

Technická univerzita v Košiciach
Fakulta elektrotechniky a informatiky

QuoVadis Research @ FEI



ročník 2, číslo 2
September 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

Kompresné snímanie riedkych signálov s analýzou hlavných komponentov	
<i>Imrich Andráš, Ján Šaliga</i>	4-11
Modeling Player Experience in Digital Entertainment	
<i>Martin Čertický, Ján Vaščák</i>	11-21
Netradičné metódy rekonštrukcie pre kompresné snímanie EKG	
<i>Pavol Dolinský, Ján Šaliga</i>	21-28
Integrované širokopásmové senzorové systémy emitujúce M-postupnosti a ich vybrané aplikácie	
<i>Martin Kmec, Pavol Galajda</i>	28-34
Analysis of Electrophysical Processes in High Voltage Insulating Materials	
<i>Roman Cimbala, Lukáš Kruželák</i>	34-41
Návrh a experimentálne vyhodnotenie vlastností difúzneho bloku pre obrazové šifrovacie algoritmy	
<i>Jakub Oravec, Ján Turán, Ľuboš Ovseník</i>	41-47
Fuzzy Cognitive Maps for Control Tasks in Intelligent Space	
<i>Michal Puheim, Ján Vaščák</i>	47-59
Analysis and Forecasting of Electricity Prices on the Polish Power Exchange	
<i>Michal Kolcun, Karolina Rusek</i>	59-68
Modelovanie tém v textových prúdoch dát	
<i>Miroslav Smatana, Peter Butka</i>	68-74
Ampacity of overhead power lines	
<i>Michal Špes, Lubomír Beňa</i>	74-83
Hybridný systém na detekciu malvéru	
<i>Matúš Uchnár, Liberios Vokorokos</i>	83-96
Metódy analýzy vybraných typov medicínskych dát	
<i>Michal Vadovský, Ján Paralič</i>	96-109

Kompresné snímanie riedkych signálov s analýzou hlavných komponentov

Ing. Imrich András

Katedra elektroniky a multimediálnych telekomunikácií
Technická univerzita v Košiciach
Košice, Slovakia
imrich.andras@tuke.sk

prof. Ing. Ján Šaliga, PhD.

Katedra elektroniky a multimediálnych telekomunikácií
Technická univerzita v Košiciach
Košice, Slovakia
jan.saliga@tuke.sk

Abstrakt—Článok prezentuje spôsob snímania riedkeho signálu odobraním iba obmedzeného počtu vzoriek. Vzorkovanie a kompresia sú pritom vykonané v jednom kroku zvanom analógovo-informačný prevod. Pôvodný signál je obnovený z redukovaného záznamu s minimálnou stratou informácie. Popísaných je niekoľko metód analógovo informačného prevodu so zreteľom na výpočtovú náročnosť a implementáciu v existujúcich zariadeniach. Navrhnuté sú dve nové metódy analógovo informačného prevodu význačné svojou jednoduchosťou – priame podvzorkovanie a podvzorkovanie s integráciou. Navrhnuté metódy sú určené pre a testované pomocou signálov parametrov kvality vody, nameraných bezdrôtovou senzorovou sieťou. Kompresné snímanie umožňuje znížiť objem prenášaných dát o >80%, a to s minimom výpočtových operácií na meracej strane a zanedbateľným skreslením obnoveného signálu.

KLúčové slová—kompresné snímanie; analógovo-informačný prevod; riedky signál; kompresia signálu

Abstract—The article presents a way of capturing a sparse signal by taking only a limited number of samples. Sampling and compression are performed in one step called analog-to-information conversion. The original signal is restored from a reduced record with minimal loss of information. Several methods of analog-to-information conversion are described with regard to computational performance and implementation in existing devices. Two new methods of analog-to-information conversion are designed for their simplicity - direct subsampling and subsampling with integration. Designed methods are intended for and tested using water quality parameter signals measured by the wireless sensor network. Compressed sensing allows to reduce the volume of transmitted data by > 80%, with a minimum of computational operations on the measuring side and negligible distortion of the recovered signal.

Keywords—compressed sensing; analog-to-information conversion; sparse signal; signal compression

I. ÚVOD

Kompresné snímanie (KS) [1] predstavuje sľubnú metódu snímania signálov, ktorá sa neriadi Shannon-Kotelnikovou vzorkovacou teorémou a dovoľuje nasnímať signál menším počtom meraní. KS umožňuje u riedkych signálov použiť menšie vzorkovacie frekvencie, výsledkom čoho sú menšie

potrebné prenosové rýchlosti. Výhodou oproti tradičným kompresným metódam sú veľmi nízke, ak vôbec nejaké, nároky na dodatočné číslicové spracovanie signálu (ČSS). Kompresia je vykonaná priamo procesom vzorkovania a väčšina ČSS je presunutá na stranu rekonštrukcie. toto je výhodné napr. u bezdrôtových senzorových sietí (BSS), kde dostupný výpočtový výkon je obmedzený v senzorových uzloch, ale prakticky neobmedzený v základových staniciach. Mnoho metód KS sa navyše dá implementovať v existujúcich zariadeniach bez zmeny hardvéru [2]. Sústava KS je navyše intrinzičky imúnna voči strate dát [3] a prenášané dáta sú šifrované [4]. Od svojho predstavenia bolo KS otestované v BSS na meranie teploty [5], elektromagnetických emisií [6], biosignálov [7], videosignálov [8], zrýchlené MRI [9] atď.. Nepriame aplikácie teórie KS zahŕňajú decentralizovanú úschovu dát [10] či rozpoznávanie digitálnych modulácií [11].

Táto práca bola motivovaná nedostatkami BSS monitorujúcej kvalitu vody [12]. Senzorové uzly merajú viaceré signálov parametrov kvality vody (SPKV) ako teplotu, salinitu, pH atď. [13] – [15]. Uzly využívajú slnečnú energiu na nabíjanie integrovaného akumulátora, pričom väčšinu energie spotrebujú sondy a vysielateľ [16]. Problematickými sa ukazujú zimné mesiace, keď je dostupné len minimum slnečného žiarenia, solárny panel môže byť pokrytý námrazou a účinnosť batérie je obmedzená kvôli nízkym teplotám. Veľká úspora energie sa dá dosiahnuť znížením objemu dát, ktoré treba odoslať. Problémom u konvenčných kompresných metód ale je, že potrebujú značný počet shannonovských vzoriek aby boli účinné. Jednak nie je možná úspora energie pri samotnom vzorkovaní, a s terajšou vzorkovacou periódou 1 hodina by na kompresiu bol potrebný prídĺhý časový rámec. Pridaná výpočtová záťaž by navyše bola protichodná s úsporou energie na vysielateľ. Všetky tieto problémy sa dajú obísť pomocou kompresného snímania.

Tento článok demonštruje, že KS sa dá využiť na monitorovanie kvality vody a účinne implementovať v existujúcej BSS. Navrhnuté sú dve metódy vzorkovania doteraz nepoužívané v systéme KS. Kap. 2 obsahuje prehľad všeobecnej teórie KS. Vyšetrené metódy vzorkovania a ich vlastnosti sú popísané v kap. 3. Experimentálne výsledky sú uvedené v kap. 4, kde je vyhodnotená účinnosť navrhovaných metód. KS konfigurácia optimálna pre monitorovanie kvality vody je navrhnutá v závere kap. 4, nasledovanej záverom.

II. KOMPRESNÉ SNÍMANIE

Hlavným cieľom u KS je skoncentrovať signál do malého počtu vzoriek ktoré nesú všetku informáciu, čo sa nazýva analógovo-informačný prevod (AIP). Tieto komprimované vzorky sú prenášané na stranu rekonštrukcie, kde je obnovený pôvodný signál. Teoreticky je možná dokonalá bezstratová rekonštrukcia [1].

Aby sa KS dalo aplikovať, predpokladá sa že vstupný signál sa dá reprezentovať lineárnou kombináciou známych básových funkcií. Signál musí byť navyše riedky, t. z. skladá sa iba z malého počtu básových funkcií. Signál skladajúci sa z s básových funkcií nazvime s -riedky. Definujme L básových vektorov $\psi_l \in \mathbb{R}^{N \times 1}, 1 \leq l \leq L$ ktoré dokážu reprezentovať akýkoľvek očakávaný vstupný signál, a tvoria slovník $\Psi \in \mathbb{R}^{N \times L}$. Vstupný signál sa potom dá popísať ako

$$\mathbf{f} = \Psi \mathbf{x}, \tag{1}$$

kde $\mathbf{x} \in \mathbb{R}^{L \times 1}$ je kombinačný vektor.

A. Analógovo-informačná konverzia

Konvenčné analógovo-číslkové prevodníky (AČP) vzorkujú signál v ekvidistančných okamihoch podľa Shannon-Kotelnikovej vzorkovacej teóremy. U signálov, ktoré sú v určitej doméne riedke, takéto vzorkovanie znamená veľkú redundanciu v zázname – objem informácie obsiahnutej v riedkom signáli je obmedzený. AIP využíva tento fakt a odoberá len obmedzené množstvo vzoriek postačujúcich na vyjadrenie informácie. Vstupný signál $\mathbf{f} \in \mathbb{R}^{N \times 1}$ je korelovaný s $M < N$ meracími signálmi reprezentovanými M riadkami meracej matice $\Phi \in \mathbb{R}^{M \times N}$. Výsledkom takéhoto AIP je informačný signál

$$\mathbf{y} = \Phi \mathbf{f} \in \mathbb{R}^{M \times 1}. \tag{2}$$

AIP sa dá vykonať viacerými spôsobmi, buď analógovo, alebo číslkovo po shannonovskom vzorkovaní [17]. Analógové implementácie umožňujú prekonať limity rýchlych AČP a používané sú hlavne u vysokofrekvenčných signálov. Číslkový AIP je výpočtovo efektívnou alternatívou ku konvenčným kompresným metódam. Pokiaľ je to možné, preferuje sa priama (číslková) implementácia (2), absentujú pri nej totiž problémy s nedokonalosťami analógových obvodov. V literatúre sú najčastejšie popisované náhodná demodulácia (ND) a náhodné vzorkovanie (NV), ale pre špecifické aplikácie sa dajú použiť aj iné, špecifické metódy.

B. Rekonštrukcia

Majme vstupný signál s -riedky na slovníku Ψ , a nech slovník Ψ a meracia matica Φ sú nekoherentné (riadky ϕ_m matice Φ nereprezentujú stĺpce ψ_l slovníka Ψ a naopak). Ak $s < M \ll N$, vstupný signál sa dá obnoviť [18]. Aproximácia potrebného počtu informačných vzoriek je

$$M_{\min} = \mu s \log_{10}(N) \tag{3}$$

za predpokladu, že signál nie je zašumený. $\mu = 1$ pre nekoherentné matice, ale musí byť zvýšené na $\mu = L/N$ pokiaľ $N < L$. Dosadením (1) do (2) dostávame

$$\mathbf{y} = \Phi \Psi \mathbf{x}, \tag{4}$$

a pre prehľadnosť označme ako maticu rekonštrukcie

$$\mathbf{A} = \Phi \Psi \in \mathbb{R}^{M \times L}. \tag{5}$$

V KS systéme sú na strane prijímača známe informačný signál \mathbf{y} , a obe matice Ψ a Φ . Jedinou neznámou pri rekonštrukcii (1) je kombinačný vektor \mathbf{x} . Keďže \mathbf{A} je obdĺžniková matica, nedá sa jednoducho invertovať a je nutné riešiť podurčenú sústavu s M rovnicami a N neznámymi. Riešenie je možné nájsť iba ak je splnený predpoklad riedkosti vstupného signálu – správne riešenie je to, ktoré je najredšie [1].

Riedkosť s vektora \mathbf{x} sa dá charakterizovať jeho ℓ_1 normou definovanou ako

$$\ell_1 : \|\mathbf{x}\|_1 = \sum_{i=1}^n |x_i|. \tag{6}$$


Riedkosť predstavuje dodatočnú informáciu, ktorá je použitá pri návrhu meracieho procesu Φ . Rekonštrukcia sa vykoná riešením

$$\min \|\mathbf{x}\|_1 \text{ pri } \mathbf{A} \mathbf{x} = \mathbf{y}, \tag{7}$$

čo garantuje optimálne riešenie ak také existuje. Ešte efektívnejšie sa odhad pôvodného signálu dá nájsť ako

$$\hat{\mathbf{f}} = \Psi (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{y}, \tag{8}$$

kde $(*)^{-1}$ označuje pseudoinverznú maticu $*$. (8) zahŕňa riešenie ℓ_2 problému, le v praktických aplikáciách (7) a (8) vracajú rovnaké riešenia v medziach šumom danej neistoty [19].




Obr. 1. Systém kompresného snímania

Kritické je u KS určenie matíc Ψ a Φ . AIP musí byť vykonaný tak, že meracia matica má náhodné vlastnosti zaručujúce nekoherenciu so slovníkom. Slovník môže byť založený na modeli signálu ak je známy, napr. sínus-kosínus alebo wavelet. U iných signálov nie je takáto doména známa a vhodný slovník je nutné natréňovať. Správne zvolený slovník zaručí vysoký možný kompresný pomer a nízku chybu rekonštrukcie. Na extrakciu slovníka pre SPKV autori navrhujú analýzu hlavných komponentov (AHK) [20]. AHK je vo všeobecnosti výhodná u signálov, kde analytický model nie je známy alebo by vyžadoval priveľa parametrov. Nasadzuje sa vo významnej miere v biomedicínskych aplikáciách [21] – [24], a bola použitá i v rôznych aplikáciách KS [3], [7], [10], [25]. Schéma systému KS so stranou snímania a rekonštrukcie je na Obr. 1.

III. VYŠETROVANÉ MERACIE METÓDY A MATICE


A. Náhodná demodulácia

Metóda ND je asi najviac študovaná v literatúre. Funkčný diagram ND je na Obr. 2. Vstupný signál $f(t)$ je násobený postupnosťou $p(t)$ z generátora náhodnej postupnosti (GNP), nadobúdajúcou úrovne ± 1 . Výstup násobičky je integrovaný a výstup integrátora je periodicky vzorkovaný konvenčným AČP. Zakaždým po odobratí vzorky sa integrátor resetuje. Vzorkovacia frekvencia AČP je nižšia ako Shannonova frekvencia snímaného signálu. Na Nyquistovej frekvencii musia fungovať iba GNP a násobička, všetko ďalšie ČSS sa vykonáva po kompresii na nižších rýchlostiach. Samotná kompresia je vykonaná ešte v analógovej časti bez ČSS. Takáto konfigurácia umožňuje energeticky efektívnu kompresiu veľmi rýchlych signálov v reálnom čase.



Obr. 2. Analógová náhodná demodulácia

Hlavnou nevýhodou analógovej ND je potreba špecializovaných obvodov. Očakávaný merací proces Φ a skutočné chovanie ND obvodov sa môžu líšiť [26], výsledkom čoho je zvýšená chyba rekonštrukcie (8). Presné modelovanie fyzických obvodov [27] a ošetrenie neurčitostí [28], [29] môžu byť problematické. Ak nie je snímaný signál prírýchly, ND sa dá implementovať číslícovo ako je ukázané na Obr. 3. Výhodou je nižšia možná chyba rekonštrukcie, keďže jediným neideálnym článkom je vstupný AČP. U pomaly sa meniacich signálov ako sú SPKV je možné KS implementovať na existujúcich zariadeniach ako firmvérovú alebo softvérovú modifikáciu.



Obr. 3. Analógová náhodná demodulácia

Po navzorkovaní vstupného signálu konvenčným AČP na jeho diskretnu reprezentáciu f_n sú vzorky násobené náhodnou postupnosťou p_n skladajúcou sa z ± 1 a sčítané. Sumátor sa resetuje zakaždým keď sa odčíta akumulovaná hodnota. Všetko toto ČSS je vykonávané v reálnom čase, takže číslícová ND je skôr vhodná pre pomalé signály. Prvky $\varphi_{mn}, 1 \leq m \leq M, 1 \leq n \leq N$ meracej matice $\Phi \in \mathbb{R}^{M \times N}$ reprezentujúcej ideálnu alebo číslícovú ND sa dajú popísať ako

$$\varphi_{mn} = \begin{cases} p_n, & (m-1)C < n \leq mC \\ 0 & \end{cases}, \quad (9)$$

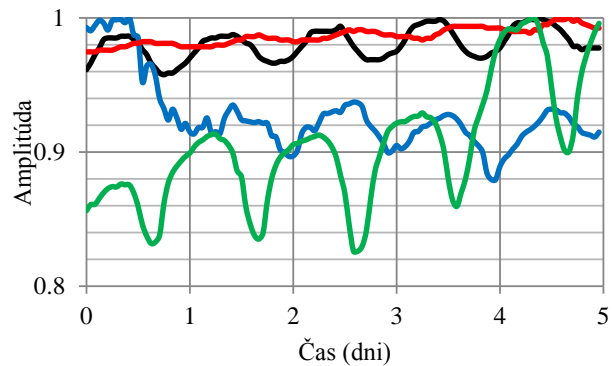
kde

$$C = \frac{N}{M} \in \mathbb{N} \quad (10)$$

je kompresný pomer.


B. Náhodné vzorkovanie

AIP architektúra s NV je jedna z implementačne najjednoduchších, pritom je však zriedka študovaná. NV sa dá realizovať buď spúšťaním AČP pomocou GNP alebo zahadzovaním vzoriek klasického AČP [30]. Obidva tieto spôsoby sú vhodné pre širokopásmové signály. Nie je nutné zvláštne analógové a prakticky žiadne ČSS. NV sa taktiež dá jednoducho implementovať na existujúcich zariadeniach bez zmien hardvéru, napriek všetkým týmto výhodám sa v literatúre častejšie vyskytuje ND, pravdepodobne kvôli obmedzenej použiteľnosti NV. U ND sa dosiahne nízka vzorkovacia frekvencia, ale informácia obsiahnutá v čase medzi vzorkami je zachovaná skrz integráciu. U NV je všetka táto informácia stratená, čo limituje NV na frekvenčne riedke signály s malou očakávanou variabilitou [31].



Obr. 4. Príklady nameraných signálov parametrov kvality vody

Typický SPKV (Obr. 4) sa skladá z pomaly sa meniacej DC zložky s vysokou amplitúdou, z pomerne malej striedavej zložky a prípadného šumu [32]. AC komponent je skreslená sínusoida so základnou periódou cca. 1 deň a niekoľkými vyššími harmonickými. SPKV teda nesie iba obmedzený informačný obsah a dá sa označiť za frekvenčne riedky [33], čím vyhovuje pre aplikáciu NV.



