterns with help of *AMAARA*, supporting exploratory analysis of behavioural data which are also used in extracting behavioural patterns. This part has rather explorative character and expands opportunities for future research. However, it presents several valuable contributions:

- We pointed out the problem of inconsistency in malware signatures labelling among anti-virus vendors and presented an approach that mitigates the issue in our research.
- We managed to implement a system for extracting all high-level behavioural patterns, which has potential to be employed in future continuation of our malware research.
- Data analysis that we performed revealed that our behavioural patterns may be further simplified from 12 behavioural categories to 10, maybe even fewer. For example, figure 4 shows that category *http_post* occurred in both malicious and harmless samples relatively seldom and so could be merged with *http_get* into broader *http* category.

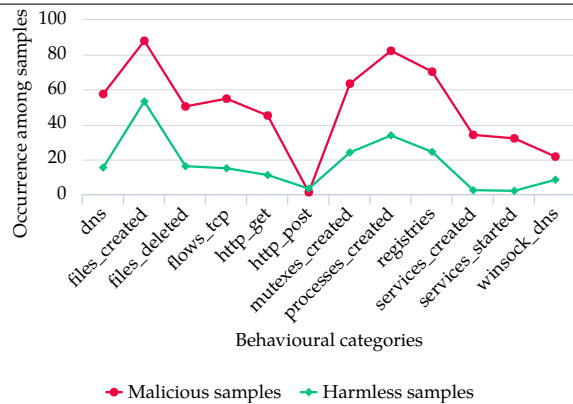


Fig. 4. Occurrence of 12 behavioural categories among *malicious* and *harmless* samples.

- Based on analysis of currently extracted behavioural patterns we expect that around 70% of malware signatures can be defined by at least one behavioural pattern on high level of abstraction.

IV. CONCLUSION AND PROPOSAL FOR CONTINUATION OF THE RESEARCH

Our work that is shortly presented in this paper succeeded to answer several questions regarding malware, its characteristics, behaviour, and level of abstraction on which it can be meaningfully researched. On our way to answers, however, further questions emerged. Those we deem interesting and worthy to pursue are outlined in next paragraphs as suggestions for continuation of our research.

In our study on packing as distinguishing malware feature we experimented with harmless and malicious programs from domain of system maintenance tools and utilities. Regarding this experiment we thought of several possible continuations: Samples from the same domain, harmless and malicious, would be examined, but with focus on different typical malware feature. The other version would vary the usage domain from which samples are selected. It could be, e.g., domain of communication tools like email clients, social network clients, chat applications. We believe that harmless samples need to get more attention in research and experiments such as this could help achieve that.

At the beginning of our work on exploring malware behaviour on high level of abstraction, we noticed an approach to behaviour abstraction on the level of function calls which sparked our interest. Kwon and Lee abstracted API calls according to object of the call into 32 classes, and each class further had 4 behaviour types—open, close, read, write [10]. While in total 128 behaviour classes would be quite a big leap from our 12 categories, it could be interesting to experiment with various granularities concerning behaviour categorisation and length of resulting behavioural pattern.

The idea for future work, we are already counting with, concerns relevance evaluation of extracted high-level behavioural

patterns. Issues of varying relevance of patterns and variables that need to be considered for the evaluation formula are identified. Our intention is directed on evaluating extracted behavioural patterns separately for each of employed anti-virus engines (in the spirit of mitigating malware signatures labelling inconsistency between AV engines), compare the resulting relevancies, and try to decide whether implementing a prototype of detection tool which would illustrate utilising our behavioural patterns would be beneficial.

The mass of data we obtained through exploratory data analysis is perfectly fit for systematic study aiming to evaluate differences between malware signatures labelling, detection ability and overall labelling granularity of AV engines employed in our data set, and their potential outcomes for malware research.

Last but not least, in our work we considered using machine learning approach to try employing our data of malware behaviour in creating a regression or classification models (first global model of all samples, then separately for each malware signature), however, lack of time hindered our plans. The idea was to experiment with regression models for *proactive* detection of novel malware variants, and by experimenting with classification models their employability for malware detection would be examined. By using on-line learning strategy a dynamically adjusting model of malware would be formed—the origin of *dynamic behavioural malware signature*.

ACKNOWLEDGMENT

This work has been supported by the Slovak Research and Development Agency under the contract No. APVV-15-0055 and by project KEGA no. 079TUKE-4/2017.

REFERENCES

- [1] O. Lysne, *The Huawei and Snowden Questions: Can Electronic Equipment from Untrusted Vendors be Verified? Can an Untrusted Vendor Build Trust into Electronic Equipment?* Simula SpringerBriefs on Computing, Cham: Springer International Publishing, 2018.
- [2] M. F. B. Abbas and T. Srikanthan, “Low-complexity signature-based malware detection for iot devices,” in *Applications and Techniques in Information Security*, pp. 181–189, Springer Singapore, 2017.
- [3] G. Bonfante, M. Kaczmarek, and J.-Y. Marion, “Architecture of a morphological malware detector,” *Journal in Computer Virology*, vol. 5, no. 3, pp. 263–270, 2009.
- [4] M. Egele, T. Scholte, E. Kirda, and C. Kruegel, “A survey on automated dynamic malware-analysis techniques and tools,” *ACM Comput. Surv.*, vol. 44, pp. 6:1–6:42, Mar. 2012.
- [5] S. Mohd Shaid and M. Maarof, “Malware behavior image for malware variant identification,” in *Biometrics and Security Technologies (ISBAST), 2014 International Symposium on*, pp. 238–243, Aug 2014.
- [6] J. Šťastná and M. Tomášek, “The problem of malware packing and its occurrence in harmless software,” *Acta Electrotechnica et Informatica*, vol. 16, no. 3, pp. 41–47, 2016.
- [7] J. Šťastná and M. Tomášek, “Assembling behavioural characteristics of malicious software,” in *2017 IEEE 14th International Scientific Conference on Informatics*, pp. 406–411, 2017.
- [8] J. Šťastná and M. Tomášek, *Characterising Malicious Software with High-Level Behavioural Patterns*, vol. 10139 of *Lecture Notes in Computer Science*, pp. 473–484. Springer International Publishing, 2017.
- [9] J. Šťastná and M. Tomášek, “High-level malware behavioural patterns: Extractability evaluation,” in *Annals of Computer Science and Information Systems volume 11: FedCSIS 2017*, pp. 569–572, 2017.
- [10] J. Kwon and H. Lee, “BinGraph: Discovering mutant malware using hierarchical semantic signatures,” in *2012 7th International Conference on Malicious and Unwanted Software*, pp. 104–111, IEEE, oct 2012.