Obr. 5. Náhodné vzorkovanie

Zo všetkých shannonovských vzoriek vstupného signálu (1) sa náhodne vyberie podmnožina M vzoriek. Nech Ξ obsahuje indexy vybraných vzoriek

$$\Xi = \{\xi_1, \xi_2, \dots, \xi_M\}. \quad (11)$$

Prvky Ξ sú náhodné čísla podľa pravidiel

$$\forall m \in \mathbb{N}, 1 \leq m \leq M : \xi_m \in \mathbb{N}, 1 \leq \xi_m \leq N, \quad (12)$$

$$\forall i, j \in \mathbb{N}, 1 \leq i < j \leq M : \xi_i < \xi_j. \quad (13)$$

Prvky meracej matice reprezentujúcej AIP s NV sa dajú zapísať podľa (11) – (13) ako


$$\varphi_{mn} = \begin{cases} 1, n = \xi_m \\ 0 \end{cases} \quad (14)$$

z čoho vzorky informačného signálu (2) sú

$$y_m = f_{\xi_m}. \quad (15)$$

C. Priame podvzorkovanie

Koherentné priame podvzorkovanie (PPV) zatiaľ nebolo študované v kontexte KS zo zrejmých dôvodov. Rekonštrukcia s takýmto AIP vo všeobecnosti nie je možná kvôli aliasingu. Bázové funkcie SPKV získané pomocou AHK však nie sú striktné periodické funkcie. Prvky Ψ sú všeobecné funkcie, ako vidieť z Obr. 6.



Obr. 6. Najvýznamnejšie hlavné komponenty SPKV

Iba niektoré z hlavných komponentov pripomínajú sínusoidy s periódou cca 1 deň. Tieto už zahŕňajú bežnú kompozíciu vyšších harmonických a interharmonických. Vyššie harmonické teda síce podliehajú pri PPV aliasingu, ale vďaka charakteru hlavných komponentov je reverzibilný. Pôvodný signál sa dá obnoviť pokiaľ aspoň 1. harmonická je vzorkovaná v súlade so Shannon-Kotelnikovou vzorkovacou teorémou [34]. K nenávratnej strate informácie môže teoreticky dôjsť ak by niektorá z vyšších harmonických zložiek signálu bola presne rovná celočíselnému násobku použitej vzorkovacej frekvencie.

Prezentovaná štúdia uvažuje podvzorkovanie priamou decimáciou shannonovského záznamu, alebo vzorkovanie s AČP ktoré nevyhovuje Shannon-Kotelnikovej vzorkovacej teoréme a pritom nie je použitý antialiasingový filter. Korešpondujúca meracia matica sa skladá z prvkov

$$\varphi_{mn} = \begin{cases} 1, n = mC \\ 0 \end{cases}, \quad (16)$$


pomocou ktorej dostávame informačný signál

$$y_m = f_{mC}. \quad (17)$$

PPV je navrhnuté ako metóda AIP špecifická pre SPKV príp. podobné signály. Prednosťou tejto metódy je jednoduchosť, nie je však použiteľná univerzálne tak ako napr. ND. Implementácia PPV v existujúcich zariadeniach je ešte jednoduchšia ako NV, keďže nie je potrebný GNP. Ak použitý AČP má pevné hodiny, záznam sa dá decimovať. Lepšiu energetickú účinnosť bude mať AČP, ktorý bude spúšťaný s frekvenciou menšou ako Nyquistovou bez ďalšej potreby decimácie záznamu.

D. Podvzorkovanie s integráciou


Podvzorkovanie s integráciou (PVI) je navrhované ako ďalšia prípadová metóda AIP a je zjednosušenou alternatívou ku ND. Modulátor je možné vynechať, keďže SPKV reprezentuje absolútnu hodnotu chemických parametrov a je vždy jednosmerný. vstupný signál je počas vzorkovacej periódy integrovaný, ako je ukázané na Obr. 7. Integrátor je periodicky resetovaný po odčítaní akumulovanej hodnoty.



Obr. 7. Analógové podvzorkovanie s integráciou

Diskrétna implementácia PVI (Obr. 8) môže byť výhodná kvôli dôvodom spomenutým v 3.A. Meracia matica sa mení z (11) na

$$\varphi_{mn} = \begin{cases} 1, (m-1)C < n \leq mC \\ 0 \end{cases}. \quad (18)$$



Obr. 8. Diskrétné podvzorkovanie s integráciou

IV. VÝSLEDKY

Diskrétna implementácia metód z predchádzajúcej kapitoly boli otestované pomocou dát zaznamenaných počas pilotnej prevádzky BSS [13]. Testované metódy sa dajú implementovať v existujúcej BSS zmenou softvéru príp. firmvéru. Pri testovaní boli použité simulácie, ktoré však dostatočne presne reprezentujú implementáciu vo fyzickej BSS.


$L' = 200$ tréningových segmentov SPKV s dĺžkou $N = 120$ (5 dní) bolo náhodne vybraných z databázy SPKV a normalizovaných na jednotkovú amplitúdu. Tento tréningový súbor bol použitý na extrakciu slovníka $\Psi \in \mathbb{R}^{N \times L'}$ pomocou AHK. Súbor iných 200 segmentov SPKV bol náhodne vybraný na samotné testovanie. Na vyhodnotenie chyby rekonštrukcie je použitá miera SDR [34]

$$SDR = 10 \log \left(\frac{\sum_{n=1}^N \hat{f}_n^2}{\sum_{n=1}^N (f_n - \hat{f}_n)^2} \right), \quad (19)$$

kde \hat{f}_n je obnovený signál. Vo výsledkoch pre každý scenár budú uvedené priemerné SDR z rekonštrukcií všetkých testovacích segmentov SPKV. U ND a NV bolo navyše pre každý testovací segment vykonaných 10^3 meraní a rekonštrukcií, zakaždým s nanovo vygenerovanou meracou maticou.

A. Počet hlavných komponentov použitých pri rekoštrukcii

Zo všetkých L' extrahovaných hlavných komponentov iba obmedzený počet má nezanedbateľnú energiu. Zvyšné komponenty môžu byť vynechané z Ψ s minimálnym dopadom na výsledné SDR . Dosiadnuteľné SDR v závislosti od počtu hlavných komponentov v (1) sa dá nájsť s použitím jednotkovej meracej matice $\Phi = \mathbf{I}_N$ (žiadne prevzorkovanie) a následnou štandardnou rekonštrukciou (8) pri rôznych L .



Obr. 9. Dosiadnuteľné SDR ako funkcia počtu hlavných komponentov.


Dosiadnuteľné SDR sa zväčšuje s počtom hlavných komponentov. Pre každé $L \geq 52$ sa dá pozorovať dokonalá rekonštrukcia aspoň u jedného z testovacích signálov. Dokonalá rekonštrukcia znamená, že $f_n = \hat{f}_n$ v (19), výsledkom čoho je $SDR \rightarrow \infty$ pre $L \geq 52$. Väčšina SPKV je bez pozorovateľného šumu, vďaka čomu je dokonalá rekonštrukcia možná.

B. Vzorkovacia frekvencia

Skutočná hranica M potrebná pre úspešnú rekonštrukciu je diskutabilná a často diskutovaná. Analyticky odvodené vzťahy ako je (3) existujú, ale ich použitie v praxi nie je také jednoduché. Skutočná riedkosť signálu je dopredu neznáma, obzvlášť ak sa slovník skladá z numericky natrénovaných [20] všeobecných funkcií a vstupný signál degradovaný náhodným a kvantizačným šumom.

Akokoľvek analytické odvodenie M_{min} je založené na štatistike. Voľba $M < M_{min}$ neznamená že rekonštrukcia nie je možná, iba že je vysoké riziko odobratia práve takých vzoriek, že rekonštrukcia nebude úspešná. Najspoľahlivejším spôsobom vybratia vhodného M je experiment, kde je pozorovaná chyba

rekonštrukcie pri zmene M . Neznáme s na určitej báze Ψ sa dá určiť retroaktívne skúmaním \mathbf{x} u úspešných rekonštrukcií. SDR ako funkcia kompresného pomeru (12) pri rôznych metódach AIP je ukázaná na Obr. 10.

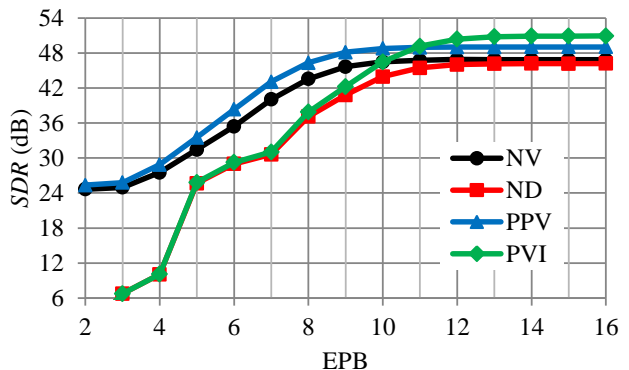


Obr. 10. Dosiadnuteľné SDR ako funkcia kompresného pomeru.

Úspešnosť všetkých testovaných metód je v závislosti od C podobná, rozdiel medzi metódami je v rozsahu 6dB SDR . Navrhnuté PVI dosahuje najvyššie SDR pri nízkom aj veľmi vysokom kompresnom pomere, ostatné metódy si vedú o niečo lepšie iba pri $C=12$. PPV môže byť preferované kvôli jednoduchosti, a to i napriek horším výsledkom pri veľkom C . Konečná voľba metódy AIP bude závisieť na potrebnom SDR .

C. Odolnosť voči kvantizácii

Vysoké rozlíšenie AČP, charakterizované efektívnym počtom bitov (EPB), je ľahko zabezpečiť a pomaľých signálov ako sú SPKV. Celkový objem dát ktorý je treba preniesť je ale úmerný EPB. Nižší EPB je prospešný pre celkovú energetickú účinnosť BSS, a dá sa znížiť kvantizáciou existujúcich vzoriek s vysokým rozlíšením. Vplyv kvantizácie na SDR bol skúmaný pomocou simulovaného ideálneho AČP s rozsahom 2. Výsledky pre $C=6$ a premenlivé rozlíšenie sú na Obr. 11.

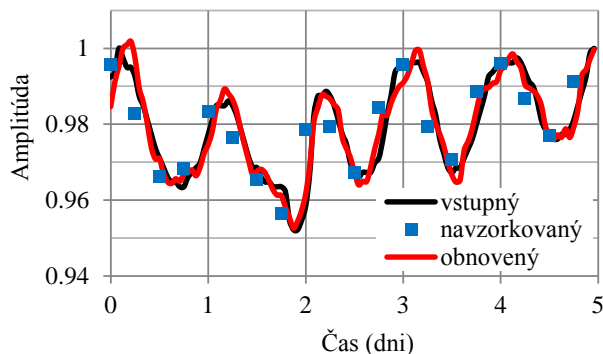


Obr. 11. Dosiadnuteľné SDR ako funkcia efektívneho počtu bitov.

NV a PPV vykazujú o niečo lepšiu odolnosť voči kvantizácii ako ND a PVI. Najvyššie SDR sa dá dosiahnuť u PVI, čo súhlasí s výsledkami z predchádzajúcej podkapitoly. Zvýšenie EPB nad 12 nevyvoláva zlepšenie SDR u žiadnej z testovaných metód AIP.

D. Požiadavky na chybu rekonštrukcie

Výsledky ukazujú že SDR je závislé od kompresného pomeru a kvantizačného šumu. Vzájomná kombinácia C a EPB určuje spotrebu energie, ktorá je úmerná SDR . Aké vysoké SDR je potrebné a či vzniknuté skreslenie je vôbec problémom musí rozhodnúť koncový používateľ. Experimenty ukazujú, že SDR nad 30dB stačí na zachytenie pomaly sa meniacej jednosmernej zložky ktoréhokoľvek SPKV. Aby ostali zachované aj najmenešie striedavé zložky prítomné v dostupnej databáze, je potrebné SDR nad 50dB.



Obr. 12. Príklad vstupného a obnoveného signálu, metóda PVI. $C=6$, $EPB=12$, $SDR=51.43dB$.

Autori navrhujú použiť PVI metódu AIP s $C=6$ a $EPB=12$. S takouto konfiguráciou bude objem vysielaných dát znížený o cca 80% pri zachovaní $SDR \geq 50dB$. Príklad vstupného a obnoveného signálu s $SDR = 51.43dB$ možno vidieť na Obr. 12.

V. ZÁVER

KS bolo pôvodne proklamované ako takmer optimálne a bezstratové. Praktické výsledky so SPKV však tvrdia že rekonštrukcia nie je dokonalá ak je použitý zmysluplný kompresný pomer. Podobné závery sa dajú nájsť aj u niektorej literatúry a pri iných aplikáciách, napr. biomedicínskych [7]. Rozumný kompresný pomer pri minimálnej výpočtovej náročnosti však robí z KS rozumnú voľbu pre BSS monitorujúcu kvalitu vody. NV a ND metódy AIP boli v minulosti použité v rôznych BSS a ukázali sa ako efektívne aj pre SPKV. Navrhované PPV a PVI sú výpočtovo a implementačne ešte jednoduchšie, pritom PVI dosahuje ešte lepšie výsledky ako osvedčené metódy AIP. Navrhnutá bola BSS konfigurácia, s ktorou dôjde k zníženiu spotreby senzorových uzlov až o 80%, a zostáva ju implementovať vo fyzických senzorových uzloch.

REFERENCES

- [1] Donoho, D. L. (2006). Compressed Sensing. *IEEE Transactions on Information Theory*, 52 (4), 1289 – 1306.
- [2] Andráš, I., Dolinský, P., Michaeli, L., Šaliga, J. (2018). A time domain reconstruction method of randomly sampled frequency sparse signal. *Measurement*, 127, 68-77.
- [3] Wu, L., Yu, K., Hu, Y., Wang, Z. (2014). CS-Based Framework for Sparse Signal Transmission over Lossy Link. In *IEEE International Conference on Mobile Ad Hoc and Sensor Systems*. Philadelphia, USA.
- [4] Liu, H., Xiao, D., Zhang, R., Zhang, Y., Bai, S. (2016). Robust and hierarchical watermarking of encrypted images based on Compressive Sensing. *Signal Processing: Image Communication*, 46, 41 – 51.
- [5] Xiao, X., He, Q., Fu, Z., Xu, M., Zhang, X. (2016). Applying CS and WSN methods for improving efficiency of frozen and chilled aquatic products monitoring system in cold chain logistics. *Food Control*, 60, 656 – 666.
- [6] Bellan, D., Pignari, S. A. (2015). Monitoring of Electromagnetic Environment along High-Speed railway Lines Based on Compressive Sensing. *Progress in Electromagnetics Research C*, 58, 183 – 191.
- [7] Craven, D., McGinley, B., Kilmartin, L., Glavin, M., Jones, E. (2016). Energy-efficient Compressed Sensing for ambulatory ECG monitoring. *Computers in Biology and Medicine*, 71, 1 – 13.
- [8] Angayarkanni, V., Radha, S. (2016). Design of Bandwidth Efficient Compressed Sensing Based Prediction Measurement Encoder for Video transmission in Wireless Sensor networks. *Wireless Personal Communications*, 87, 1 – 21.
- [9] Talari, A., Rahnavard, N. (2016). CStorage: Decentralized compressive data storage in wireless sensor networks. *Ad Hoc Networks*, 37, 475 – 485.
- [10] Zong, F., Eurydice, M. N., Galvosas, P. (2016). Fast reconstruction of highly undersampled MR images using one and two dimensional principal component analysis. *Magnetic Resonance Imaging*, 34, 227 – 238.
- [11] Sun, Z., Wang, S., Chen, X. (2016). Feature-Based Digital Modulation Recognition using Compressive Sampling. *Mobile Information Systems*, 10, 9754162.
- [12] Maceková, L., Žiga, M. (2014). The wireless sensor network concept for measurement of water quality in water streams. *Acta Electrotechnica et Informatica*, 14 (2), 60 – 67.
- [13] Šaliga, J., Žiga, M., Galajda, P., Drutarovský, M., Kocur, D., Maceková, L. (2015). Wireless sensor network for river water quality monitoring. In *XXI IMEKO World Congress "Measurement in Research and Industry"*, 30 August – 4 September 2015. Prague, Czech Republic.
- [14] Galajda, P., Drutarovský, M., Šaliga, J., Žiga, M., Maceková, L., Marchevský, S., Kocur, D. (2015). Sensor Node for the Remote River Quality Monitoring. In *Measurement 2015*, 25 – 28 May 2015 (pp. 313 - 316). Smolenice, Slovakia: Slovak Academy of Science.
- [15] Šaliga, J., Kocur, D., Galajda, P., Drutarovský, M., Macekova, L., Andráš, I., Michaeli, L. (2017). Multi-parametric Sensor Network for Water Quality Monitoring. In *IMEKO TC19 Workshop on Metrology for the Sea*, 11 – 13 October 2017. Naples, Italy.
- [16] Stojmenović, I. (2005). Energy Scavenging and Nontraditional Power Sources for Wireless Sensor Networks. In *Handbook of Sensor Networks: Algorithms and Architectures* (pp. 75 - 106). New Jersey, USA: John Wiley & Sons.
- [17] Daponte, P., De Vito, L., Rapuano, S., Tudosa, I. (2017). Analog-to-Information Converters in the Wideband RF Measurement for Aerospace Applications: Current Situation and Perspectives. *IEEE Instrumentation & Measurement Magazine*, 20 (1), 20 – 28.
- [18] Candes, E. J., Wakin, M. B. (2008). An Introduction to Compressive Sampling. *IEEE Signal Processing Magazine*, 25 (2), 21 – 30.
- [19] Fung, G., Mangasarian, O.L. (2011). Equivalence of minimal ℓ_0 and ℓ_p -norm solutions of linear equalities, inequalities and linear programs for sufficiently small p . *Journal of Optimization Theory and Applications*, 151 (1), 1-10.
- [20] Palese, L. L. (2018). A random version of principal component analysis in data clustering. *Computational Biology and Chemistry*, 73, 57 – 64.
- [21] Phniomark, A., Hu, H., Phukpattaranont, P., Limsakul, C., (2012). Application of Linear Discriminant Analysis in Dimensionality Reduction for Hand Motion Classification. *Measurement Science Review*, 12 (3), 82 – 89.
- [22] Ji, Y., Sun, S., Xie, H. B., (2017). Stationary Wavelet-based Two-directional Two-dimensional Principal Component Analysis for EMG Signal Classification. *Measurement Science Review*, 17 (3), 117 – 124.