PLC Based HIL Workplace for Verification of Complex Drives Control Methods

Peter TALIAN (*Author*)

Department of Electrical Engineering and Mechatronics
Technical University of Košice
Košice, Slovakia
peter.talian@tuke.sk

Daniela Perduková (*Author*)

Department of Electrical Engineering and Mechatronics
Technical University of Kosice
Košice, Slovakia
daniela.perdukova@tuke.sk

Abstract—*The quality of the stroke control in the middle of the continuous line greatly influences the quality of the end product line, whether it be sheet metal, pipes, plastic film or paper making, and so on. The main requirement is that the movement itself is constant and non-invasive in the material during all line operations and: start of the line, line break, tensile defects affecting the part of the line before and after the middle part and, of course, also changes in parameters (for example the moment of inertia) The submitted paper deals with hardware-in-the-loop simulations. It is devoted to realization of HIL workplaces based on PA programmable machine, the creation of the regulatory structure model of middle section of continuous line in MATLAB Simulink, where subsequently, this continuous model must be discretized to the disk model, the structure being divided into the part with the controller and part with the center line model of the continuous line. The designed model of the middle part of the continuous line is implemented in the PA programmable machine, where it is possible to display the progress of the monitored variables using the operator panel.*

Keywords— *Hardware-in-the-loop, Programmable Logic Controller (PLC), programovateľný automat (PA), Continuous line, II. Ljapunov method*

I. INTRODUCTION

The basic requirement in continuous processing of various materials by means of pulling tension in the area of their elastic or plastic deformations is that for an accurately defined time course of the pull, which in general leads to the requirement for high quality tension control in flexible nonlinear systems with inexactly known parameters and external additive disturbances. This is a relatively difficult task to solve in general, especially for systems with nonlinear and flexible properties and with imprecisely known system description and system parameters, e.g. the flexible coupling and nonlinearities of the system [1]–[4]. It is very often necessary to change and adjust the parameters or sometimes also the structure of the designed controllers directly on the line, which, for one, is time consuming, and also carries the risk that not all possible parametric as well as additive

disturbances affecting the line will be considered and tested. Continuous processing lines represent a multi-motor drive system in which the individual drives are mechanically coupled through the web of material. This system can be regarded as a nonlinear multivariable system the parameters of which depend on the mechanical properties of the material and on the speed of its motion. Continuous lines as large-scale systems are very often decomposed into many subsystems for web tension control and web speed control. All those subsystems have strong mutual interactions with one other. In a large scale system [5], [6] control decentralization is very often necessary because the system to be controlled is too large and the problems to be solved are too complex. Most industrial web transport systems use decentralized PID or PI type controllers [7]–[9]. These control methods are simple but the coupling between tension and speed limits their performance primarily in dynamic states. Another rather important aspect in these systems is that there exist many uncertainties and disturbances (vibrations, web slipping, roller non-circularity, etc.), which can result in a reduction in quality and even destruction of the material being processed [10]. For this reason the control strategy for continuous technological lines should be robust with respect to the uncertainties and disturbances.

Various robust control methods have been developed. The shortcoming of most robust control structures is the fact that robustness is secured only for a small range of parameter changes [11]–[14], and that they employ rather complex correction networks for securing autonomy [15]–[18]. Research in complex and robust control techniques for web transport systems based on the classical mathematical equation is a topical issue. In [19]–[21] optimal multivariable control methods that are able to reduce the effect of interaction were introduced, but they require an accurate model and parameters. The advanced control methods, such as observed based feedback control [22], [23] and time optimal control [24] are very complicated in terms of both structure and controller parameters design, which is their main drawback in terms of their industrial application.

Due to the fact that multi-motor drives occur in practice as

parts of larger technological assemblies, it is necessary to look for such methods of their control that would be simply and easily physically interpretable. Otherwise their wide application in industrial practice cannot be expected.

One of the ways of achieving the above goals is to use control structures with a reference model, designed on basis of Lyapunov’s second method suitable also for MIMO systems [25]–[28]. These control structures enable getting a general nonlinear time-variant continuous system into a defined steady state using a prescribed reference model, while the structural complexity of the designed controllers depends on the suitable choice of the Lyapunov function [29]–[32].

As the design procedure of control structures according to this method contains several optional elements, there generally exist many variations of such structures that can be deduced using the said method.

For the solution of tasks of the above described type this paper proposes a model reference control structure, the stability of which is derived on basis of the second Lyapunov method [33]. The main idea of the method lies in extending the system control algorithm by a new additional piece of information that can be easily obtained from the system’s output variable and which will secure that in steady state the control deviation of the output variable will be zero. If we then design line control for this extended system such that will make it asymptotically stable with prescribed dynamics according to the reference model, this will automatically fulfil the desired control goal in steady state, as well as in very good quality in transient states.

The properties of the designed control structure for tension control of the middle section of a continuous processing line were verified by modelling in MATLAB.

II. CONTINUOUS LINE STRUCTURE

Typical representatives of multi-motor drive systems are continuous processing lines, where the individual working machines are coupled with each other through the material. They are, for example, lines for processing continuous flows of material (e.g. sheet metal strips, tubes, processing lines in paper mills and printing works, etc.) by material traction in the field of elastic or plastic deformation, which influences the material’s mechanical properties.