- [23] Oesterlein, T. G., Lenis, G., Luik, A., Verma, B., Schmitt, C., Dossel, O., (2014). Removing ventricular Far Field Artifacts in Intracardiac Electrograms during Stable Atrial Flutter using the Periodic Component Analysis – Proof of Concept Study. *Electrocardiology 2014 – Proceedings of 41th International Congress on Electrocardiology*, 49 – 52.
- [24] Rošťáková, Z., Rosipal, R., (2018). Time Alignment as a Necessary Step in the Analysis of Sleep Probabilistic Curves. *Measurement Science Review*, 18 (1), 1 – 6.
- [25] Huang, H., Ouyang, H., Gao, H., Guo, L., Li, D., Wen, J., (2016). A Feature Extraction Method for Vibration Signal of Bearing Incipient Degradation. *Measurement Science Review*, 16 (3), 149 – 159.
- [26] Abari, O., Lim, F., Chen, F., Stojanović, V. (2013). Why Analog-to-Information Converters Suffer in High-Bandwidth Sparse Signal Applications. *IEEE Transactions on Circuits and Systems – I: Regular papers*, 60 (9), 2273 – 2284.
- [27] Daponte, P., De Vito, L., Iadarola, G., Iovini, M., Rapuano, S. (2016). Experimental comparison of two mathematical models for Analog-to-Information Converters. In 21st IMEKO International Symposium 19th International Workshop on ADC Modelling and Testing, September 2016 (pp. 65 -70). Budapest, Hungary.
- [28] Daponte, P., De Vito, L., Iadarola, G., Rapuano, S. (2016). PRBS non-idealities affecting Random Demodulation Analog-to-Information Converters. In 21st IMEKO International Symposium 19th International Workshop on ADC Modelling and Testing, September 2016 (pp. 71 - 76). Budapest, Hungary.
- [29] Daponte, P., De Vito, L., Iadarola, G., Rapuano, S. (2016). Effects of PRBS Jitter on Random Demodulation Analog-to-Information Converters. In 2016 IEEE Metrology for Aerospace. Florence, Italy.
- [30] Candes, E., Becker, S. (2013). Compressive sensing: Principles and Hardware implementations. *2013 Proceedings of the ESSCIRC*, 22 – 23.
- [31] Wakin, M., Becker, S., Nakamura, E., Grant, M., Sovero, E., Ching, D., Yoo, J. (2012). A Non-Uniform Sampler for Wideband Spectrally-Sparse Environments. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 2 (3), 516 – 529.
- [32] WSN-AQUA Wireless Sensor Network for water Quality Monitoring (2015). <http://husk.fei.tuke.sk>, Online: 2018/21/08.
- [33] Lopes, M. E. (2013). Estimating Unknown Sparsity in Compressed Sensing. In International Conference on Machine Learning (ICML) 2013.
- [34] Andráš, I., Dolinský, P., Michaeli, L., Šaliga, J., (2018). Sparse Signal Acquisition via Compressed Sensing and Principal Component Analysis. *Measurement Science Review*, vol. 18, no. 5 (2018), pp. 175-182. ISSN 1335-8871.

Modeling Player Experience in Digital Entertainment

Martin Čertický

Technical University in Košice
Department of Cybernetics and Artificial Intelligence
Letná 9, 040 01 Košice, Slovakia
Email: mcerticky@gmail.com

Ján Vaščák

Technical University in Košice
Department of Cybernetics and Artificial Intelligence
Letná 9, 040 01 Košice, Slovakia
Email: jan.vascak@tuke.sk

Abstract—Analyses of user experience in the digital entertainment industry currently rely on self-reporting methods, such as surveys, ratings, focus group interviews, etc. We argue that self-reporting alone carries inherent problems – mainly the misinterpretation and temporal delay during longer experiments – and therefore should not be used as a sole metric. To tackle this problem, we propose the possibility of modeling consumer experience using psychophysiological measures and demonstrate how such models can be trained using machine learning methods. Models trained exclusively on real-time data produced by the autonomic nervous system and involuntary physiological responses are much less susceptible to imprecision caused by the delay between the experience and the interview. Multiple psychophysiological measures, such as heart rate, electrodermal activity, electroencephalography, and respiratory activity have been used in combination with self-reporting to prepare training sets for machine learning algorithms. The training data was collected from 31 participants during hour-long experiment sessions, where they played multiple video-games. Afterward, we trained and compared results of 4 different machine learning regression (random forest & neural network) and classification (random forest & random jungle) models, out of which the best one produced 96% accuracy. Additionally, we provide a reduced subset of correlating psychophysiological features required to model enjoyment levels using machine learning models. The results suggest that psychophysiological measures can indeed be used to assess the enjoyment level of digital entertainment consumers.

Keywords: machine learning; psychophysiological measures; user experience; modeling; random forest; random jungle; neural network; classification; regression; digital entertainment; enjoyment; heart rate; respiratory activity; electroencephalography; galvanic skin response.

Abstrakt—Analýza user experience v oblasti digitálnej zábavy momentálne zahŕňa najmä metódy postavené na subjektívnom sebahodnotení, ako prieskumy, dotazníky, pokusné skupiny, interview atď. Tvrdíme, že tieto metódy so sebou prinášajú nevyhnutelné problémy - najmä nesprávne interpretácie pojmov a časové oneskorenie (temporal delay) pri dlhotrvajúcich experimentoch - a preto by nemali byť používané ako jediná metrika hodnotenia user experience. Ako riešenie tohoto problému navrhujeme možnosť využitia modelovania user experience pomocou kombinácie metód strojového učenia a psychofyziologických meraní. Modely trénované výhradne pomocou dát produkovaných autonómnou nervovou sústavou a mimovoľne ovládanými fyziologickými indikátormi sú menej náchylné na vyššie spomínané nedostatky spojené so zaužívanými spôsobmi merania user experience.

Takéto modely zároveň znižujú riziko nepresností vzniknutých v čase medzi hrou a samotným hodnotením. Na získanie trénovacej množiny dát pre naše modely sme použili kombináciu psychofyziologických príznakov ako srdcový tep, elektrodermálnu aktivitu, elektroencefalografiu a respiračnú aktivitu spolu so subjektívnym seba-hodnotením účastníkov experimentov. Tieto dáta boli nahraté od 31 účastníkov počas cca. hodinu trvajúcich experimentov, počas ktorých hrali rôzne počítačové hry. Následne sme trénovali a porovnali výsledky 4 rôznych klasifikačných a regresných modelov, z ktorých najlepší dosiahol presnosť 96%. Nakoniec sme vytvorili podmnožinu príznakov, ktoré najviac vplývali na výsledky jednotlivých modelov, a teda poukazujeme na ich koreláciu s user experience v oblasti digitálnej zábavy. Spomínané výsledky naznačujú, že psychofyziologické príznaky sú užitočným nástrojom pre budúce iterácie spôsobu merania user experience v tejto oblasti.

Kľúčové Slová: strojové učenie; psychofyziologické príznaky; user experience; modelovanie; random forest; random jungle; neuronová sieť; klasifikácia; regresia; digitálna zábava; srdcový tep; respiračná aktivita; elektroencefalografia; elektrodermálna aktivita.

I. INTRODUCTION

Electronic entertainment (EE) industry has undergone extensive growth over the past decade. In the USA alone (a country with the biggest video-game market in the world) the sales went from \$7.3 billion in 2006 to \$23.5 billion spent in the game industry in 2015. The global value of the video-game industry is estimated to reach \$120 billion by 2019 [1]. Yet the assessment of user experience in video-games is still done using primarily self-report techniques, such as questionnaires and interviews [2].

We propose a new approach to assessing players' experience (in particular their enjoyment) that might mitigate some disadvantages of self-report techniques, such as emotional bias, misinterpretation or temporal delay between the experience and the reporting.

Based on the assumption that psychophysiological measures, such as heart rate, electrodermal activity or respiratory activity, correlate with user experience, we suggest combining them with the player's self-reports to create machine learning-based model of the player's enjoyment. A well-trained model will allow game developers to obtain high-quality data about players' emotions during particular in-game events without the questionnaires.

In order to test this approach, we performed a collection of experiments with real participants, trained four different machine learning models and compared their performance. The results seem to confirm the validity of this technique. We also provide an overview of several types of related psychophysiological measures, along with a very brief biological background and a hardware that can be used to collect them. Finally, we published an anonymized version of our dataset for further research on the sub

II. STATE OF THE ART

Numerous definitions of the term user experience have been proposed up to this day [3], [4], [5], [6]. In 2008, Haasenzahl described the user experience as an umbrella term used to stimulate research in HCI (human-computer interaction) to focus on aspects which are beyond usability and its task-oriented instrumental values [7]. A survey book focusing on game user experience from 2015 by Bernhaupt lists different definitions of user experience and it also provides an overview of different evaluation methods applicable to particular game development phases [2]. One of the terms connected closely to digital entertainment and our research is enjoyment. While social research on the motivational appeal of video games is still sparse [8], there is some indication that resolving game tasks and mastering game challenges is closely connected to game enjoyment. In 2011, Tamborini et al. conducted two studies, replicating and extending [9] and [10] to provide empirical support for a definition of enjoyment as the satisfaction of both hedonic (arousal, absorption and affect) and nonhedonic (competence, autonomy, and relatedness) needs [11].

Kivikangas et al. reviewed many scientific research papers concerning the use of psychophysiological measures in video-games [12]. The review investigated various types of psychophysiological metrics, pros and cons of their research and particular causes of changes in the subject's psychophysiological states. Another study relevant to our research is the work of Drachen et al. who studied correlations between self-reporting and psychophysiological measures [13]. In their research, they used iGEQ (In-Game Experience Questionnaire) as a self-reporting method in combination with heart rate and electrodermal activity measurement. The In-Game Experience Questionnaire (iGEQ) is a self-report scale for the exploration of the participant's experience during playing a computer game [14]. They found statistically significant correlations between HR/EDA and iGEQ dimensions, although with different patterns of covariance. In 2010, Drachen focused on the effects of particular game genres on the subject's physiological states [15]. The importance of game genre within our research is discussed in Section III. Further research of psychophysiological responses in video-games has focused on studying various effects of game genre and specific situations on the subject's psychophysiological states. For instance, Ballard and Wiest studied the effects of violent video-games on the hostility and cardiovascular responses of males [16]. Similar studies were conducted with movies. Codispoti et al. investigated various reactions to emotional movies with

an emphasis on the subject's gender [17]. With a subject sample of 33 females and 27 males, they investigated the cardiac response to highly arousing pleasant and unpleasant films. Based on the correlations found, they concluded that both pleasant and unpleasant movies prompt similar cardiac deceleration. The results of these experiments suggest that there indeed exists a correlation between psychophysiological indicators and the experience and emotions of EE consumers, but the relation to their enjoyment, in particular, is not trivial.

The connection between psychophysiological measures and specific emotions was studied by Mandryk et al., who monitored multiple indicators of subjects playing against computer-controlled opponents, as well as other co-located players:

- EKG (Cardiovascular measures)
- HR (Heart Rate)
- GSR (Galvanic Skin Response)
- EMG (Electromyography)
- Resp Rate (Respiratory Rate)
- RespAmp (Respiratory Amplitude)

Afterward they were able to compile a list of possible correlations between particular psychophysiological measures and subjective responses [18]:

- **Fun** significantly correlated with **GSR**.
- **Boredom** correlated with **EMG**.
- **Challenge** correlated linearly with **RespAmp** and **EMG**.
- **Ease** also correlated linearly with **RespAmp** and **EMG**.
- **Frustration** significantly correlated with **GSR** and **RespRate**.

Other publications addressed the correlation problem of psychophysiological measures with similar results. Drachen, Nacke, Yannanakis, and Petersen have produced several papers in the field, indicating how various emotions affect the psychophysiological measures of subjects. In 2009, their results indicated that HR as a measure of arousal is a good correlator with self-report measures of player experience, both positive and negative [13], [19]. Going deeper into the topic, in 2010 they found that higher HR average is indicative of players feeling tense and frustrated. In general, a low HR average indicates positive affect, achieving the flow-state, feelings of competence and immersion and low levels of challenge [15].

III. USER EXPERIENCE EVALUATION IN VIDEO-GAMES

Nowadays, without using physiology, there is a limited number of methods used for assessing user experience in games: behavioral observation, interviews, questionnaires, focus groups or heuristic, and game metrics evaluation [2]. These methods (excluding game metrics and heuristic evaluations) come with inherent problems, such as the subject's bias and interpretation difficulties. For example, while questionnaires provide a quick way to obtain quantitative insights into player feelings and attitudes, they lack the depth of an interview or the objectivity of metrical measures. They also work most reliably when a large number of people are available for testing [2].

We feel that the game development process might benefit from being able to evaluate specific parts of the product

(such as game levels or movie scenes) in a more reliable and automated manner. We propose a solution combining the subject's self-reports with involuntary responses of the autonomous nervous system (ANS), which are impervious to personal bias and provide the data immediately. Similar to 2013's work of Martinez et al. [20], our research focuses on using one-dimensional time-series input signals such as an electroencephalograph (EEG), electromyograph (EMG) and galvanic skin response (GSR) for modeling user experience in video-games. This kind of data was used as an input for a machine learning based model trained to predict the player's enjoyment.

When evaluating user experience in video-games using automated methods, certain challenges inherent to individual types of games had to be taken into consideration:

A. *Single-player*

Single-player games provide a clear view of how various game events and situations affect the player's psychophysiological state (in comparison with multi-player games). Lacking the social aspect of the game makes players less distracted and more focused on the gameplay than playing with other people. Single-player games provide a straightforward opportunity to use data for the evaluation of individual levels of the game. Unlike in multi-player games, players encounter similar situations throughout the gameplay, which, for example, may provide information on what sections of a particular level are the most (or least) entertaining. In 2011, Hainey et al. discussed motivation differences in single-player and multi-player games [21].

B. *Multi-player*

Multi-player format seems to be more challenging for the user experience evaluation process. Players are set into the same game environment repeatedly, however, the gameplay itself is rarely similar to the previous attempts. In addition, different player compositions create a dynamic setting which makes measurements considerably more difficult than in the single-player format.

Furthermore, there are multiple different potentially important influences which could be considered. Game genre, social aspects of the game, player's sociodemography, or even the combination of all these aspects can have a significant effect on player's responses. For example, while playing a single-player game, the player's experience is not influenced by the behavior or the performance of their teammates or opponents. In contrast, many multi-player games encourage their players to communicate with their teammates to simulate real-life battlefield experience or to improve their cooperation skills during gameplay. After an initial set of experiments with multi-player games (described in Section V), we have decided to focus on single-player games to prevent any unnecessary interference during later gameplay sessions.

IV. PSYCHOPHYSIOLOGICAL MEASURES

Any research method in which the dependent variable is a physiological measure and the independent variable is beha-


vioral or mental (such as memory) is a psychophysiological method. Physiological measures take many forms and range from blood flow or neural activity in the brain to heart rate variability and eye movements. These measures can provide information about processes including emotion and cognition, as well as interactions between them. Physiological measures thus offer a very flexible set of tools for researchers to answer questions about behavior, cognition, and health [22].

All the measures used in our research are parts of the human nervous system, more specifically the autonomic nervous system (ANS), which controls involuntary physiological responses. Measures controlled by the ANS function automatically. Therefore, they can not be affected or controlled consciously, which reduces the risk of unsuccessful experiments or imprecise results. We believe that a combination of traditional techniques with psychophysiological measures will provide a reliable insight into the player experience. Although there is no prior verification of reliability of such a combination, interviews and questionnaires are currently the only way to evaluate the player experience, and therefore the only way to create our model. This section provides a short introduction into the ANS and psychophysiological measures used in our work.

The ANS is comprised of two branches: the sympathetic nervous system (SNS) and the parasympathetic nervous system (PSNS). The easiest way to distinguish differences between these two branches is to associate "fight or flight" responses with the SNS, and "rest and digest" responses with the PSNS. In this manner, the SNS is responsible for "exciting" the body in stressful environments (e.g. competition), and does so by stimulating the responses shown in Figure 1. More specifically, by stimulating the secretion of adrenaline and noradrenaline, otherwise known as epinephrine and norepinephrine, the SNS prepares the body for stress. More relevantly, the SNS also increases heart rate, the force of contraction, and blood pressure, leading to an increased blood flow to the muscles [23]. Therefore, any time the subject feels an "adrenaline rush" before a stressful activity, this is essentially the SNS being stimulated and preparing the subject for competition. In contrast, the PSNS does the opposite and it is responsible for reducing heart rate and blood pressure in the absence of stress. Essentially, the PSNS helps facilitate recovery after a stressful event (e.g. competition) by counteracting the effects of the SNS [23]. To put it simply, the SNS increases heart rate and blood flow to the muscles, whilst the PSNS reduces heart rate and peripheral blood flow - in effect, they counteract one another.

A. *Traditional methods of psychophysiological state assessment (self-report)*

As addressed in Section III, self-reporting of user experience using traditional methods was used in numerous previous publications. Methods like questionnaires, interviews, narrative techniques etc. have proven useful for assessing the subject's experience with the added value of the ability to determine the subject's feelings and preferences. However, the results of such methods may be biased especially with subjects who were



Obr. 1. The human autonomic nervous system and its response stimuli [24].

frustrated during the experience caused by their inadequate skill level or emotional state prior to the experiment.

B. Heart rate + Heart rate variability

Heart rate (HR) is a measure of cardiovascular activity which reflects the emotional state. It has been found to increase for a number of negative emotions (e.g. anger, anxiety, embarrassment, fear, sadness) as well as for some positive emotions (e.g. happiness, joy) and surprise [25].

The heart rate variability (HRV) is the time difference between each successive heartbeat, otherwise known as the R-R interval or the inter-beat interval. The time between each heartbeat is not fixed or consistent, but it varies with every beat - hence the term variability. Historically, HRV has been measured using an electrocardiogram (ECG), but with the development of technology, it can now be reliably measured using smartphone applications combined with a heart rate strap [26] or a pulse sensor [27]. Whilst there are many other metrics used to measure HRV, the most common is known as the "root-mean-square difference of successive normal R-R intervals (RMSSD)" [28].