In industrial practice many various typical multi-motor drive configurations exist [10] where the pulling tension in the web arises due to different circumferential speeds of the work rolls, or due to the differences in their positions. For simplicity only the coupling of two machines (middle part of continuous line) is investigated, but this idea can be extended to an indefinite number of machines coupled by the processed material.

Figure 1 shows the structure of the middle section of a continuous line (further referred to as CL). The structure includes DC motors powered through static transistor

converters TC. The working machines of the line are driven by the motors through gearbox j ; v_1, v_2 are machine rolls circumferential velocities, F_{12} is the tension in the web of material between the two machines. The main line disturbances are tensions before and after the middle section of the considered line affecting the first and second drive (F_{01} and F_{23}). K_V are circumferential velocity sensors, K_F is the tension sensor, r is roll radius, u_{v1}, u_{v2} are outputs from velocity sensors and u_{F12} is the output of the tension sensor. The control voltages u_1, u_2 of converters represent the input variables of the system. The tension in the web of material F_{12} and the web of material velocity v_2 are the output variables. section, so it can be ignored. Assume further that for all sensors the amplification value equals 1, so we will continue with real physical ranges of the particular quantities.

The block diagram of the CL middle section (for Simulink) under these assumptions is shown in Fig. 2.

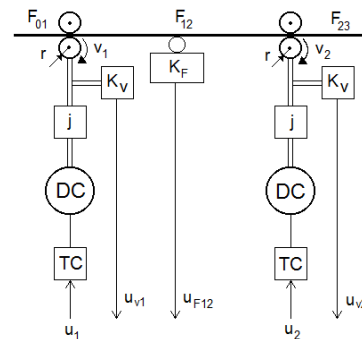


Fig. 1. Structure diagram of middle section of continuous line.

In the block diagram a commonly known model of separately excited DC motor is used. For flexible coupling properties modelling we used the model according to Brandenburg [34]. The physical analysis of the line [35] implies that this system includes a so called “fast” tension subsystem and “slow” speed subsystem, and it is a non-autonomous system (i.e. these two subsystems influence one another). The parameters of the CL model are specified in the Appendix A.

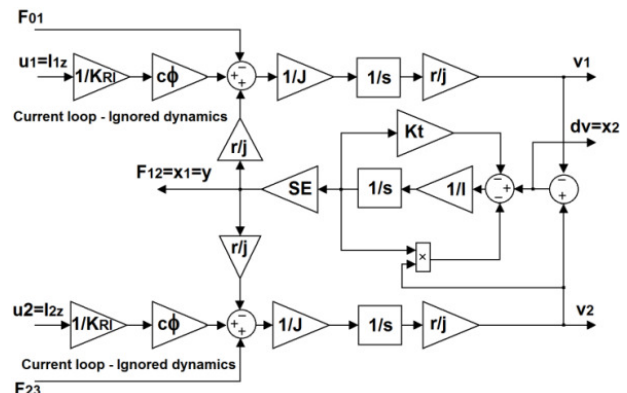


Fig. 2. Block diagram of CL middle section.

In terms of control this is a 3rd order MIMO system with two inputs [$u_1 = I_{1z}, u_2 = I_{2z}$] and two outputs [$F_{12}; v_2$], which can be influenced by two additive disturbances [F_{01}, F_{23}].

As has already been mentioned, the main goal of control in such systems is precise tension control – it should have a constant and non-oscillating course in all operation stages (start-up, deceleration) and under the influence of disturbances before and after the section of the line under consideration as well as of changes of parameters (e.g. the moment of inertia).

In terms of tension control the controlled system will be a 2nd order system with two inputs [$u_1 = I_{1z}, u_2 = I_{2z}$] and one output $y = F_{12}$. The first state variable will be the tension ($F_{12} = x_1$) and we will choose the second state variable to be the difference of the circumferential velocities of the rolls ($dv = x_2 = v_2 - v_1$), where velocity v_2 will be considered as an additional disturbance.

The state description of the middle section of the CL in terms of tension control according to Fig. 2 has the form:

$$\begin{bmatrix} \frac{dx_1}{dt} \\ \frac{dx_2}{dt} \end{bmatrix} = \begin{bmatrix} -\frac{(K_t) + v_2}{1} & \frac{SE}{1} \\ -\frac{2r^2}{j^2J} & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 \\ -\frac{rc\phi}{jJK_{RI}} \end{bmatrix} u_1 + \begin{bmatrix} 0 \\ \frac{F_{01}r}{jJ} + \frac{F_{23}r}{jJ} + \frac{rc\phi}{jJK_{RI}} u_2 \end{bmatrix}. \quad (1)$$

III. DESIGN OF CONTROL STRUCTURE WITH REFERENCE MODEL FOR MIDDLE SECTION OF CONTINUOUS LINE

The desired dynamical properties of continuous line pulling tension will be prescribed by a reference model, which is as a rule of the same order as the controlled system, generally in the form

$$\frac{dx_M}{dt} = \mathbf{A}_M \mathbf{x}_M + \mathbf{B}_M w, \quad (2)$$

where \mathbf{A}_M is the state matrix of the reference model, \mathbf{B}_M is the reference model inputs matrix, \mathbf{x}_M is the reference model state quantities vector, and w is the desired value.

As for the 2nd order controlled system we need to obtain additional information on the unknown parametrical and also additive disturbances, we will extend its reference model by one state variable $x_{3M} = x_{eM}$, which will secure that in steady state the tension control disturbance is equal to zero. The reference model will be a 3rd order linear system the dynamics of which can be set by a single optional positive parameter α . According to [36] this reference model can secure optimal dynamical properties of the controlled system in terms of the minimal control disturbance and minimal input power criterion.