C. Respiratory activity

Respiration is measured as the rate of volume at which an individual exchanges air in their lungs. Previous research has found that respiration rate is increased by emotional arousal and decreased by rest and relaxation [29]. Overall, respiratory activity (RA) is rather easily measured during the experiments. There are several types of devices used for measuring respiratory activity, worn on the chest, torso, neck or even the wrist.

D. Electrodermal activity

Electrodermal activity (EDA) measures the activity of the eccrine sweat glands and has been found to be a linear

correlate to arousal [30]. Although room temperature, humidity, participants activities and the correct attachment of the electrodes have to be carefully considered, Phasic EDA is a well researched and valid method to record arousal and has been used for measuring emotions for interaction with systems [31], [32]. EDA sensors are typically worn at the fingertips, but nowadays wrist-worn sensors and even ring sensors are becoming available.

E. Electroencephalography

Electroencephalography (EEG) provides data about the brain's electrical activity with millisecond accuracy. Certain features of the signals have been shown to be associated with drowsiness and vigilant attention [33] or to reflect inactivity in the brain regions (smaller use of mental resources [34]). EEG has also been used to study the processing of visual emotional stimuli [35]. However, to this date, the use of EEG in game research has been sparse, perhaps due to the complicated nature of the signal, which combined with a complex stimulus produces a range of methodological challenges [12].

V. EXPERIMENTS

We have conducted two sets of experiments in order to confirm the viability of the proposed approach.

A. Preliminary Experiments

In the first batch of experiments, we measured only one psychophysiological indicator (heart rate, using wrist-worn smartwatch sensor Fitbit Surge¹) of one participant who played ~20 hours of Dota 2 throughout several days.² This first set of experiments helped us support the validity of our hypotheses and establish the process for the subsequent experiments. Figure 2 depicts the heart rate recorded from 4 games throughout 3 different days. Unsurprisingly, we were unable to reliably model player's enjoyment using only one psychophysiological indicator.

During the second set of experiments, we expanded the number of measured features to 10 and the number of participants to 31. The measurement details can be found in Table I and following subsections.

B. Apparatus

For data collection, we used an apparatus consisting of three different sensors and a webcam:

- **Zephyr Bioharness 3**³ for measuring heart rate, respiratory and physical activity.
- **Neurosky Mindwave Mobile**⁴ for measuring EEG and blinking frequency.
- **Grove GSR Sensor**⁵ in combination with Arduino Uno⁶ for measuring electrodermal skin activity.

¹<https://www.fitbit.com/us/surge>


²More information about this batch of experiments can be found in [36] and [37].

³<https://www.zephyranywhere.com/>

⁴<http://neurosky.com/>

⁵<http://wiki.seeedstudio.com/>

⁶<https://www.arduino.cc/>



Obř. 2. Heart rate during four games of Dota 2, played by the test subject in 3 sessions.

- **Creative Senz3D⁷** for recording the experiment.

C. Data Collection

When dealing with psychophysiology, it is important to carefully consider the prior psychophysiological states of the subject. As described in [18] and confirmed by our initial experiments, particular readings of subjects vary depending on several factors. For example, in Figure 2 there are 4 games of the same subject playing the same game in three separate sessions during three days. This figure shows that average values of different measures vary significantly based on subject's mental and physical state on given day. Psychophysiological measurements can be affected by many variables. Temperature, humidity, attachment of electrodes, individual differences, differences concerning gender, age, time of the day, the use of stimulants such as coffee or energy drinks, medicaments, etc. can cause different reactions in sensor readings [38]. Therefore, we decided to ignore absolute values of HR, RA, EEG and EDA measurements in the future and use the deviations from the session average instead.

Besides the psychophysiological state, the game format also affects the experimental readings considerably. While in Single-player games the players are focused solely on the game experience, in Multi-player format the social aspect comes into play. To avoid similar interference, we avoided any unnecessary communication with subjects.

With Bioharness sensor, we were not able to access the data in real time (no real-time API is provided), so the data was processed after the experiments using a simple CSV log parser. Mindwave EEG sensor provides the data in real time, so our database was updated every second during the experiments: attention, meditation, and blinking frequency were stored. Attention and meditation features are calculated on Mindwave

Mobile sensor's chip using NeuroSky's proprietary algorithm described in [39]. The blinking rate was extracted using the sensor's raw data, detecting repeating anomalies every time an eye-blink happened. EDA sensor we used was connected to Arduino and while it was able to send the data in real time using a serial port, we have decided to store it into text files during the experiment and only add it to the database after cleaning the noise. Since the noise in the data was quite rare, we were able to use the forward interpolation for filling the missing values in the dataset.

As shown in Figure 3, we measured 10 psychophysiological features using three different sensors (listed in Subsection V-B). The list of measured features with corresponding units is shown in Table I. In our database, we stored the deviations from the session-average values instead of the absolute values for each feature except the blinking frequency. The blinking frequency was represented by three values – a number of times the subject blinked during the last 10, 30 and 60 seconds. The sampling frequency was *1 measurement per second* for all the features.

Additionally, we constructed three more proxy features for each measurement to address the temporal structure of the data: the value deviation over the last 10 seconds, last 30 seconds and last 60 seconds (similar to blinking frequency data)⁸.

D. Subject Sample

There were 31 experiment participants with an average age of 28 years. 26 of them were male and 5 female. The information about their age, gender, and experience with playing video-games was available (three discrete levels: non-player, average player, frequent player). However, after performing the feature analysis, this information proved ineffective (or even counterproductive) for training our models and was not used.

E. Gameplay Session

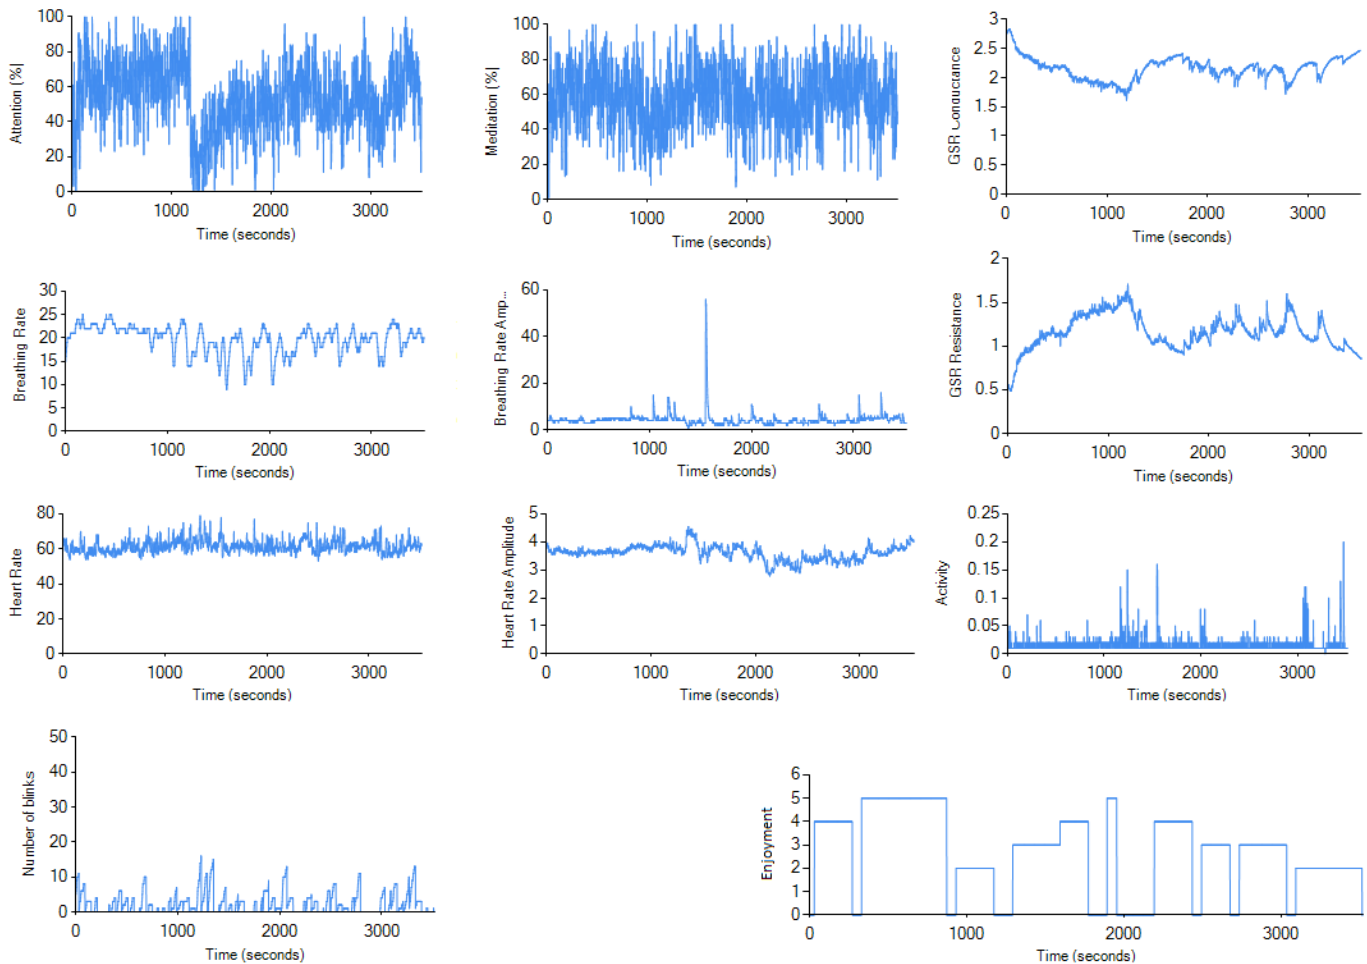
Prior to the experiment, each participant was informed about simplified definition of enjoyment based on definition provided in Section II. Every participant played approximately 45 minutes of 2-3 different games (in total). The game genre and titles were selected based on their previous experience with video-games to avoid any discouragement caused by forcing a subject to play inappropriately difficult games. After the session, we conducted an interview where participants watched the video recording of their session and labeled their enjoyment level during individual time periods. Enjoyment was measured using a five-item (1 = lowest enjoyment, 5 = highest enjoyment) Likert-type scale adapted from [9]. In games with short levels/segments, we let the participants label the level as one event (for example, Need For Speed: Payback levels are usually 1-3 minutes long). If the levels/segments were longer, we asked the participants to point out game events which had an effect on their enjoyment levels and

⁸We published an anonymized version of our dataset and source code at: <https://github.com/Games-and-Simulations/psychophysiological-indicators-data>

⁷<https://us.creative.com/>

Tabuľka I
LIST OF MEASURED PSYCHOPHYSIOLOGICAL FEATURES AND SENSORS USED.

Sensor	Measured Feature	Data range	Unit
Zephyr Bioharness 3	Heart Rate (HR)	25 - 240	BPM (beats per minute)
Zephyr Bioharness 3	Heart Rate Amplitude (HRamp)	0.25 - 15	mV
Zephyr Bioharness 3	Breathing Rate (BR)	4 - 70	BPM (breaths per minute)
Zephyr Bioharness 3	Breathing Rate Amplitude (BRamp)	0 - 65534	16 bit unsigned number
Zephyr Bioharness 3	Activity	+/-16 (any axis)	VMU (vector magnitude in g)
Seedstudio Grove GSR Skin Sensor Module	GSR Conductance (GSRCon)	0 - 1023	Siemens
Seedstudio Grove GSR Skin Sensor Module	GSR Resistance (GSRRes) (1/Conductance)	0 - 1023	Ohm
Neurosky Mindwave Mobile	Attention	0 - 100	%
Neurosky Mindwave Mobile	Meditation	0 - 100	%
Neurosky Mindwave Mobile	Blinking Frequency (BF)	0 - 65534	16 bit unsigned number



Obz. 3. Sample data from our data collection software. There are 10 features measured by psychophysiological sensors and one target feature (enjoyment) collected during a post-game interview.

labeled between those. Based on games and participant’s ability to assess their enjoyment, the times between enjoyment alterations differed. This assessment is an 11th feature shown in Table I, labeled as enjoyment and served as a target feature for our machine learning models.

VI. MODELING

We trained four machine learning models to output player’s enjoyment based on measured psychophysiological features. The target values were the enjoyment levels provided by the subjects (on a scale of 1–5, where 5 is the highest enjoyment). We tested two different approaches to this problem: classifi-

cation and regression. Input for all our models was a time-series dataset consisting of 39 features: four features derived for each measure listed in Table I except blinking frequency (3 features). The output of our classification models was one of the 5 classes (enjoyment levels). Our regression models returned an enjoyment as a real number.

A. Methods

We experimented with a feedforward deep neural network, a random decision forest, and a decision jungle methods for our models. The neural network is one of the most common approaches to this kind of tasks. The random decision forest and decision jungle methods were selected due to their versatility (they work well with both the regression and classification tasks), implicit feature selection, no need for scaling and fast training.

1) *Deep Feed Forward Neural Network*: A DNN is a feed-forward, artificial neural network that has more than one layer of hidden units between its inputs and its outputs [40].

We tested multiple topologies and hyperparameter settings for our neural network model. Model was created in Keras⁹ API using Tensorflow¹⁰ backend. The best results were obtained using a combination of four hidden layers, each having 128 nodes. We used rectified linear unit activation function, an *Adam* [41] gradient based optimization method with 0.001 learning rate parameter and 20 best features selected by the *SelectKBest* method¹¹.

2) *Random Decision Forest*: The decision forest algorithm is an ensemble learning method for classification. The algorithm works by building multiple decision trees and then voting on the most popular output class. Voting is a form of aggregation, in which each tree in a classification decision forest outputs a non-normalized frequency histogram of labels. The aggregation process sums these histograms and normalizes the result to get the "probabilities" for each label.

Decision trees, in general, are non-parametric models, meaning they support data with varied distributions. For regression tasks, each tree outputs a Gaussian distribution as a prediction. An aggregation is performed over the ensemble of trees to find a Gaussian distribution closest to the combined distribution for all trees in the model [42].

For training our decision forest models, we used the Azure Machine Learning Studio framework. Our optimal model had a maximum of 16 decision trees, maximum depth of each tree was 32. To build each node of the tree, there was 256 maximum number of splits. Number of training samples required to generate a leaf node was 2. We used bagging (bootstrap aggregating) as a resampling method.

⁹<https://keras.io/>

¹⁰<https://www.tensorflow.org/>

¹¹We also considered testing the LSTM neural network model. However, after considering that LSTMs do not deal well with gaps in time-series data, we decided against it. As described in V-C, our dataset is not one continuous time series – there are downtimes where target feature (enjoyment) was not labeled.

3) *Random Decision Jungle*: A decision jungle consists of an ensemble of a decision directed acyclic graphs (DAGs). By allowing tree branches to merge, a decision DAG typically has a lower memory footprint and a better generalization performance than a decision tree, albeit at the cost of a somewhat higher training time. Similarly to decision forests, decision jungles are non-parametric models, which can represent non-linear decision boundaries. They also perform integrated feature selection and classification and are resilient in the presence of noisy features [43].

We used 32 DAGs that could have been created in the ensemble. Maximum depth of the graphs to create the ensemble was 64, with a maximum width of 256. The number of optimization steps per decision DAG layer was 16 000. Same as with decision forests, bagging (bootstrap aggregating) as a resampling method was used.

B. Data Preprocessing

Prior to the training, we went through a typical process of pre-processing the data:

- *Replacing missing values*: in case of missing values, we filtered the noise in the dataset using forward interpolation.
- *Adding derived features*: As explained above, we constructed derived features representing deviations of each feature within particular time windows (10, 30 and 60 seconds).
- *Ignoring intervals with missing enjoyment label*: Since the enjoyment is used as a target value, we did not include the intervals where it is missing in our training. These intervals occurred when no actual gameplay took place: loading times, switching games, explaining controls, etc.
- *Normalization*: Finally, each feature was scaled to the range of [-1, 1]. This applies only to our neural network model since random forests and jungles deal with unscaled data without problems.

After pre-processing the data, 75 177 samples remained, where each sample represents one second of labeled gameplay, totaling in ~21 hours of gameplay time. The data was divided into a training test and test set using the 80% - 20% split for each model.

C. Feature Selection & Cross-validation

For the neural network model, we applied a feature selection algorithm to determine the optimal subset of relevant features. We used the *univariate linear regression tests method* in combination with *SelectKBest* method provided by the *scikit-learn*¹² library. After attempting to train our model using different numbers of features, we observed that it is not feasible to successfully train the model using less than 10 features. Later, we decided to use 20 out of 39 features to train our model¹³. Using more than 20 features did not improve the

¹²<https://scikit-learn.org/>

¹³Out of 8 features provided by Mindwave sensor, only one (meditation deviation from average) was selected for training. Features related to breathing rate were prioritized over heart rate related features (5 vs. 3). All features provided by our GSR sensor were selected.


results enough to compensate for the increase in the training time.

Since the random forest and random jungle algorithms perform the feature selection inherently, we did not replicate the feature selection process for these models.

As our dataset is relatively small, we used 10-fold cross validation for each model to prevent overfitting. None of the tested models showed more than 2% disparity in all folds. All the results (error/accuracy of trained models) presented in this paper represent an average value over all the folds.

D. Results

When training the regression models, our goal was to minimize the RMSE (root mean squared error) values, which represent the deviation between the model output and the enjoyment level indicated by the test subjects. The enjoyment values gathered during the experiments had an integer value on the scale from 1 to 5.



Obr. 4. Value loss (MSE) on training and testing dataset, and RMSE of model.

Our neural network regression model produced a real number representing predicted value of enjoyment. Table II lists results of different tested settings and topologies of neural network. Best performing model produced RMSE of 0.2441 (see Figure 4). The random decision forest regression model had the RMSE of 0.4909. Both these results can be considered satisfactory. Regression and classification performance results for random forest model with different tested settings are listed in Table III.

In classification, we used the accuracy metric defined as the percentage of the correctly predicted samples (using 5 possible classes). Our random decision forest classification model was trained with 96% accuracy and random decision jungle model performed with 88% accuracy. Confusion matrices in Figures 5 and 6 show the predicted vs. observed values for all the 5 classes.

Tabuľka II

DETAILED REGRESSION RESULTS OF DEEP FEED FORWARD NEURAL NETWORK MODEL. EACH TESTED TOPOLOGY IS CHARACTERIZED BY A SPECIFIC CONFIGURATION OF HIDDEN LAYERS AND UNITS PER HIDDEN LAYER (SEE THE FIRST TABLE COLUMN).

Network Topology (Hidden Layers)	Learning Rate	# of Features	RMSE
64, 32	0.01	10	1.1051
64, 32	0.01	15	1.0817
64, 32	0.01	20	1.0810
64, 32	0.001	10	1.0633
64, 32	0.001	15	1.0150
64, 32	0.001	20	1.0147
64, 64, 32	0.01	15	1.0064
64, 64, 32	0.001	15	0.7697
64, 64, 32	0.01	20	1.0080
64, 64, 32	0.001	20	0.7618
64, 64, 64, 64	0.01	15	0.8736
64, 64, 64, 64	0.001	15	0.4952
64, 64, 64, 64	0.01	20	0.9963
64, 64, 64, 64	0.001	20	0.4905
128, 128, 128, 128	0.01	15	1.1692
128, 128, 128, 128	0.001	15	0.2441
128, 128, 128, 128	0.01	20	1.1694
128, 128, 128, 128	0.001	20	0.2443

Additionally, different settings and topologies of random decision forest and jungle models are showed in Tables III and IV.

		Predicted Class				
		1	2	3	4	5
Actual Class	1	92.6%	2.9%	2.1%	1.7%	0.7%
	2	0.2%	95.2%	1.8%	1.5%	1.2%
	3	0.1%	1.0%	97.2%	1.2%	0.5%
	4	0.0%	1.1%	2.7%	95.4%	0.8%
	5	0.1%	0.5%	1.2%	1.3%	96.9%

Obr. 5. Confusion matrix of trained random decision forest classification model.

VII. CONCLUSION

This paper aimed to simplify and automate the process of evaluating the user experience in digital entertainment (especially video-games) and to mitigate some of the drawbacks of self-reporting methodology. We propose an alternative approach: using psychophysiological measures, such as heart rate, electrodermal activity or respiratory activity in combination with machine learning methods.

		Predicted Class				
		1	2	3	4	5
Actual Class	1	60.1%	5.8%	22.2%	9.1%	2.8%
	2	0.3%	72.6%	17.2%	6.2%	3.6%
	3	0.2%	2.0%	92.2%	3.9%	1.8%
	4	0.2%	2.8%	15.3%	78.4%	3.3%
	5	0.3%	1.5%	7.3%	5.7%	85.3%

Obř. 6. Confusion matrix of trained random decision jungle classification model.

Tabuřka III

DETAILED REGRESSION & CLASSIFICATION RESULTS OF RANDOM DECISION FOREST MODELS. EACH MODEL USES DIFFERENT NUMBER OF TREES, MAXIMUM DEPTH AND MINIMAL SAMPLES SPLIT (FIRST THREE COLUMNS).

# of trees	Max Depth	Min Samples Split	RMSE	Accuracy
8	8	128	1.0112	54.07%
8	16	128	0.6752	90.21%
8	16	256	0.6673	90.04%
16	8	128	1.0111	55.56%
16	16	128	0.6539	92.66%
16	16	256	0.6451	92.58%
16	32	128	0.5401	95.42%
16	32	256	0.5112	95.57%
32	16	128	0.6457	93.96%
32	32	256	0.4909	96.72%

Tabuřka IV

DETAILED CLASSIFICATION RESULTS OF RANDOM DECISION JUNGLE MODEL.

# of DAGs	Max Depth	Max Width of DAGs	optimization steps	Accuracy
8	32	128	2048	59.61%
8	64	128	2048	62.41%
8	64	256	2048	65.83%
16	32	128	4096	66.51%
16	32	128	8192	70.15%
16	64	256	8192	77.63%
32	32	128	8192	71.40%
32	32	128	16384	74.99%
32	64	256	16384	83.37%
32	128	512	16384	88.38%

We provide an introductory analysis of various available physiological data sources, their relevance to user experience modeling and technical prerequisites for their collection. Afterwards, we demonstrated the process of gathering real-time data produced by the autonomic nervous system and involuntary physiological responses and show how they can be post-

processed and used to train machine learning models.

Tabuřka V

COMPARISON OF TRAINED MACHINE LEARNING MODELS.

Machine learning method	Problem approach	Score
Feed forward neural network	Regression	RMSE: 0.2441
Random decision forest	Regression	RMSE: 0.4909
Random decision forest	Classification	Acc.: 0.9672
Random decision jungle	Classification	Acc.: 0.8838

The presented initial experiments support the validity of the proposed approach. Four different machine learning models were successfully trained using different parameters for optimization. Data fed to these models consisted of 20-39 types of features measured during approximately hour-long gameplay sessions of 31 subjects, totaling approx. 70 000 samples. Based on the good performance of these models, as shown in Table V, we conclude that machine learning and psychophysiological measures can be a useful addition or even an alternative to typical means of assessing user experience in the digital entertainment business. Even as proposed approach does not entirely escape the disadvantages of self-reporting techniques for measuring user experience, with sufficient number of participants, it can definitely be useful as an optimization tool for replacing questionnaires and interviews with successfully trained machine learning model.

ACKNOWLEDGMENT

This work is financially supported by the Scientific Grant Agency of MŠVVaŠ SR and SAV by project VEGA No. 1/0663/17 - Intelligent Cyber-Physical Systems in Heterogeneous Environment with Support of IoE and Cloud-Based Services.

LITERATÚRA

- [1] E. D.E.S.A. Washington, "Sales, demographics and usage data: Essential facts about the computer and video-game industry," 2015.
- [2] R. Bernhaupt, *Game user experience evaluation*. Springer, 2015.
- [3] P. M. Desmet and P. Hekkert, "Framework of product experience," *International journal of design*, vol. 1, no. 1, pp. 57–66, 2007.
- [4] M. Hassenzahl and N. Tractinsky, "User experience-a research agenda," *Behaviour & information technology*, vol. 25, no. 2, pp. 91–97, 2006.
- [5] E. L.-C. Law, V. Roto, M. Hassenzahl, A. P. Vermeeren, and J. Kort, "Understanding, scoping and defining user experience: a survey approach," in *Proceedings of the SIGCHI conference on human factors in computing systems*. ACM, 2009, pp. 719–728.
- [6] C. Lallemand, G. Gronier, and V. Koenig, "User experience: A concept without consensus? exploring practitioners' perspectives through an international survey," *Computers in Human Behavior*, vol. 43, pp. 35–48, 2015.
- [7] M. Hassenzahl, "User experience (ux): towards an experiential perspective on product quality," in *Proceedings of the 20th Conference on l'Interaction Homme-Machine*. ACM, 2008, pp. 11–15.
- [8] P. Vorderer and J. Bryant, *Playing video games: Motives, responses, and consequences*. Routledge, 2012.
- [9] R. M. Ryan, C. S. Rigby, and A. Przybylski, "The motivational pull of video games: A self-determination theory approach," *Motivation and emotion*, vol. 30, no. 4, pp. 344–360, 2006.
- [10] R. Tamborini, N. D. Bowman, A. Eden, M. Grizzard, and A. Organ, "Defining media enjoyment as the satisfaction of intrinsic needs," *Journal of communication*, vol. 60, no. 4, pp. 758–777, 2010.
- [11] R. Tamborini, M. Grizzard, N. David Bowman, L. Reinecke, R. J. Lewis, and A. Eden, "Media enjoyment as need satisfaction: The contribution of hedonic and nonhedonic needs," *Journal of Communication*, vol. 61, no. 6, pp. 1025–1042, 2011.

- [12] J. M. Kivikangas, G. Chanel, B. Cowley, I. Ekman, M. Salminen, S. Järvelä, and N. Ravaja, "A review of the use of psychophysiological methods in game research," *Journal of Gaming & Virtual Worlds*, vol. 3, no. 3, pp. 181–199, 2011.
- [13] A. Drachen, L. E. Nacke, G. Yannakakis, and A. L. Pedersen, "Psychophysiological correlations with gameplay experience dimensions," *arXiv preprint arXiv:1004.0243*, 2010.
- [14] W. IJsselstein, W. Van Den Hoogen, C. Klimmt, Y. De Kort, C. Lindley, K. Mathiak, K. Poels, N. Ravaja, M. Turpeinen, and P. Vorderer, "Measuring the experience of digital game enjoyment," in *Proceedings of Measuring Behavior*. Noldus Information Technology Wageningen, Netherlands, 2008, pp. 88–89.
- [15] A. Drachen, L. E. Nacke, G. Yannakakis, and A. L. Pedersen, "Correlation between heart rate, electrodermal activity and player experience in first-person shooter games," in *Proceedings of the 5th ACM SIGGRAPH Symposium on Video Games*. ACM, 2010, pp. 49–54.
- [16] M. E. Ballard and J. R. Wiest, "Mortal combat (tm): The effects of violent videogame play on males' hostility and cardiovascular responding1," *Journal of Applied Social Psychology*, vol. 26, no. 8, pp. 717–730, 1996.
- [17] M. Codispoti, P. Surcinelli, and B. Baldaro, "Watching emotional movies: Affective reactions and gender differences," *International Journal of Psychophysiology*, vol. 69, no. 2, pp. 90–95, 2008.
- [18] R. L. Mandryk, K. M. Inkpen, and T. W. Calvert, "Using psychophysiological techniques to measure user experience with entertainment technologies," *Behaviour & information technology*, vol. 25, no. 2, pp. 141–158, 2006.
- [19] G. N. Yannakakis, J. Hallam, and H. H. Lund, "Entertainment capture through heart rate activity in physical interactive playgrounds," *User Modeling and User-Adapted Interaction*, vol. 18, no. 1-2, pp. 207–243, 2008.
- [20] H. P. Martinez, Y. Bengio, and G. N. Yannakakis, "Learning deep physiological models of affect," *IEEE Computational Intelligence Magazine*, vol. 8, no. 2, pp. 20–33, 2013.
- [21] T. Hainey, T. Connolly, M. Stansfield, and E. Boyle, "The differences in motivations of online game players and offline game players: A combined analysis of three studies at higher education level," *Computers & Education*, vol. 57, no. 4, pp. 2197–2211, 2011.
- [22] Z. Infantolino and G. A. Miller, "Psychophysiological methods in neuroscience," <http://nobaproject.com/modules/psychophysiological-methods-in-neuroscience>, accessed: 2016-03-15.
- [23] G. Tortora and B. Derrickson, "Principles of anatomy and physiology: Organisation, support and movement and control systems of the human body," *Hoboken, NJ: John Wiley and Sons*, 2009.
- [24] "Parasympathetic nervous system rest and digest," <http://ktmc.info/parasympathetic-nervous-system-rest-and-digest>, accessed: 2016-03-15.
- [25] S. D. Kreibig, "Autonomic nervous system activity in emotion: A review," *Biological psychology*, vol. 84, no. 3, pp. 394–421, 2010.
- [26] A. A. Flatt and M. R. Esco, "Validity of the ithletetm smart phone application for determining ultra-short-term heart rate variability," *Journal of human kinetics*, vol. 39, no. 1, pp. 85–92, 2013.
- [27] J. A. Heathers, "Smartphone-enabled pulse rate variability: an alternative methodology for the collection of heart rate variability in psychophysiological research," *International Journal of Psychophysiology*, vol. 89, no. 3, pp. 297–304, 2013.
- [28] A. E. Aubert, B. Seps, and F. Beckers, "Heart rate variability in athletes," *Sports medicine*, vol. 33, no. 12, pp. 889–919, 2003.
- [29] R. M. Stern, W. J. Ray, and K. S. Quigley, *Psychophysiological recording*. Oxford University Press, USA, 2001.
- [30] M. E. D. A. M. Schell and D. L. Fillion, "The electrodermal system," *Principles of Psychophysiology: Physical, social and inferential elements*, pp. 295–324.
- [31] J. McCarthy and P. Wright, "Technology as experience," *interactions*, vol. 11, no. 5, pp. 42–43, 2004.
- [32] R. D. Ward and P. H. Marsden, "Physiological responses to different web page designs," *International Journal of Human-Computer Studies*, vol. 59, no. 1, pp. 199–212, 2003.
- [33] R. J. Davidson, D. C. Jackson, and C. L. Larson, "Human electroencephalography," *Handbook of psychophysiology*, vol. 2, pp. 27–52, 2000.
- [34] M. E. Smith, L. K. McEvoy, and A. Gevins, "Neurophysiological indices of strategy development and skill acquisition," *Cognitive Brain Research*, vol. 7, no. 3, pp. 389–404, 1999.
- [35] L. Aftanas, N. Reva, A. Varlamov, S. Pavlov, and V. Makhnev, "Analysis of evoked eeg synchronization and desynchronization in conditions of emotional activation in humans: temporal and topographic characteristics," *Neuroscience and behavioral physiology*, vol. 34, no. 8, pp. 859–867, 2004.
- [36] M. Certicky, "Correlation between user experience in electronic entertainment and psychophysiological measurements," in *Proceedings of Scientific Conference of Young Researchers*, 2016, pp. 80–83.
- [37] M. Certicky, M. Certicky, P. Sincak, and F. Cavallo, "Modeling user experience in electronic entertainment using psychophysiological measurements," in *Proceedings of 2018 World Symposium on Digital Intelligence for Systems and Machines - DISA 2018*. Danvers, 2018, pp. 219–226.
- [38] E. Ganglbauer, J. Schrammel, S. Deutsch, and M. Tscheligi, "Applying psychophysiological methods for measuring user experience: possibilities, challenges and feasibility," in *Workshop on user experience evaluation methods in product development*. Citeseer, 2009.
- [39] G. U. Navalyal and R. D. Gavas, "A dynamic attention assessment and enhancement tool using computer graphics," *Human-centric Computing and Information Sciences*, vol. 4, no. 1, p. 11, 2014.
- [40] G. Hinton, L. Deng, D. Yu, G. E. Dahl, A.-r. Mohamed, N. Jaitly, A. Senior, V. Vanhoucke, P. Nguyen, T. N. Sainath *et al.*, "Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups," *IEEE Signal processing magazine*, vol. 29, no. 6, pp. 82–97, 2012.
- [41] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- [42] A. Criminisi, J. Shotton, E. Konukoglu *et al.*, "Decision forests: A unified framework for classification, regression, density estimation, manifold learning and semi-supervised learning," *Foundations and Trends® in Computer Graphics and Vision*, vol. 7, no. 2–3, pp. 81–227, 2012.
- [43] J. Shotton, T. Sharp, P. Kohli, S. Nowozin, J. Winn, and A. Criminisi, "Decision jungles: Compact and rich models for classification," in *Advances in Neural Information Processing Systems*, 2013, pp. 234–242.

Netradičné metódy rekonštrukcie pre kompresné snímanie EKG

Pavol Dolinský

Katedra elektroniky a multimediálnych telekomunikácií
Fakulta elektrotechniky a informatiky, Technická
univerzita v Košiciach
Košice, Slovakia
pavol.dolinsky@tuke.sk

Ján Šaliga

Katedra elektroniky a multimediálnych telekomunikácií
Fakulta elektrotechniky a informatiky, Technická
univerzita v Košiciach
Košice, Slovakia
jan.saliga@tuke.sk

Abstrakt—Tento článok sa venuje netradičným metódam rekonštrukcie kompresne snímaného EKG. Uvádza základnú teóriu kompresného snímania a pokračuje v popise novo navrhnutých metód rekonštrukcie, ktoré pracujú po rámcach s variabilnou dĺžkou. Najprv rozoberá metódu rekonštrukcie s využitím parametrického modelu. Ďalej uvádza novú metódu vytvorenia normalizovaného rekonštrukčného slovníka pomocou analýzy hlavných komponentov, ktorý je synchronizovaný s obsahom signálu a tiež kombinovanú metódu rekonštrukcie s využitím slovníka tvoreného modelovanými syntetickými priebehmi. Vytvorené metódy dosahujú lepšiu kvalitu rekonštrukcie v porovnaní so slovníkmi s waveletovými funkciami pre kompresné pomery vyššie ako 4.

Kľúčové slová—kompresné snímanie; kompresia EKG; model EKG

Abstract—This paper is dealing with unconventional reconstruction methods for compressed sensing of ECG signals. It introduces the basic theory of compressed sensing and continues with description of newly proposed reconstruction methods. First, the reconstruction method using parametric model is proposed. Subsequently a novel method of creating a normalized reconstruction dictionary using principal component analysis is introduced, where the dictionary and the content of input signal are synchronized. By combining both methods, another one is introduced where the dictionary is created using synthetic modelled waveforms. Proposed methods achieve better reconstruction quality than a wavelet dictionary for compression ratios above 4.

Keywords— compressed sensing; ECG compression; ECG signal model

I. ÚVOD

Moderné systémy monitorovania zdravotného stavu využívajú takzvané siete „Body Area Network“ (BAN) [1], [2]. Jedná sa o sieť bezdrôtových snímačov, ktoré sú implantovateľné, nosia sa prilepené na tele, alebo ich pacient nosí so sebou. Z tohto hľadiska sa na použité snímače kladú špecifické požiadavky, ktoré v prvom rade zahŕňujú vysokú životnosť batérie (nízku spotrebu), malé rozmery, priaznivú

cenu a výkon. Stále pretrvávajúcou výzvou v oblasti bezdrôtových snímačov totiž zostáva znižovanie spotreby energie, pričom najväčší podiel na spotrebe má v ich prípade vysielateľ [3]. Možný prístup znižovaniu spotreby je vhodná metóda kompresie, ktorá pred samotným vysielaním redukuje objem dát. Tradičné efektívne techniky kompresie sú obvyčajne výpočtovo náročné a niekedy neumožňujú vysielateľ, či ukladať údaje v reálnom čase, čo je pre danú aplikáciu nevhodné.

Z uvedených dôvodov sa v poslednej dobe, nie len v oblasti biomedicínskych signálov, pomerne rýchlo rozšírila netradičná metóda stratovej kompresie nazvaná kompresné snímanie (KS) (alebo „Compressed Sensing“) [4]-[7]. Jej základnou myšlienkou je jednoduchým spôsobom nasnímať o signáli iba určitú informáciu, na základe ktorej bude na strane prijímača možné vykonať jeho rekonštrukciu tak, aby táto čo najlepšie reprezentovala pôvodný snímaný signál. Všetok potrebný výpočtový výkon sa tým presunie na stranu prijímača, ktorý v tomto prípade nie je mobilný, a tak nemá limitované zdroje energie.