Then the extended state description of the reference model for the 2nd order system is:

$$\begin{bmatrix} \frac{dx_{eM}}{dt} \\ \frac{dx_{1M}}{dt} \\ \frac{dx_{2M}}{dt} \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ -\frac{\alpha^3}{2} & -\frac{3\alpha^2}{2} & \frac{3\alpha}{2} \end{bmatrix} \begin{bmatrix} x_{eM} \\ x_{1M} \\ x_{2M} \end{bmatrix} + \begin{bmatrix} -1 \\ 0 \\ 0 \end{bmatrix} w. \quad (3)$$

Note: The tension is generated by the first drive in opposite direction to the line speed, which is represented by the work rolls circumferential velocity v_2 of the second drive.

The block diagram of the considered reference model is shown in Fig. 3.

It is clear in Fig. 3 that in steady state the input of integrator x_{3M} will equal zero and tension will equal the desired value w .

For the controlled system description we will consider a system described by state equations

$$\frac{dx}{dt} = \mathbf{A}x + \mathbf{B}u + \mathbf{d}, \quad (4)$$

where \mathbf{A} is the controlled system state matrix, \mathbf{B} is the controlled system inputs matrix, u is the controlled system input and \mathbf{d} is the time variable vector of unmeasurable additive disturbances.




Fig. 3. Reference model for pulling tension control extended by an additional state variable.

In terms of CL middle section tension control this is a 2nd order controlled system which similarly to the reference model will be extended by the output controlled variable integrator. Its state description will then in general be as follows:

$$\begin{bmatrix} \frac{dx_e}{dt} \\ \frac{dx_1}{dt} \\ \frac{dx_2}{dt} \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ a_{11} & a_{12} & 1 \\ a_{21} & a_{22} & 0 \end{bmatrix} \begin{bmatrix} x_e \\ x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ b_2 \end{bmatrix} u + \begin{bmatrix} 0 \\ d_1 \\ d_2 \end{bmatrix}, \quad (5)$$

where d_1 and d_2 are unknown additive disturbances and a_{11} ,

a_{12} , a_{21} , a_{22} are elements of the 2nd order controlled system state matrix \mathbf{A} .

As the goal of electrical drive control is not the zero state of the state vector \mathbf{x} but the zero state of its control deviation from the desired values, it is suitable to choose as state quantities of the system the deviations of state vector \mathbf{x} from the desired values, and also to examine stability with regard to these deviations.

If we establish the reference model and system disturbance as

$$\frac{d\mathbf{e}}{dt} = d\mathbf{x}_M - d\mathbf{x}, \quad (6)$$

then through simple adjustments we will obtain a system whose states are constituted by state deviation \mathbf{e} :

$$\frac{d\mathbf{e}}{dt} = \mathbf{A}_M \mathbf{B}_M + \mathbf{B}_M w - \mathbf{A}\mathbf{x} - \mathbf{B}\mathbf{u} - \mathbf{d}, \quad (7)$$

$$\frac{d\mathbf{e}}{dt} = \mathbf{A}_M (\mathbf{x}_M - \mathbf{x}) + (\mathbf{A}_M - \mathbf{A})\mathbf{x} + \mathbf{B}_M w - \mathbf{B}\mathbf{u} - \mathbf{d}, \quad (8)$$

$$\frac{d\mathbf{e}}{dt} = \mathbf{A}_M \mathbf{e} + \mathbf{f} - \mathbf{B}\mathbf{u}, \quad (9)$$

where we have denoted

$$\mathbf{f} = (\mathbf{A}_M - \mathbf{A}) \mathbf{x} + \mathbf{B}_M w - \mathbf{d}, \quad (10)$$

where \mathbf{f} is the generalized disturbance vector which

comprises all parametrical and additive disturbances affecting the system with regard to its reference model.

The goal of the controller design is to find such mathematical formulation for establishing the input u where the zero solution of the system (9) would be asymptotically stable, i.e. $\lim_{x \rightarrow \infty} \mathbf{e} = 0$.

The Lyapunov function is most often chosen as the weighted quadratic form of system states, because it is positive definite and simple. If we choose the Lyapunov function for system (9) as

$$V = \mathbf{e}^T \mathbf{P} \mathbf{e} = \mathbf{e}^T \mathbf{z}, \quad (11)$$

where \mathbf{z} is the weighted state deviation vector, where for the i -th element it applies that

$$z_i = \sum_{k=1}^n p_{ki} e_k, \quad (12)$$

where p_{ki} are elements of positive definite matrix \mathbf{P} and n denotes the order of the extended controlled system, we can deduce the derivation of Lyapunov function (11) with regard to system (9) as:

$$\frac{dV}{dt} = \mathbf{e}^T (\mathbf{A}_M^T \mathbf{P} + \mathbf{P} \mathbf{A}_M) \mathbf{e} + 2(\mathbf{f}^T \mathbf{z} + b_2 u), \quad (13)$$

$$\frac{dV}{dt} = -\mathbf{e}^T \mathbf{Q} \mathbf{e} + 2(\mathbf{f}^T \mathbf{z} + b_2 u). \quad (14)$$

The zero solution of system (9) will be asymptotically stable if we secure that the Lyapunov function derivation (11) is negative definite. It must then apply that

$$\mathbf{A}_M^T \mathbf{P} + \mathbf{P} \mathbf{A}_M = -\mathbf{Q}. \quad (15)$$

Equation (15) is a matrix Lyapunov equation where matrices \mathbf{P} and \mathbf{Q} are positive definite matrices.

By choosing the reference model according to (3) we can avoid solving (15) as for this reference model the elements of matrix \mathbf{P} according to [36] can be determined analytically, while it applies that $\mathbf{Q} = -\alpha \mathbf{P}$.