Rekonštrukcia kompresne snímaného signálu je vo všeobecnosti výpočtovo náročná úloha, ktorá spočíva vo využití jeho známych vlastností a typických priebehov pre doplnenie informácie stratenej počas kompresie s využitím výpočtových prostriedkov. K uvedenej úlohe sú tak potrebné vhodné bazové funkcie (slovníky), ktorými je možné pôvodný signál a jeho chovanie efektívne napodobniť. Tento článok stručne popisuje novo navrhnuté metódy rekonštrukcie KS EKG spolu s dosiahnutými výsledkami pri kompresii reálnych záznamov EKG z databázy arytmií MIT-BIH [8]. Prvá metóda využíva pre rekonštrukciu parametrický model (PM), druhá slúži pre vytvorenie normalizovaného rekonštrukčného slovníka použitím analýzy hlavných komponentov (PCA) a tretia je kombináciou oboch metód.

II. ZÁKLADNÁ TEÓRIA KOMPRESNÉHO SNÍMANIA

Je známe, že niektoré signály je možné vo vhodnej transformovanej oblasti vyjadriť ako lineárnu kombináciu malého počtu bazových funkcií. Takéto signály sa nazývajú riedke a práve na nich je možné aplikovať metódu

kompresného snímania [1] - [6], a tak ich komprimovať. Je to metóda stratovej kompresie väčšinou založená na násobení signálu pseudonáhodnou postupnosťou a jeho podvzorkovaní, teda na vzorkovaní s frekvenciou menšou ako je daná vzorkovacou teorémou, čím sa získa o signáli iba určitá informácia. Pri samotnom snímaní pritom nie je obvyčajne potrebné vôbec vopred podrobne poznať snímaný signál a stačí o ňom vedieť, že je riedky v niektorej transformovanej oblasti. Konkrétnu transformovanú oblasť, ostatné vlastnosti a chovanie signálu je potrebné poznať až pri jeho rekonštrukcii. Cieľom rekonštrukcie je na základe týchto dostupných informácií o signáli a jeho podvzorkovaného priebehu vytvoriť nový signál, ktorý má v ideálnom prípade priebeh totožný so signálom pred kompresným snímaním.

Uvažujme, že je vektor signálu diskrétného v čase rozmeru $N \times 1$, ktorý je možné vyjadriť ako

$$\mathbf{x} = \Psi \alpha, \quad (1)$$

kde Ψ je bázová matica (slovník) rozmeru $N \times N$, v ktorej každý stĺpec tvorí bázový vektor, pritom α obsahuje transformačné koeficienty. Ak hodnota transformačných koeficientov po zoradení od najväčšieho po najmenší klesá rýchlo k nule, signál je komprimovateľný v báze Ψ . V tom prípade sa dá signál dostatočne vyjadriť pomocou K transformačných koeficientov najväčšej hodnoty, pričom ostatné koeficienty zanedbateľnej hodnoty položíme rovné nule. Podľa tejto definície je tiež možné komprimovať signály, kde je iba málo transformačných koeficientov nenulových [1].

Podľa [2], [3], ak je signál komprimovateľný v báze Ψ , je možné ho rekonštruovať pomocou $M = cK$ lineárnych kombinácií v inej báze Φ , ktorá je s bázou Ψ nekoherentná, kde c je malá konštanta väčšia ako 1. Matica Φ má rozmer $M \times N$, pričom $M \ll N$. Preto je možné namiesto priameho vzorkovania vektora \mathbf{x} rozmeru $N \times 1$ navzorkovať vektor \mathbf{y} rozmeru $M \times 1$, čo pre vstupný signál nemusí byť v súlade so vzorkovacou teorémou

$$\mathbf{y} = \Phi \mathbf{x}, \quad (2)$$

po dosadení (1) do (2):

$$\mathbf{y} = \Phi \Psi \alpha = \Theta \alpha, \quad (3)$$

Vzájomná koherencia opisuje maximálnu podobnosť, ktorú možno nájsť medzi riadkami matice Φ a bázovými vektormi v stĺpcoch matice Ψ . Aby sa dosiahla čo najmenšia koherencia, vo väčšine literatúry o kompresnom snímaní sa uvažuje, že matica Φ obsahuje náhodné čísla. Navyše je taký systém možné ľahko implementovať využitím generátorov pseudonáhodnej postupnosti [6].

Matica Θ v rovnici (3) má rozmer $M \times N$ a $M \ll N$, signál nemožno jednoducho rekonštruovať inverziou tejto matice. Je potrebné riešiť podurčenú sústavu rovníc, kde počet rovníc N je menší ako počet neznámych M . Ak ale uvažujeme, že takto navzorkovaný signál je riedky a komprimovateľný, teoreticky je možné zo všetkých riešení nájsť jediné správne α , ktoré je najviac riedke. Riedkosť K vektora α je ekvivalentná pseudo-norme ℓ_0 , ktorá je definovaná ako:

$$\ell_0 : \|\alpha\|_0 := \{n : \alpha_n \neq 0\}, \quad (4)$$

Pretože táto definícia nespĺňa axiomy pre normu, často sa nazýva pseudo-normou [1], [6], [7]. Hľadať riešenie jej minimalizáciou je výpočtovo náročné a neefektívne, preto používa sa vo všeobecnosti minimalizácia normy ℓ_p pre dostatočne malé p [9]. Rekonštruovaný signál je možné potom tiež odhadnúť ako:

$$\hat{\mathbf{x}} = \Psi(\Theta^T \Theta)^{-1} \Theta^T \mathbf{y}, \quad (5)$$

kde $(\)^{-1}$ označuje pseudoinverznú maticu a T transpozíciu [10].

III. KS EKG S REKONŠTRUKCIU PARAMETRICKÝM MODELOM

Základnou myšlienkou je na strane rekonštrukcie pomocou diferenciálnej evolúcie (DE) [11] optimalizovať parametre dynamického modelu tak, aby výsledný modelovaný priebeh čo najlepšie zodpovedal pôvodnému nekomprimovanému signálu. Snímacia časť je oproti tradičným prístupom doplnená o QRS detektor a spracováva signál po rámcoch s variabilnou dĺžkou.

A. Kompresia

EKG signál sa na vstupe vzorkuje bežným AČP podľa vzorkovacej teorémy. Pomocou QRS detektora sa zistia presné polohy R vln n_{Ri} a signál sa rozdelí na rámce tak, že každý rámec obsahuje jeden srdcový cyklus. Okamih rozdelenia rámcov je určený jednoduchým spôsobom pevne v dvoch tretinách nasledujúceho R-R intervalu. Ako QRS detektor je tu vhodné použiť nízkoprikonový analógový detekčný obvod ako je napríklad [12]. Pre účely testovania bol použitý detekčný algoritmus podľa [13]. Tento spôsob delenia rámcov má určitú výhodu v tom, že poloha R vlny je pred rekonštrukciou už známa, čím je možné zaručiť jej presnú polohu aj v rekonštruovanom signáli. Takto nie je potrebné analyzovať presnosť rekonštrukcie polohy R vlny, ako sa to obvyčajne robí v prípade algoritmov používajúcich pevné dĺžky rámcov (napríklad [14]).

Z každého rámca sa následne odstráni jednosmerná (JS) zložka odčítaním jeho strednej hodnoty. Pôvodná úroveň JS zložky sa uloží do O_i . Amplitúda sa normalizuje predelením každej vzorky maximálnou hodnotou v rámci. Táto maximálna hodnota uloží sa do A_i . Na rámec x_i sa následne aplikuje kompresné snímanie vo forme násobenia maticou náhodných čísel Φ_i podľa rovnice (2). Riadky matice Φ_i obsahujú pseudonáhodnú postupnosť čísel ± 1 s Bernoulliho rozdelením pravdepodobnosti. Pre každý rámec sa generuje postupnosť s rovnakou inicializáciou („seed“). Počet riadkov matice Φ_i je daný ako:

$$M_i = \lfloor N_i / D \rfloor, \quad (6)$$

pričom D je konštantný decimálny faktor, ktorý sa v priebehu kompresie nemení. Výstupný vektor \mathbf{y}_i sa lineárne kvantuje pre zvýšenie kompresného pomeru a spolu s hodnotami A_i , O_i , N_i a n_{Ri} ako doplnkovou informáciou sa posiela k prijímaču ako samostatný blok dát.

B. Rekonštrukcia

Využíva sa dynamický model EKG signálu podľa [15]. Pomerne dobre dokáže zachytiť morfológické vlastnosti reálnych EKG signálov a dá sa využiť aj pre odšumenie signálu [16]. Pretože jednotlivé vlny PQRST sú tu reprezentované súčtom piatich exponenciálnych funkcií, z pohľadu teórie KS je pomocou neho srdcový cyklus reprezentovaný vždy iba pomocou piatich bázových funkcií, ktoré sa líšia svojimi parametrami. Pre rekonštrukciu je potom potrebné iba nájsť parametre týchto funkcií. V našom prípade bol model ešte modifikovaný pridaním malého množstva gaussovského šumu, ktorý ma za úlohu simulovať šum prítomný v reálnych signáloch. Vektor syntetického srdcového cyklu \mathbf{z}_i je pomocou modelu reprezentovaný ako

$$\mathbf{z}_i(u_i) = \sum_{w \in \{P,Q,R,S,T\}} a_{wi} \exp\left(-\frac{\Delta\theta_{wi}^2}{2b_{wi}^2}\right) + g(n, \sigma) \quad (7)$$

kde $\Delta\theta_{wi} = 2\pi(n - n_{wi})/N_i$, pričom n je číslo vzorky $n=0,1,\dots,N_i$ a $g(n, \sigma)$ je prídavný gaussovský šum so smerodajnou odchýlkou σ a nulovou strednou hodnotou, ďalej a_{wi} sú parametre amplitúdy, b_{wi} doby trvania a n_{wi} polohy vlny, ktoré sú obsiahnuté tiež vo vektore u_i spolu s parametrom σ . Pre každý i -ty rámec známej pôvodnej dĺžky N_i je uvedený model využitý pre generovanie jedného syntetického srdcového cyklu \mathbf{z}_i s rovnakou dĺžkou. K modelu sa nepridáva žiadna JS zložka a ani kolísanie základnej línie. Optimalizačnú úlohu pre DE potom možno zapísať ako:

$$u_i = \arg \min_{u_i} \|\mathbf{y}_i - \langle \Phi_i, \mathbf{z}_i(u_i) \rangle\|_2 \quad (8)$$

Po nájdení optimálnych parametrov u_i sa výsledný rekonštruovaný signál získa ako:

$$\hat{\mathbf{x}}_i = A_i \mathbf{z}_i(u_i) + O_i \quad (9)$$

kde A_i a O_i sú príslušné hodnoty amplitúdy a JS zložky získane vysielačou časťou. Nakoniec sa jednotlivé rekonštruované rámce poskladajú za sebou, čím vznikne kompletný zrekonštruovaný EKG signál.

C. Výsledky

Uvedená metóda bola simulovaná v programovacom prostredí LabVIEW s použitím databázy MIT-BIH ako vstupných signálov. V prvom rade je vhodné zaviesť priemerný kompresný pomer CR , ktorý vyjadruje redukciu počtu bitov na reprezentáciu pôvodných I rámcov signálu. V našom prípade bol vypočítaný ako:

$$CR = \frac{1}{I} \sum_{i=1}^I \frac{N_i \cdot B_0}{B_H + M_i \cdot B_C} \quad (10)$$

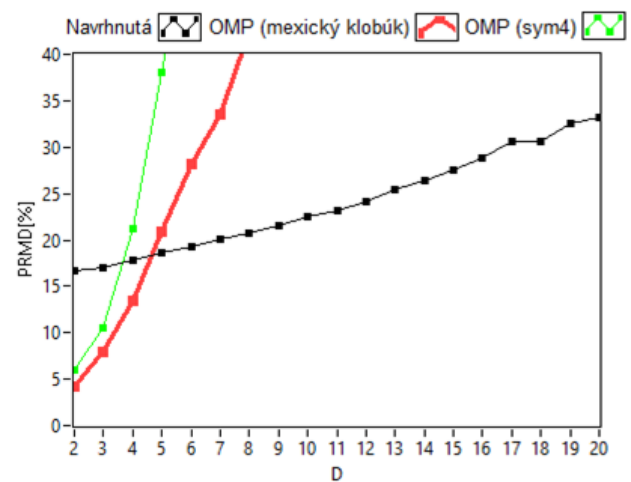
kde B_0 je počet bitov na jednu vzorku pôvodného vstupného signálu \mathbf{x} , B_C je počet bitov na jednu vzorku kvantovaného komprimovaného vektora \mathbf{y}_i veľkosti M_i a B_H je počet bitov hlavičky dátového bloku, ktorá nesie hodnoty A_i , O_i , N_i a n_{Ri} . Ak uvažujeme, že databáza je navzorkovaná s rozlíšením 11 bitov, potom $B_0 = 11$ bit. Hlavička dátového bloku bola uvažovaná $B_H = 40$ bit, čo zahŕňa 2×11 bitov pre hodnoty A_i ,

O_i a 2×9 bitov pre N_i a n_{Ri} . Kompresný pomer je možné meniť decimálnym faktorom D (čím sa zmení M_i) a tiež zmenou počtu bitov B_C na jednu komprimovanú vzorku pri kvantizácii.


Pre vyhodnotenie kvality rekonštrukcie bolo použité priemerné $PRMD$ počítané pre každý záznam podľa vzťahu:

$$PRMD = \frac{1}{I} \sum_{i=1}^I \frac{\|\mathbf{x}_i - \hat{\mathbf{x}}_i\|_2}{\|\mathbf{x}_i\|_2} \times 100 \% \quad (11)$$

Na obr. 1 je možné vidieť, že $PRMD$ závisí takmer lineárne na zvolenom decimálnom faktore D . V porovnaní s použitím waveletovej bázy a OMP [17], navrhnutá metóda nemá síce lepšie výsledky pre malé hodnoty D , avšak sú podstatne lepšie pre hodnoty $D > 5$. Uvedené výsledky sú priemerom pre prvých 10 rámcov všetkých záznamov databázy. Príklad rekonštruovaného signálu je uvedený na obr. 2.



Obr. 1. Porovnanie kvality rekonštrukcie navrhnujetej metódy PM s klasickou metódou OMP a waveletov mexický klobúk a Symlet4 pre rôzne faktory D



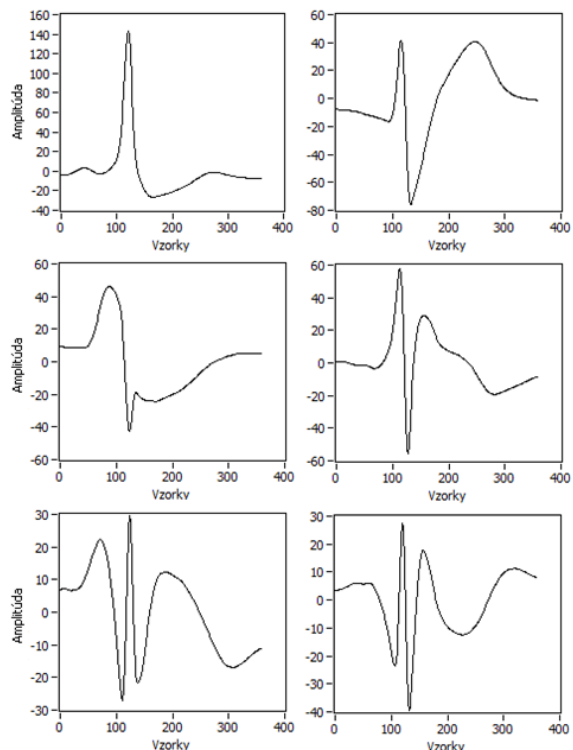
Obr. 2. Príklad priebehu rekonštruovaného navrhnutou metódou pri $CR=9,43$ a $PRMD=13,7\%$

IV. KS EKG S REKONŠTRUKCIOU NORMALIZOVANÝM SLOVNÍKOM

Metóda rekonštruje KS EKG pomocou normalizovaného agnostického slovníka vytvoreného metódou PCA, pričom sa signál bude spracovávať po rámcoch s variabilnou dĺžkou, ktoré sú synchronizované so slovníkom.

A. Kompresia

Vstupný signál sa rovnakým spôsobom ako v predošlej kapitole vzorkuje bežným AČP a za pomoci QRS detektora sa rozdelí na rámce. Použitý QRS detektor je rovnaký ako v predošlom prípade. Takto získané rámce \mathbf{x}_i sa už ale nijako neupravujú a priamo sa komprimujú násobením maticou náhodných čísel Φ_i podľa rovnice (2). Veľkosť matice Φ_i je $M_i \times N_i$, kde N_i je rovné počtu vzoriek príslušného vstupného rámca \mathbf{x}_i , M_i je opäť dané požadovaným pevne nastaveným decimálnym faktorom D (6) a obsahuje pseudonáhodnú postupnosť s Bernoulliho rozdelením pravdepodobnosti. Výstupom je iba vektor \mathbf{y}_i a pôvodná dĺžka rámca N_i . V uvedenom prípade tak kompresný pomer $CR \approx D$.



Obr. 3. Prvých 6 báзовých funkcií v stĺpcoch slovníka Ψ^2

B. Vytvorenie slovníkov

Pre rekonštrukciu bolo uvažované použiť dva druhy slovníkov. Prvý je takzvaný špecifický, ktorý je vytvorený z priebehov, medzi ktorými sa nachádza tiež priebeh, ktorý sa pokúšame rekonštruovať. Druhý je takzvaný agnostický, a je vytvorený z priebehov, ktoré naopak neobsahujú práve rekonštruovaný priebeh. Preto bola celá databáza arytmií MIT-BIH rozdelená na dve polovice (2×24 záznamov) a boli vytvorené dva slovníky, ktoré označme ako Ψ^1 a Ψ^2 . Slovník Ψ^1 je vytvorený zo záznamov č.100-200, a môže byť preto použitý ako špecifický pre rekonštrukciu záznamov č.100-200, pričom je agnostický pre rekonštrukciu záznamov č.201-234. Podobne slovník Ψ^2 je vytvorený zo záznamov č.201-234, pre ktoré je špecifický, no naopak je agnostický pre č.100-200.

Prvý kanál všetkých záznamov bol pomocou QRS detektora v celej svojej dĺžke (30 minút) rozdelený na rámce s variabilnou dĺžkou metódou opísanou v predošlej sekcii. Tým spôsobom bolo získaných dokopy asi 50.000 rámcov z 24 záznamov, z ktorých každý sa normalizoval v amplitúde, a tiež v čase prevzorkovaním na jednotnú dĺžku 360 vzoriek (1 sekunda pri vzorkovacej frekvencii 360Hz) s pomocou splajnovej interpolácie. Z normalizovaných priebehov sa vytvorili slovníky Ψ^1 a Ψ^2 pomocou PCA, pričom vo výslednom slovníku sa ponechalo v stĺpcoch len prvých P zo všetkých komponentov, ktoré obsahujú najväčšiu energiu. Rozmer matíc Ψ je tak $360 \times P$. Tým, že jednotlivé rámce, z ktorých je slovník vytvorený obsahujú takmer vždy jeden srdcový cyklus s iným priebehom (prípadne artefakty) je predpoklad, že počet komponentov P potrebných na

rekonštrukciu bude menší ako v prípadoch, kedy je slovník tvorený rámcami s konštantnou dĺžkou.

C. Rekonštrukcia


Vzhľadom na to, že metóda kompresie rozdelí signál na rámce s variabilnou dĺžkou, nie je možné použiť maticu básových funkcií s pevným rozmerom. V našom prípade matica Ψ_i s rozmerom $N_i \times P$, je získaná prevzorkovaním stĺpcov slovníka resp. na pôvodnú dĺžku rámca N_i . Takým spôsobom je možné použiť rovnaké priebehy básových funkcií pre akúkoľvek dĺžku rámca. Rámec sa následne bude rekonštruovať hľadaním pseudoinverznej matice podľa rovnice (5). Rekonštruované rámce sa následne poskladajú za sebou, čím vznikne úplný rekonštruovaný EKG signál.

D. Výsledky


Metóda bola vyskúšaná pre prvých 10 srdcových cyklov všetkých záznamov MIT-BIH, pričom boli menené hodnoty D a P . Kvalita rekonštrukcie pri použití špecifického slovníka sa od agnostického líši len minimálne. Pretože je v praxi výhodnejšie použiť agnostický slovník, priemerné hodnoty PRMD pre celú databázu sú uvedené na obr.4 pre rekonštrukciu agnostickým slovníkom.

Z uvedených výsledkov vidieť, že je možné nájsť určitú hodnotu D , od ktorej je chyba rekonštrukcie len málo závislá na počtu básových funkcií v slovníku P . S rastúcim kompresným pomerom tak stačí menej básových funkcií P pre dosiahnutie rovnakej kvality rekonštrukcie. V prípade, ak $P < 50$ je počet básových funkcií nedostatočný na imitáciu signálu aj v nekomprimovanej forme (kedy $D=1$). Príklad rekonštrukcie signálu je na obr. 5.

Pri konštantnej dĺžke, rámca ako je to v metódach [18], [14] môže rámec obsahovať viac ako jeden srdcový cyklus, ktorý nie je žiadnym spôsobom synchronizovaný s rekonštruovaným signálom. V [14] je analyzovaný vplyv počtu funkcií v slovníku, ktorý je natrénovaný pomocou algoritmu K-SVD nesynchronizovanými rámcami s pevnou dĺžkou 256 vzoriek, pričom je ukázané, že pre faktor $D=8$ a $PRMD < 14\%$ je potrebný slovník s $P > 5000$. V porovnaní s výsledkami na obr.4 je v našom prípade pre $D=8$ potrebné iba $P \geq 100$, pričom $PRMD < 10\%$. Treba však brať do úvahy, že v našom prípade je slovník potrebné prevzorkovať.



Obr. 4. Závislosť PRMD od faktora D pri rekonštrukcii agnostickým slovníkom pre rôzne počty básových funkcií P



Obr. 5. Príklad rekonštrukcie záznamu č.123 pomocou agnostického slovníka pre $D=8$, $P=300$ s $PRMD=6,25\%$

Výhodou tejto metódy je, že v porovnaní s predchádzajúcou zo sekcie III. vedie k oveľa lepšej kvalite rekonštrukcie a v prípade PM podstatne menšej výpočtovej náročnosti. Nevýhodou je potreba niekoľkých záznamov navzorkovaných klasickým spôsobom pre vytvorenie slovníka, ktorý sa musí pred rekonštrukciou každého komprimovaného rámca celý prevzorkovať. Záznamy pre vytvorenie slovníka však nemusia byť špecifické, a je tak možné použiť akékoľvek dostupné záznamy.

V. REKONŠTRUKCIA KS EKG POUŽITÍM SLOVNÍKA TVORENÉHO SYNTETICKÝMI PRIEBEHMI

Kombináciou predošlých dvoch metód rekonštrukcie bola navrhnutá ešte jedna pokusná. Využíva parametrický model EKG signálu pre vytvorenie slovníka v priebehu rekonštrukcie, pričom tento sa vytvára pre každý jeden rekonštruovaný záznam zvlášť, a to bez potreby akýchkoľvek vopred známych priebehov na jeho natrénovanie. Na začiatku rekonštrukcie akéhokoľvek záznamu je tak slovník prázdny a postupne sa dopĺňa modelovanými priebehmi hľadanými metódou PM (sekcia III.), ktoré čo najlepšie pasujú do konkrétneho rekonštruovaného signálu. Ako náhle je v slovníku dostatok modelovaných priebehov, je možné rekonštrukciu toho istého priebehu spustiť znova, iba s použitím vytvoreného slovníka, pričom je predpoklad, že táto rekonštrukcia bude mať vyššiu kvalitu, ako po prvom spustení s použitím PM.

Použitá metóda kompresie je takmer totožná s metódou uvedenou v sekcii III., rozdiel spočíva vo vynechaní lineárnej kvantizácie, preto táto nebude opisovaná znova.

A. Rekonštrukcia


V tomto prípade je možné s výhodou využiť báзовé funkcie platné pre jeden z rámcov aj pre nasledujúce rámce, pretože po sebe idúce srdcové cykly sa na seba obyčajne podobajú, no bude ich potrebné prevzorkovať na rovnakú dĺžku. Algoritmus teda začne rekonštrukciou prvého rámcu pomocou PM a ihneď pokračuje na druhý, kde skúsi rekonštruovať prevzorkovaným priebehom z predošlého rámcu podľa rovnice (5). Overí, či $MSE < \epsilon$, kde ϵ je nastavená prahová hodnota chyby riešenia:

$$MSE = \frac{1}{M} \sum_{m=1}^M (\mathbf{y} - \hat{\mathbf{y}})^2 \quad (10)$$

pričom $\hat{\mathbf{y}} = \Phi \hat{\mathbf{x}}$. Ak MSE nevyhovuje podmienke, daný rámec sa rekonštruje pomocou PM a podobným spôsobom pokračuje na ďalší, pričom teraz už môže použiť báзовé funkcie vytvorené z priebehov predošlých rámcov. Po skončení rekonštrukcie tak získame priebeh, ktorý sa dá ešte ďalej vylepšiť opätovným spustením algoritmu avšak už s použitím báзовých funkcií získaných pri predchádzajúcom spustení.

B. Výsledky

Pomocou uvedeného algoritmu bolo pokusne zrekonštruovaných prvých 10 srdcových cyklov každého záznamu z databázy. Použité boli decimálne faktory $D=5$ a $D=8$. Optimálne nastavenie prahu ϵ je pre dosiahnutie čo najlepšej kvality rekonštrukcie kritické. Bolo zistené, že pre každý záznam je jeho optimálna hodnota iná, takže nie je možné použiť jedno nastavenie univerzálne pre akýkoľvek záznam. Vzhľadom na to bola rekonštrukcia vyskúšaná pre rôzne hodnoty $\epsilon \in \{1; 0,8; 0,5; 0,3; 0,1; 0,05; 0,03; 0,02; 0,01\}$. Výsledky s najmenšími hodnotami $PRMD$ boli zvolené pre výpočet priemernej hodnoty pre celú databázu, ktorá je 11,23% pre $D=5$ a 14,79% pre $D=8$. V porovnaní so samostatnou metódou PM je kvalita rekonštrukcie podstatne lepšia, no nie lepšia ako pri použití agnostického slovníka. Nevýhodou metódy s PM bolo, že sa pomocou DE nepodarilo vždy presne v rekonštruovanom signáli trafiť modelom do všetkých vln, a niektoré tak v signáli mohli úplne chýbať. Opakovaným spustením DE sa tento problém dal občas odstrániť. Chýbajúca vlna sa vtedy v syntetickom signáli objaví, no zas môže chýbať niektorá iná vlna. Vytvorením slovníka z priebehov získaných opakovaným spustením DE sa tento problém potlačí, pretože sa tieto priebehy prekryjú a navzájom doplnia. V priemere je tak potrebných asi 20 báзовých funkcií v slovníku, čo zodpovedá asi dvom spusteniam DE na každý rámec. Podstatnou nevýhodou je potreba nastavenia prahu ϵ , ktorý musí byť pred spustením rekonštrukcie známy. Príklad rekonštruovaného priebehu je na obr. 6.



Obr. 6. Príklad rekonštrukcie záznamu č.228 slovníkom tvoreným syntetickými priebehmi

VI. ZÁVER

KS je v oblasti spracovania EKG signálov stále experimentálnou metódou, ktorá sa v praxi bežne nevyužíva. Kvalita rekonštrukcie signálu tu stále zostáva predmetom rôznych zlepšení. V článku boli stručne predstavené 3 novo navrhnuté netradičné metódy rekonštrukcie pre KS EKG, z ktorých každá vykazuje lepšiu kvalitu rekonštrukcie v porovnaní s klasickou metódou použitím slovníka waveletových funkcií a algoritmu OMP pre kompresné pomery väčšie ako 4. Posledná z uvedených metód zostáva iba pokusnou, vzhľadom na to, že nie je jasný postup nastavenia prahu MSE pre dosiahnutie najlepšej kvality rekonštrukcie. Uvedený problém by bolo možné zrejme odstrániť náhradou metódy hľadania pseudoinverznej matice za algoritmus OMP, čo zostáva úlohou pre budúce riešenie.

LITERATÚRA

- [1] J. Cheng, L. Xia, Ch. Ma, Y. Lian, X. Xu, C.P. Yue, Z. Hong, P.Y.A. Chiang, "A near-threshold, multi-node, wireless body area sensor network powered by RF energy harvesting," Custom Integrated Circuits Conference (CICC), 9-12 October 2012. San Jose, CA, USA, IEEE, vol.1, no.4, 9-12.
- [2] S. Ullah, H. Higgins, B. Braem, B. Latre, C. Blondia, I. Moerman, S. Saleem, Z. Rahman, K.S. Kwak, "A comprehensive survey of wireless body area networks," Journal of Medical Systems, 36 (3), 2011, 1065-1094.
- [3] S. Feng-Tso, C. Kuoand, M. Griss, "Power efficiency through activity recognition (for ECG-based sensing)," 5th International Conference on Pervasive Computing Technologies for Healthcare (Pervasive-Health), 23-26 May 2011. Dublin, Ireland, IEEE, 115-122.
- [4] D. Donoho, "Compressed sensing," In: IEEE Transactions on Information Theory, vol. 52, no. 4, 2006, p. 1289-1306. ISSN 0018-9448

- [5] S. Foucart, H. Rauhut, *A Mathematical Introduction to Compressive Sensing*, Birkhäuser Applied and Numerical Harmonic Analysis Series, Springer Science+Business Media New York 2013, ISBN 978-0-8176-4948-7
- [6] M. Davenport, M. Duarte, Y. Eldar, G. Kutyniok, „Introduction to compressed sensing,“ In: *Compressed Sensing, Theory and Application*, Eds. New York, Cambridge University Press, 2012, p. 1-64.
- [7] P. Dolinský: „Principles and Applications of Compressed Sensing in Biomedical Signal Acquisition,“ In: *SCYR 2016, TU Košice*, 2016, p. 206-209. ISBN 978-80-553-2566-8
- [8] A.L. Goldberger, L.A.N. Amaral, L.Glass, J.M. Hausdorff, P.Ch. Ivanov, R.G. Mark, J.E. Mietus, G.B. Moody, C-K Peng, H.E. Stanley, „PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals,“ *Circulation* 101(23), 2000, p. 215-220
- [9] G .Fung, O.L. Mangasarian, „Equivalence of minimal ℓ_0 and ℓ_p -norm solutions of linear equalities, inequalities and linear programs for sufficiently small p ,“ In: *Journal of Optimization Theory and Applications*, 2011, Vol. 151 (1), 1–10.
- [10] L. Michaeli, J. Šaliga, P. Dolinský, I. Andráš: „Optimization Paradigm in the Signal Recovery after Compressive Sensing,“ In: *Measurement Science Review*, Vol. 18, Walter de Gruyter GmbH, Berlin 2018, ISSN 1335-8871
- [11] R. Storn, K. Price, „Differential Evolution - A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces,“ In: *Journal of Global Optimization*, Vol. 11, 1997, p. 341-359
- [12] R. Xiao, M. Li, M. Law , P. Mak, R. P. Martín, „Ultra-low power QRS detection using adaptive thresholding based on forward search interval technique,“ In: *International Conference on Electron Devices and Solid-State Circuits (EDSSC)*, IEEE, 2017, Hsinchu, Taiwan
- [13] P. Dolinský, I. Andráš, L. Michaeli, J. Šaliga, „High Sensitivity Experimental QRS Detector,“ In: *Radioelektronika 2018*, IEEE, p. 1-4, ISBN 978-1-5386-2485-2
- [14] D. Craven, B. McGinley, L. Kilmartin, M. Glavin, E. Jones, „Energy-efficient Compressed Sensing for ambulatory ECG monitoring,“ In: *Computers in Biology and Medicine*, vol. 71, 2016, p. 1-13. ISSN 0010-4825
- [15] P.E. McSharry, G.D. Clifford, L. Tarassenko, L.A Smith, “A Dynamical Model for Generating Synthetic Electrocardiogram Signals,“ In: *IEEE Transactions on Biomedical Engineering*, Vol. 50 (3), 2003, p.289-294
- [16] Y. Lu, J. Yan, Y. Yam, „Model-Based ECG Denoising Using Empirical Mode Decomposition,“ In: *IEEE International Conference on Bioinformatics and Biomedicine*, IEEE, 2009, Washington, DC, USA, p.192-196.
- [17] J.A. Tropp, A.C. Gilbert, „Signal Recovery From Random Measurements Via Orthogonal Matching Pursuit,“ In: *IEEE Transactions on Information Theory*, Vol. 53 (12), 2007, p. 4655-4666
- [18] M. Fira, L. Goras, C. Barabasa, „Reconstruction of compressed sensed ECG signals using patient specific dictionaries,“ *International Symposium on Signals and Systems ISSCS2013*. 11-12 July, Iasi, Romania, IEEE

Integrované širokopásmové senzorové systémy emitujúce M-postupnosti a ich vybrané aplikácie

Martin Kmec
Imsens GmbH
Ilmenau, Nemecko
martin.kmec@ilmsens.com


Pavol Galajda
Katedra elektroniky a multimediálnych telekomunikácií,
FEI, TU Košice
Košice, Slovensko
pavol.galajda@tuke.sk

Abstrakt—Neustále rozširovanie oblastí použitia širokopásmových (UWB) senzorových systémov najmä v spojení s výzvami PRIEMYSLU 4.0 spôsobuje, že sa dostávajú do stredu pozornosti stále väčšieho množstva potenciálnych aplikácií a teda koncových užívateľov. Toto so sebou zákonite prináša potrebu nových a výkonnejších UWB senzorov. Všeobecné požiadavky na tieto systémy sú: vysoká celková účinnosť systému čo zvyčajne koreluje s nízkou spotrebou energie, flexibilita pracovnej šírky frekvenčného pásma, modularita použitej architektúry, istá úroveň zabudovanej inteligencie, spoľahlivosť a robustnosť. Na druhej strane by mali nové systémy v ideálnom prípade vykazovať malé rozmery a, v prípade ich priemyselnej výroby, primerané (značí ideálne minimálne) výrobné náklady. Tento trend a rôznorodosť aplikačne špecifických požiadaviek majú za následok existenciu širokého spektra UWB senzorových konceptov. Jedným z nich je rodina širokopásmových senzorových systémov emitujúcich M-postupnosti, o čom pojednáva tento článok.

Keywords—širokopásmové senzorové systémy; M-postupnosti; integrované obvody; lokalizácia a detekcia; analýza mlieka; radar; dojenie kráv; impedančná spektroskopía

I. ÚVOD

Koncepty aktívnej senzoriky majú vo všeobecnosti jeden spoločný menovateľ – na ilumináciu alebo stimuláciu skúmaného cieľa využívajú svoj vlastný zdroj energie (napr. mechanické vlny, elektromagnetické vlny a i.). Aktívny senzor emituje túto stimulačnú energiu smerom k skúmanému cieľu, ktorý môže byť niekedy všeobecnejšie nazývaný aj ako MUT (z angl. Medium Under Test). Po interakcii s cieľom je reflektovaná energia, prípadne časť rozptýlenej stimulačnej energie, detekovaná prijímacím elementom (v ďalšom aj ako aktuátor alebo žiarič, t.j. anténa, sonda a pod.) a následne spracovaná v prijímači (pozri Obr. 1). Je teda zrejmé, že medzi výhody aktívnych senzorov patrí ich možnosť vykonávať merania v podstate kedykoľvek a kdekoľvek, nezávisle na situácii alebo čase. Avšak na druhej strane, drvivá väčšina aktívnych systémov vyžaduje generovanie presne definovaného, resp. senzorovému systému veľmi dobre známeho, druhu a množstva stimulačnej energie určenej na potrebnú stimuláciu cieľov. Ilustrácia na Obr. 1 **Chyba! Nenašiel sa žiaden zdroj odkazov.**znázorňuje elementárnu myšlienku aktívnej senzoriky.



Obr. 1 Všeobecný prípad aktívnej senzoriky – bistatická realizácia.