Based on the above, for Lyapunov function derivation the following applies:

$$\frac{dV}{dt} = -\alpha \mathbf{e}^T \mathbf{P} \mathbf{e} + 2(\mathbf{f}^T \mathbf{z} + b_2 u), \quad (16)$$

$$\frac{dV}{dt} = -\alpha \mathbf{e}^T \mathbf{z} + 2(\mathbf{f}^T \mathbf{z} + b_2 u), \quad (17)$$

where \mathbf{P} is a positive definite matrix

$$\mathbf{P} = \begin{bmatrix} \frac{\alpha^5}{2} & \alpha^4 & \frac{\alpha^3}{2} \\ \alpha^4 & \frac{5\alpha^2}{2} & \frac{3\alpha^2}{2} \\ \frac{3\alpha^2}{2} & \frac{3\alpha^2}{2} & \frac{3\alpha}{2} \end{bmatrix}. \quad (18)$$

The first element of (17) is always negative, as the expression $\mathbf{e}^T \mathbf{z} = \mathbf{e}^T \mathbf{P} \mathbf{e}$, where $\mathbf{z} = \mathbf{P} \mathbf{e}$ is always positive. System (9) will then be asymptotically stable, i.e. its derivation will be negative, if for input u the following will apply

$$u = -K \mathbf{e}^T \mathbf{z}. \quad (19)$$

Note: The second element of (17) will be negative, if $b_2 u = -b_2 K \mathbf{e}^T \mathbf{z}$ will be larger than $\mathbf{f}^T \mathbf{z}$, which can always be assured by a sufficiently large value of optional positive parameter K .

IV. TENSION CONTROL FOR MIDDLE SECTION OF CONTINUOUS LINE

We consider the state description of the CL middle section in terms of tension according to (1).

We will extend this 2nd order system by an additional state variable x_e according to (5) as follows:

$$\begin{bmatrix} \frac{dx_e}{dt} \\ \frac{dx_1}{dt} \\ \frac{dx_2}{dt} \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ -\frac{(K_t) + v_2}{l} & \frac{SE}{l} & 0 \\ -\frac{2r^2}{j^2 J} & 0 & 0 \end{bmatrix} \begin{bmatrix} x_e \\ x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ -\frac{rc\phi}{jJK_{RI}} \end{bmatrix} u_1 + \begin{bmatrix} 0 \\ 0 \\ \frac{F_{01}r}{jJ} + \frac{F_{23}r}{jJ} + \frac{rc\phi}{jJK_{RI}} u_2 \end{bmatrix}. \quad (20)$$

The dynamic properties of tension in the middle section of the continuous line will be prescribed by a reference model according to (3). The optional positive number α in the reference model enables the setting of optimal dynamics of the controlled variable, while it applies that it is inversely proportional to the constant used for settling the dynamical actions in the model. If we need to settle the tension in the web of material within approximately 1s, then based on the Shannon-Kotelnikov theorem the value of the parameter will be $\alpha = 5$.

For generating state quantities deviations of the reference model and the system according to (6) the following modification can be applied

$$\begin{aligned} e_3 &= x_{eM} - x_e = \int x_{1M} dt - \int x_1 dt = \\ &= \int (x_{1M} - x_1) dt = \int e_1 dt. \end{aligned} \quad (21)$$

The controlled system (20) will observe the reference model, and $\lim_{x \rightarrow \infty} \mathbf{e} = 0$ will apply, i.e. the controlled system will be asymptotically stable if we calculate input u according to (19), where vector \mathbf{z} is

$$\mathbf{z} = \mathbf{P}\mathbf{e}. \quad (22)$$

With regard to the selection of the reference model according to (3) the elements of matrix \mathbf{P} were determined from matrix (18) for $\alpha = 5$.

For the elements of vector \mathbf{z} it then follows:

$$z_1 = p_{11}e_1 + p_{12}e_2 + p_{13}e_3, \quad (23)$$

$$z_2 = p_{21}e_1 + p_{22}e_2 + p_{23}e_3, \quad (24)$$

$$z_3 = p_{31}e_1 + p_{32}e_2 + p_{33}e_3, \quad (25)$$

and input u will equal

$$u = -K(e_1 z_1 + e_2 z_2 + e_3 z_3). \quad (26)$$

The resulting schematic of CL middle section tension control is shown in Fig. 4.

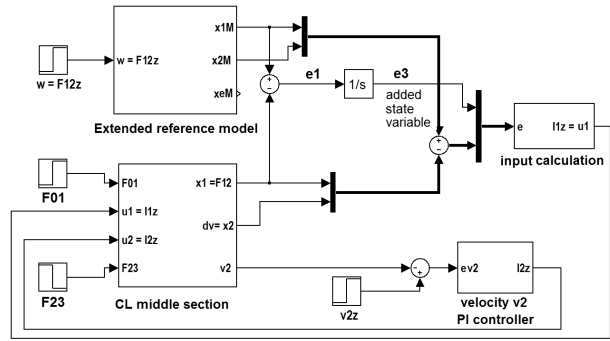


Fig. 4 Block diagram of CL tension control.

For continuous line speed control (v_2 – circumferential velocity of second drive work rolls) a simple standard PI controller was used, as in this case the main target is the quality of tension control. As mentioned above, for the proposed controller the change in velocity v_2 represented another additive disturbance.

V. VERIFICATION OF THE PROPOSED CONTROL STRUCTURE AND DISCUSSION

From the point of view of production technology it is required that the drive system of the continuous line ensures the required value of tension in the web independent from its speed. The goals of the system's control are the following:

- Autonomous setting of controlled line variables, such as speed and tension of the line, i.e. system decoupling.
- Invariance against tension disturbances caused primarily by change of speed v_2 , which represents an external slowly changing disturbance, and by the tension disturbances before and after the line section under consideration. (i.e. disturbances in load torque of the drive – F_{01} , F_{23}).
- Robustness against line parameter changes (damping constant changes, changes of the drives' moment of inertia).
- Desired dynamics for every controlled variable (adjustment of tensions without overshoot).

The properties of the proposed control structure for tension control of the middle section of a continuous line were verified by digital simulation in MATLAB for the so called CL operation cycle, which includes three stages – start-up, line running at constant operational speed, and line run finish. The CL parameters used in the simulation are listed in the Appendix A.

When verifying the properties of the designed control we assumed the influence of two types of external (additive) disturbances on the CL middle section, namely:

- step changes of tension before (F_{01}) and after (F_{23}) the line section under consideration from zero value to the

value of 80 % of the nominal tension in time $t = 3$ s and $t = 6$ s, as demonstrated in Fig. 5;

- the slowly changing line speed v_2 which was controlled by a standard PI controller (the PI controller parameters are listed in the Appendix A). The time plot for line speed v_2 for the desired value equal to the nominal speed, i.e. $v_2 = 0.6 \text{ ms}^{-1}$ is shown in Fig. 6.

The designed control structure was derived on basis of the second Lyapunov method which delimits the range of its optional parameters, i.e. the values of the elements of matrix \mathbf{P} and the parameter K , for which the controlled system as a whole will be stable.

The elements of matrix \mathbf{P} are computed from the Lyapunov matrix equation (15), where a positive definite matrix \mathbf{Q} has to be chosen. The magnitude of the elements of matrix \mathbf{Q} (and therefore also of matrix \mathbf{P}) influences the rate of decay of the Lyapunov function (11), i.e. the rate of decay of control deviation \mathbf{e} . The system (9) will be stable for any chosen elements of matrix \mathbf{Q} as long as the condition of positive definiteness is satisfied. If, however, we chose a reference model such that will secure optimal dynamical properties of the controlled system in terms of the minimal control deviation and minimal input power [36], we can avoid solving the Lyapunov matrix (15), because the elements of matrix \mathbf{P} can be determined analytically according to (18), as demonstrated in Chapter III.

The proposed tension control structure includes one optional parameter K in (17) for calculating input u , and this parameter has to be positive and sufficiently large to secure asymptotic stability of the controlled system ((15) Chapter III.). On the other hand, its size is limited by physical limitations in the controlled system, such as motor currents in case of electrical drives, the dynamics of real converters, etc.

The dynamical performance of the output controlled variable of tension F_{12} for the concerned operation cycle and for the value of parameter $K = 2$ (or $K = 5$) is illustrated in Fig. 7. It is evident that tension in the middle section of the continuous line practically follows the tension prescribed by the reference model during the whole operation cycle, and it does so even when influenced by step disturbances at its input and output at time $t = 3$ s and $t = 6$ s (Fig. 5), and also under the influence of all changes of speed (Fig. 6), which fact verifies the invariance of the proposed control against additive disturbances. For the value of parameter $K = 5$ we obtain a better course of tension, which corresponds with better satisfaction of the asymptotic stability condition in (19).

The robustness of the proposed control structure was verified for changes in the two most important controlled system parameters that significantly influence the properties of flexible coupling, namely damping of the material being processed (material elasticity), and the moment of inertia of the drives (pulling thicker sheet metal, material weld). Figure 8 and Fig. 9 show the time plots of tension F_{12} for as much as fivefold reduced material damping (i.e. five times more elastic material) and for a twofold increase of the drives' moment of

inertia (parameter $K = 2$).




Fig. 5. Time plots of external disturbances under CL middle section control.




Fig. 6. Time plot of velocity v_2 control in CL middle section.




Fig. 7. Time plot of tension control of CL middle section.




Fig. 8. Time plot of velocity v_2 control in CL middle section for $K_t = 0.2 \times K_{tN}$ and $J = 2 \times J_N$.




Fig. 9. Time plot of CL middle section tension control for $K_t = 0.2 \times K_{tN}$ and $J = 2 \times J_N$.

Similarly, Fig. 10 and Fig. 11 show the dynamics of speed and tension control for the case when damping of the web of material in the line was increased fivefold, and there was a twofold reduction of the drives' moment of inertia (parameter $K = 2$). In view of the real world operation of the line these are significant and boundary changes of values of the parameters under consideration. In both cases external disturbances exert their influence on the line before and after the considered section of the line, as illustrated in Fig. 5. It is clear from the quoted figures that the dynamics, autonomy and invariance of tension control practically did not change with the significant change of the parameters considered, which fact points at the strong robustness of the proposed controller.




Fig. 10. Time plot of velocity v_2 control in CL middle section for $K_t = 5 \times K_{tN}$ and $J = 0.5 \times J_N$.




Fig. 11. Time plot of CL middle section tension control for $K_t = 5 \times K_{tN}$ and $J = 0.5 \times J_N$.

In order to tackle the problem of robust tension control, various methods (H_{∞} , optimal control) are described in the literature. These methods lead to relatively complex control

structures and complicated computations of their parameters, and their main disadvantage lies in the fact that they can secure robustness of control only for a certain limited range of changes of these parameters [11]–[14], and the decoupling of the individual subsystems (autonomy) is solved by the application of various types of correction networks [15]–[17]. On the other hand, the control structure proposed in this paper is very simple, and there is no need for a mathematical model of the system for the calculation of the controller parameters (20). The dynamical properties of tension setting are in general prescribed by a linear reference model in state space (2), and stability is secured by computing the parameters (the elements of positive definite matrix \mathbf{P}) using the Lyapunov matrix (15) and by choosing a positive parameter K .

Based on the results of the proposed control structure verification, it is possible to state that the control structure is stable and strongly robust, and autonomy of the CL output quantities, the desired dynamics and invariance to the influence of additive disturbances are secured.

Controller synthesis requires data about all state quantities of the controlled system, which is the main disadvantage of the proposed stable control structure. However, the state quantities can be obtained either by measurement or from various types of observers.

VI. CONCLUSION

The paper deals with the design and verification of a new stable control structure with reference model for the control of tension in the middle section of a continuous processing line. The basic idea lies in generating additional information (a new suitable state variable) into the controlled system that would enable the achievement of zero control deviation in steady state. The controller is then designed as such that would secure asymptotic stability of the extended system and by this automatically also zero control deviation based on the application of principles of the second Lyapunov method.