V prípade aktívnych UWB senzorov (niekedy uvádzané aj ako UWB radar¹, alebo ako kombinácia týchto dvoch pojmov, vid' napr.[1]) je podstatou stimulácia cieľov (alebo všeobecne MUT) elektromagnetickými vlnami vyznačujúcimi sa veľkou šírkou frekvenčného pásma. Pozn.: toto je platné len za zjavného predpokladu, že prijímač je tiež v stave prijímača a spracovať odpovedajúce signály. Dôvody a dôsledky použitia veľkej šírky pásma pre senzorové systémy krátkého dosahu sú obširne spracované v [2]. Pojem šírka pásma sa vzťahuje na frekvenčné pásmo v ktorom sa rozprestiera stimulačný signál a v rámci ktorého je zariadenie v stave pracovať s akceptovateľnými chybami. Formulácia „veľká šírka pásma“ musí byť braná do úvahy v relácii k normalizovaným kritériám, t.j. celková šírka pásma musí podliehať špecifickým ohraničeniam. Ako je možné vidieť v tematicky orientovanej literatúre, napr. v [3]-[7] alebo už v uvádzanej [2], je definovanie UWB špecifických ohraničení nečakane komplexnou záležitosťou. V prvom rade to prirodzene závisí na tom ktorom zdroji definície a teda nutne na početnosti inštitúcií zaoberajúcich sa tematikou UWB počas jej celej histórie. Tak napríklad podľa DARPA² zo začiatku 1990-ych rokov môžu elektromagnetické vlny, ktoré majú okamžitú zlomkovú frekvenčnú šírku pásma väčšiu ako 25%, byť klasifikované ako UWB. Pre zaujímavosť, výkonové limity v hraničných frekvenčných bodoch neboli v prvopočiatkoch explicitne definované, a to pravdepodobne preto, že sa predpokladali zaužívané body troj-decibelového útlmu alebo body potlačenia až o 20 dB a to s ohľadom na skoršie postoje

¹ RADAR - skrátená forma od Radio Detection and Ranging (orig. Radio Aircraft Detection and Ranging)

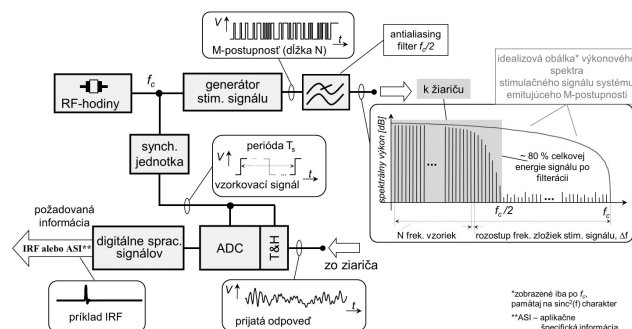
² DARPA - Defense Advanced Research Projects Agency, USA

vo vzťahu k UWB systémom a ich aplikáciám [5]. Neskôr bol pôvodný 25%-ný limit zlomkovej šírky pásma znížený na technologicky výhodnejších 20% a frekvenčné hranice sa širšou dohodou ustanovili v bodoch pri ktorých dochádza k útlmu výkonového spektra o 10 decibelov. Okrem toho, regulačná organizácia považujú za UWB aj signály s absolútnou šírkou pásma (znova s hranicami v bodoch s poklesom o 10 dB) väčšou ako 500 MHz (pozn.: EU štandard hovorí o šírke ≥ 50 MHz).

Zatiaľ je zrejmé, že podstatou aktívnej UWB senzorky je získavanie informácií o testovaných cieľoch použitím tzv. širokopásmovej stimulácie. V ďalšom je potrebné pripomenúť, že väčšina sledovaných cieľov alebo MUT patrí do kategórie lineárnych časovo invariantných (LTI, z angl. linear time invariant) systémov, vid' [1] alebo [2], a že správanie sa každého LTI systému môže byť opísané jeho impulzovou (IRF, z angl. impulse response function) alebo frekvenčnou (FRF, z angl. frequency response function) charakteristikou. Vyjadrenie pomocou IRF je často označované charakteristikou v časovej oblasti. Ekvivalentne FRF, ktorá je spektrálnym náprotivkom³ IRF, charakterizuje LTI systém vo frekvenčnej oblasti. V konečnom dôsledku je teda cieľom akéhokoľvek aktívneho UWB senzora získať potrebné informácie na čo najpresnejšie určenie jednej (alebo oboch) z týchto charakteristík.

II. SENZOROVÉ SYSTÉMY EMITUJÚCE M-POSTUPNOSTI

Princíp senzorevho systému krátkeho dosahu využívajúceho vysokofrekvenčné M-postupnosti na stimuláciu skúmaných objektov a digitálnu koreláciu v prijímači bol prvý krát predstavený v roku 1999 [8]. Tento koncept predstavuje zaujímavú alternatívu voči etablovaným UWB systémom ktoré vyzívajú impulzy alebo rôzne rozmiatané monotónne signály (napr. systémy s frekvenčnými moduláciami) a je stále považovaný (aspoň podľa vedomostí autorov) za svetový unikát, pričom účelnosť jeho využitia vo veľkom množstve senzorevých aplikácií je v súčasnosti reálnym faktom [9]. Detailný princíp činnosti ako aj porovnanie s existujúcimi UWB systémami bol opísaný vo vyššie uvedenej literatúre, najmä však v [2] príp. [9]. Elementárnu myšlienku jeho fungovania zobrazuje ilustrácia na Obr. 2.



Obr. 2 Základná štruktúra senzorevho systému založeného na využití M-postupnosti, spolu s ilustráciami významných UWB signálov (vrátane príkladu výslednej IRF).

³ Napr. po Fourierovej transformácii

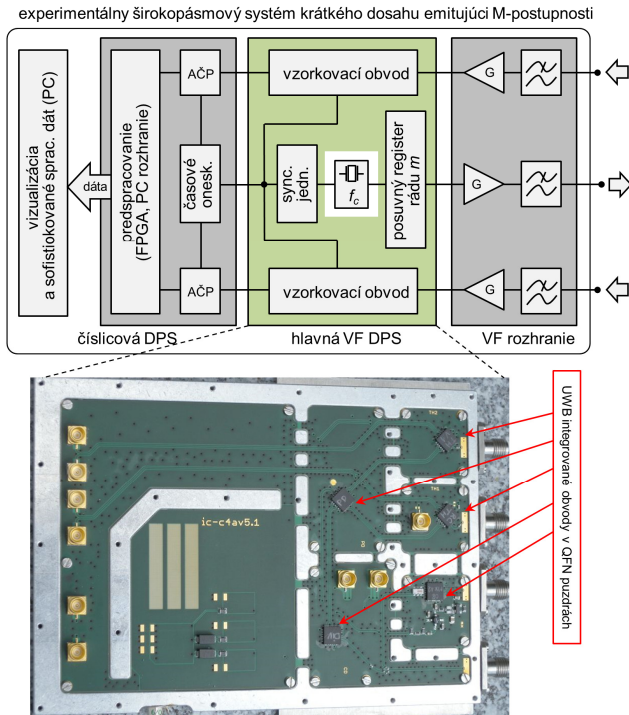
Ako ilustruje Obr. 2, časová základňa systému je riadená stabilným vysokofrekvenčným oscilátorom (RF-hodiny). Tento poskytuje monotónny riadiaci signál s frekvenciou f_c (tiež označované aj ako centrálné hodiny), ktorým je na jednej strane napájaný generátor stimulačného signálu, t.j. špeciálne navrhnutý vysokofrekvenčný posuvný register dĺžky m a na strane druhej synchronizačná jednotka, t.j. vysokofrekvenčná binárna delička rádu n . Stimulačný signál generovaný generátorom je potom vedený do koncového rozhrania (všeobecne žiariča) cez dolnopriepustný filter (anti-aliasing filter). Tento signál je po interakcii s MUT prijímaný širokopásmovým vzorkovacím obvodom (T&H), pracujúcim v móde podvzorkovania a ďalej spracovaný v analógovo číslicovom prevodníku ako aj bloku digitálneho spracovania dát. Základné špecifiká takýchto systémov možno zhrnúť nasledovne:

- relatívne jednoduché generovanie stimulačných signálov pomocou posuvných registrov,
- možnosť jednoduchej integrácie vysokofrekvenčnej systémovej časti na jednom čipe, za predpokladu použitia vhodného technologického uzla, napr. 0,35μm alebo 0,25μm BiCMOS,
- vzhľadom na to, že vstupno/výstupné signály majú činiteľ výkyvu blízko 1, nemusia obvody rozhrania s MUT spracovávať signály s vysokými napätovými špičkami,
- v prípade použitia viacerých technologických uzlov, napr. kombinácie 0,25μm BiCMOS s 65 nm CMOS, relatívne priamočiara integrácia vo forme systému v puzdre - SiP (z angl. System in Package),
- použitie rigidného interného časovania a synchronizácie, čoho výsledkom je časová nestabilita (jitter) pod 10 fs,
- v prípade vylepšených topológií systému, ako napr. uvedené v [10] alebo [9], zvýšená flexibilita pracovného frekvenčného pásma, vďaka eliminácii potreby tzv. anti-aliasing filtra.

III. MONOLOITICKÁ INTEGRÁCIA SYSTÉMU

Poznatky získané počas realizácií tzv. viacčipových radarov emitujúcich M-postupnosti, napr. Obr. 3, a [11], [12] alebo [13] a teda z návrhov jednotlivých aplikačne špecifických integrovaných obvodov (IO), motivovali prvú monolitickú integráciu kompletnej RF časti radarovej elektroniky na jednom čipe, SoC (z angl. System on Chip). Kľúčové výhody SoC riešení sú zvyčajne v celkovom zlepšení parametrov a spoľahlivosti, ako aj znížení ceny systému. Prvá je primárne spôsobená SoC vlastnou minimalizáciou parazitných prvkov v prepojeniach jednotlivých funkčných makro-blokov konečného systému, ako aj znížením teplotných gradientov (a ich nežiaducim zmenám) v systéme. Druhá je logicky výsledkom miniaturizácie, ktorá je úmerná úrovni integrácie. Okrem toho sa znižujú požiadavky na napájanie, keďže dochádza k zmenšeniu počtu prúdovo náročných 50-Ω-ých rozhraní, ktoré sú zvyčajne potrebné, ak sú signály smerované mimo čipu. Popri uvádzaných výhodách, má monolitická

integrácia na jednom čipe aj niekoľko menej pozitívnych aspektov. V prvom rade ide všeobecne o nežiadúce presluchy signálov najmä vo viackanálových systémoch. Presluchy sú tiež často skloňovanou témou najmä ak čip obsahuje analógové a digitálne stavebné bloky na jednom substráte. Problém sa však stáva najmarkantnejším v prípade systémov ktoré pracujú s vysokofrekvenčnými a širokopásmovými signálmi, kedy sú súbory opatrení platné pri úzkopásmových systémoch použiteľné len podmienčne.

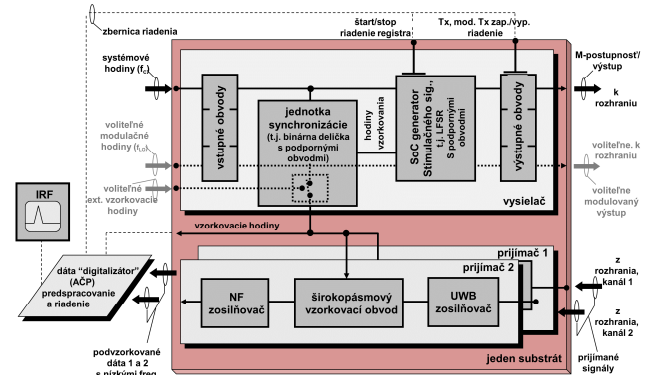


Obr. 3 SoB modul 1Tx2Rx radaru, zostavený s viacerých aplikačne špecifických IC v QFN puzdrách (dizajn DPS a mechaniky P. Rauschenbach).

Pre ilustráciu (Obr. 3), zatiaľ čo sofistikované viacčipové riešenie SoB (z angl. System on Board) s kovovými výplňami v doske plošného spoja (DPS) dosahuje Tx-Rx izoláciu až 120 dB v celom frekvenčnom rozsahu záujmu (nom. 0 – 12 GHz), typicky dosiahnuteľná širokopásmová izolácia v rámci jedného čipu je len niekde na úrovni 60 - 70 dB, napr. [14], [15]. Okrem toho, pokiaľ nie sú pri puzdrení implementované špeciálne riešenia napr. [16], tak sa Tx-Rx izolácia zapuzdreného obvodu ešte ďalej zhoršuje. Napriek tomu, jedinečné vlastnosti diskutovaných radarových systémov z hľadiska ich stability [2] a z toho vyplývajúcich možností kalibrácie [17] umožňujú eliminovať tieto nedostatky na akceptovateľné minimum pre väčšinu uvažovaných aplikácií.


Obr. 4 znázorňuje zjednodušenú blokovú topológiu SoC a periférie pre digitalizáciu signálu, ako aj pred-spracovanie dát. Topológia čipu je zvolená tak, aby SoC prirodzene pokrýval aplikácie vyžadujúce minimálne konfiguráciu radaru s jedným vysielateľom a dvoma prijímačmi. Architektúra jadra je založená na pôvodnom koncepte prezentovanom na Obr. 1. SoC je vybavený dodatočnými vstupno/výstupnými portami

a funkčnými modulmi tak, aby bola zabezpečená jednoduchá flexibilita nastavenia pracovného frekvenčného pásma, paralelizácia viacerých SoC vo viackanálových MIMO (z angl. Multiple Input Multiple Output) systémoch [13], alebo kalibrácia zariadenia. Pozri tiež [2], [10] alebo [15]. Tento súbor úprav podporuje použitie uvádzaného integrovaného obvodu pre väčší počet aplikácií. Napríklad viackanálová topológia senzora je rozhodujúca pre zobrazovanie [18], alebo lokalizáciu [19] s vysokým rozlíšením a kalibračná schopnosť je užitočná pre samostatné snímače UWB, ktoré sú implementované napr. v systémoch testovania alebo charakterizácie elektronických prvkov alebo materiálov [20].



Obr. 4 Zjednodušená architektúra SoC hlavice systému emitujúceho M-postupnosti.

Konkrétna realizácia SoC s architektúrou ako na Obr. 4, v 0,25 μm SiGe:BiCMOS technológii s $F_T = 110$ GHz a $F_{\text{max}} = 180$ GHz na jednom substráte má rozmery 1 x 2 mm². Vyrobený integrovaný obvod je napájaný z 3.3 V zdroja a jeho celková spotreba je pod 350 mA. Na Obr. 5 je mikrofotografia finálneho obvodu.



Obr. 5 Mikrofotografia SiGe SoC čipu s označenými blokmi, izolačnými štruktúrami a oblasťami izolačných (oddelovacích) štruktúr ako aj rozhraniami. Veľkosť zobrazeného čipu je 2 x 1 mm².


IV. VYBRANÉ APLIKÁCIE SYSTÉMU

Jedinečná kombinácia integrovateľnosti, multikanálových schopností, signálovej stability a kalibrovateľnosti senzorových

systémov emitujúcich M-postupnosti podstatne rozširuje horizont možných aplikácií, a to či už v laboratóriu na úrovni základného alebo aplikačného výskumu, ale aj mimo laboratórneho prostredia – t.j. v priemysle, napr. [21]-[27]. Takto môžu byť diskutované senzory použité na presné merania impedancie, merania vzdialenosti s vysokým rozlíšením, alebo bezkontaktné detekcie pohybov, alebo dokonca zmien impedancií. Pritom, impedančné, t.j. dielektrické zmeny, alebo pohyby, ktoré snímače detekujú, môžu mať rôzne zdroje a príčiny v čom spočíva rôznorodosť (až jedinečnosť) možných aplikácií.

Na jednej strane je napríklad možné odhaliť mikro-pohyby orgánov v tele a korigovať nedokonalosti MRT – magnetickej rezonančnej tomografie [24], bezkontaktné detekovať zmeny zloženia tkanív s cieľom včasnej detekcie nádorových ochorení [23], [25], alebo detekovať hmyz, napr. termity v drevených konštrukciách [28]-[30].


Okrem toho, špeciálne *impedančná spektroskopia* prešla v posledných desaťročiach obrovským vývojom. Prvotne išlo najmä o meranie odchýlok dielektrických vlastností potravín od normálu a týmto o zabezpečenie kontinuity kvality pri ich výrobe a skladovaní [31]. V súčasnosti je v mnohých oblastiach priemyslu, poľnohospodárstva, kontrolných úradov a pod. monitorovanie impedančných vlastností vyrábaných látok, ale aj látok vstupujúcich do výrobných procesov nutnosťou. Tu sú žiadané predovšetkým také meracie metódy, ktoré umožňujú detekciu kontinuálneho stavu v reálnom čase a ideálne bez zásahu do výrobného procesu, t.j. bezkontaktné. Ako príklad možno uviesť meranie zloženia mlieka, t.j. obsahu laktózy, tukov, bielkovín a močoviny pri dojení kráv v reálnom čase pomocou diskutovaného širokopásmového systému emitujúceho M-postupnosti, ako ukazuje Obr. 6.



Obr. 6 Pilotný pokus merania zloženia mlieka v reálnom prostredí počas dojenia kráv.

Podstatou merania na Obr. 6 je určenie vlastností impulznej odzvy koplánarneho vlnovodu, ktorý je v nepriamom kontakte

s testovanou kvapalinou – čerstvým mliekom, t. j. dielektrickým médiom, a vyhodnotenie jej prenosových vlastností v časovej oblasti. Pozn. z [32] je zrejme, že prenosové vlastnosti koplánarneho vlnovodu sú závislé na dielektrickom prostredí v ktorom sa nachádza. Obr. 7 znázorňuje zjednodušenú schému merania.



Obr. 7 Schéma merania zloženia kvapalných látok, napr. mlieka.

Vyhodnocovanie nameraných dát ešte nie je ukončené, no je možné uviesť, že dosiahnutá presnosť určenia percentuálneho obsahu hlavných zložiek mlieka spĺňa požiadavky kladené na daný druh systému.

Na strane druhej, možno zaradiť do zoznamu aplikácií tie, ktoré sú založené na fakte, že stimulačné radarové UWB vlny môžu preniknúť väčšinou stavebných materiálov a to aj pri veľmi nízkom emitovanom výkone (tisíckrát slabšom ako vyžarovanie mobilných telefónov), čo otvára ďalší rad aplikácií systémov emitujúcich M-postupnosti, napr.:

Život s podporou okolia (AAL, z angl. Ambient assisted living): Najmä v západnom svete