As regards control of the continuous line output quantities (tension and speed), the control is decentralized, because the speed and tension subsystems of the line were considered as independent systems and the coupling between them was regarded as a disturbance. The controller for each subsystem was then designed independently.

The properties of the proposed control structure were verified by simulation. The main advantage of the proposed control structure is its strong robustness over a wide range of changes of significant parameters of the controlled system, together with fulfilment of other defined objectives of control of such dynamical systems, i.e. invariance and desired dynamics prescribed by the reference model both in transient and in steady states. What is more, the Lyapunov synthesis tools guarantee the stability of the whole controlled system.

The proposed control strategy is very simple, the obtained simulation results have shown it to be effective for tension control in continuous lines and applicable also in other types

of nonlinear systems of similar structure, and therefore it is possible to assume its wide application in industrial practice.

APPENDIX A

Parameters of CL used for simulation:

A. DC motors

$U_N = 24$ V, $n_N = 3650$ rpm-s, $R_a = 0.7$ Ω , $I_N = 8.5$ A, $P_N = 140$ W, $J = 0.002$ kgm², $M_N = 0.37$ Nm, $L_a = 0.1$ mH, $j = 24$, $c\phi = 0.043$ Vs, $v_{\max} = 0.6$ ms⁻¹, $I_{\max} = 20$ A, $F_{12N} = 25$ N, $K_{RI} = 1$ V/A (current sensor).

B. Processed material

$b = 0.03$ m, $h = 0.1 \cdot 10^{-3}$ m, $S = bh = 3 \cdot 10^{-6}$, $E = 1.8 \cdot 10^9$ Nm⁻², $SE = 5400$ N, $T_{12} = 2.25$ s, $l_{12} = 1.35$ m,

$$K_t N = \frac{Jj^2}{T_{12} 2r^2} = 160 \text{ kgs}^{-1}.$$

C. Work rolls

$r = 0.04$ m.

D. Reference model

$\alpha = 5$.

E. Parameters of PI controller of velocity v_2

$K_p = 20$, $K_I = 2$.

ACKNOWLEDGMENT

This work was supported by the Slovak Research and Development Agency under the contract No. APVV-16-0206

REFERENCES

- [1] J. Zilkova, P. Girovsky, M. Batmend, "Modelling the technological part of a line by use of neural networks", *Advances in Intelligent Systems and Computing*, vol. 239, pp. 349–358, 2014. DOI: 10.1007/978-3-319-01854-6_36.
- [2] J. Li, S. H. Liu, L. J. Cai, "Coupling model and controller design for four-layer register system", in *Proc. Int. Conf. Mechatronics, Manufacturing and Materials Engineering (MMME 2016), MATEC Web of Conferences*, 2016. [Online]. DOI: 10.1051/04023.
- [3] R. N. Norris, "Sectional electric drive for paper machines", *Trans. American Institute of Electrical Engineers*, vol. XLV, pp. 496–511, 2009. DOI: 10.1109/JAIEE.1926.6537596.
- [4] M. Valenzuela, J. Bentley, R. Lorenz, "Evaluation of torsional oscillations in paper machine sections", *IEEE Trans. Industry Applications*, vol. 41, no. 2, pp. 493–501, 2005. DOI: 10.1109/TIA.2005.844383.
- [5] X. Q. Shi, D. E. Davison, R. Kwong, E. J. Davison, "Optimized decentralized control of large scale systems", in *Proc. 12th IEEE Int. Conf. Control and Automation (ICCA)*, 2016. DOI: 10.1109/ICCA.2016.7505264.
- [6] P. R. Pagilla, N. B. Siraskar, R. V. Divedula, "Decentralized control of web processing lines", *IEEE Trans. Control Systems Technology*, vol. 15, no. 1, pp. 106–117, 2007. DOI: 10.1109/TCST.2006.883345.
- [7] N. H. Priya, P. Kavitha, N. M. S. Srinivasan, K. Ramkumar, "Design of PSO-based PI controller for tension control in web transport systems", in *Proc. Int. Conf. Soft Computing Systems*, 2015, pp. 509–516. DOI: 10.1007/978-81-322-2674-1_47.
- [8] B. Allaoua, A. Laoufi, B. Gasbaoui, "Multi-drive paper system control based on multi-input multi-output PID controller", *Leonardo Journal of Sciences*, vol. 16, pp. 59–70, 2010.
- [9] B. Bouchiba, A. Hazzab, H. Glaoui, F. Med-Karim, I. K. Bousserhane, P. Sicard, "Decentralized PI controller for multimotors web winding system", *Journal of Automation, Mobile Robotics & Intelligent Systems*, vol. 6, no. 2, pp. 32–36, 2012.
- [10] B. Jefteniu, M. Bebiu, S. Statkiu, "Controlled multi-motor drive", in *Proc. Int. Symposium on Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM 2006)*, IEEE, 2006.
- [11] H. Koc, D. Knittel, M. de Mathelin, G. Abba, "Modeling and robust control of winding systems for elastic webs", *IEEE Trans. Control Systems Technology*, vol. 10, no. 2, pp. 197–208, 2002. DOI: 10.1109/87.987065.
- [12] A. Benlatreche, D. Knittel, E. Ostertag, "Robust decentralized control strategies for large-scale web handling systems", *Control Engineering Practice*, vol. 16, no. 6, pp. 736–750, 2008. DOI: 10.1016/j.conengprac.2006.03.003.
- [13] G. T. Lee, J. M. Shin, H. M. Kim, J. S. Kim, "A web tension control strategy for multi-span web transport systems in annealing furnace", *ISIJ International*, vol. 50, no. 6, pp. 854–863, 2010. DOI: 10.2355/isijinternational.50.854.
- [14] N. Giannoccaro, T. Nishida, T. Sakamoto, "Decentralized H ∞ based control of a web transport system", in *Proc. of the 18th IFAC World Congress*, Milano (Italy), pp. 8651–8656, 2011. DOI: 10.3182/20110828-6-IT-1002.01284.
- [15] B. Shafiei, M. Ekramian, K. Shojaei, "Robust tension control of strip for 5-stand tandem cold mills", *Journal of Engineering*, 13 pages, 2014. DOI: 10.1155/2014/409014.
- [16] X. Zhang, Q. Zhang, "Robust control of strip tension for tandem cold rolling mill", in *Proc. 30th Chinese Control Conf. (CCC 2011)*, pp. 2390–2393, 2011.
- [17] H. R. Koofgar, F. Sheikholeslam, S. Hosseinnia, "Unified gauge-tension control in cold rolling mills: a robust regulation technique", *International Journal of Precision Engineering and Manufacturing*, vol. 12, no. 3, pp. 393–403, 2011. DOI: 10.1007/s12541-011-0051-6.
- [18] P. R. Pagilla, N. B. Siraskar, R. V. Divedula, "Decentralized control of web processing lines", *IEEE Trans. Control Systems Technology*, vol. 15, no. 1, pp. 106–117, 2007. DOI: 10.1109/TCST.2006.883345.
- [19] W. Zhao, X. Ren, "Adaptive robust control for four-motor driving servo system with uncertain nonlinearities", *Control Theory and Technology*, vol. 15, no. 1, pp. 45–57, 2017. DOI: 10.1007/s11768-017-5120-7.
- [20] S. Tan, L. Wang, J. Liu, "Research on decoupling method of thickness and tension control in rolling process", in *Proc. IEEE 11th World Congress on Intelligent Control and Automation (WCICA 2014)*, pp. 4715–4717, 2014. DOI: 10.1109/WCICA.2014.7053510.
- [21] G. Pin, V. Francesconi, F. A. Cuzzola, T. Parisini, "Adaptive task-space metal strip-flatness control in cold multi-roll mill stands", *Journal of Process Control*, vol. 23, no. 2, pp. 108–119, 2013. DOI: 10.1016/j.jprocont.2012.08.008.
- [22] K. C. Lin, "Observer-based tension feedback control with friction and inertia compensation", *IEEE Trans. on Control Systems Technology*, vol. 11, no. 1, pp. 109–118, 2003. DOI: 10.1109/TCST.2002.806464.
- [23] S. H. Song, S. K. Sul, "A new tension controller for continuous strip processing line", *IEEE Trans. Industry Applications*, vol. 36, no. 2, pp. 633–639, 2000. DOI: 10.1109/28.833782.
- [24] A. Angermann, M. Aicher, D. Schroder, "Time optimal tension control for processing plants with continuous moving webs", in *IEEE 35th Annual Meeting-IEEE Industry Applications Conf.*, 1999. DOI: 10.1109/IAS.2000.882671.
- [25] H. Butler, *Model reference adaptive control: from theory to practice*. Prentice Hall, 1992, pp. 80–113.
- [26] I. Landau, *Adaptive Control*. London: Springer, 2011, pp. 523–541. DOI: 10.1007/978-0-85729-664-1_16.
- [27] M. Orsag, C. Korpela, S. Bogdan, P. Oh, "Lyapunov based model reference adaptive control for aerial manipulation", in *Proc. Int. Conf. Unmanned Aircraft Systems (ICUAS)*, 2013, pp. 966–973. DOI: 10.1109/ICUAS.2013.6564783.

- [28] T. Minan, J. Cao, Y. Xiaoxiao, W. Xiaoming, G. Baohui, "Model reference adaptive control based on Lyapunov stability theory", in *Proc. 26th Chinese Control and Decision Conf. (CCDC 2014)*, 2014, pp. 1828–1833, DOI: 10.1109/CCDC.2014.6852467.
- [29] M. Sassano, A. Astolfi, "Dynamic Lyapunov functions", *Automatica*, vol. 49, no. 4, pp. 1056–1067, 2013. DOI: 10.1016/j.automatica.2013.01.027.
- [30] V. Lakshmikantham, "Advances in stability theory of Lyapunov: Old and new", *Systems Analysis Modelling Simulation*, vol. 37, no. 4, pp. 407–416, 2000.
- [31] W. He, Ch. Sun, S. S. Ge, "Top tension control of a flexible marine riser by using integral-barrier Lyapunov function", *IEEE/ASME Trans. Mechatronics*, vol. 20, no. 2, pp. 497–505, 2015. DOI: 10.1109/TMECH.2014.2331713.
- [32] K. S. Narendra, L. S. Valavani, "A comparison of Lyapunov and hyperstability approaches to adaptive control of continuous systems", *IEEE Trans. on AC*, vol. 25, no. 2, pp. 243–247, 1980. DOI: 10.1109/TAC.1980.1102316.
- [33] A. M. Lyapunov, *Stability of Motion*. New-York & London: Academic Press, 1966.
- [34] G. Brandenburg, "Ein mathematisches modell für eine durchlaufende Stoffbahn in einen System angetriebener umschlungener Walzen", *Regelungstechnik und Prozess – datenverarbeitung*, vol. 21, no. 3, pp. 69–104, 1973. (in German).
- [35] D. Perdukova, P. Fedor, J. Timko, "Modern methods of complex drives control", *Acta Technica CSAV*, vol. 49, no. 1, pp. 31–45, 2004.
- [36] V. D. Furasov, *Ustojcivost' dvizenija, ocenki i stabilizacija*. Moskva: Nauka, 1977, pp. 213–220. (in Russian).

QuoVadis Research @ FEI

Vydavateľ: Technická univerzita v Košiciach Fakulta elektrotechniky a informatiky

Sídlo: Letná 9, 042 00 Košice

Elektronická adresa: <http://quovadis.fei.tuke.sk>

Periodicita: 2-krát ročne

Založenie časopisu: September 2018.

Jazyk: V časopise sú články v anglickom a slovenskom jazyku.

ISSN: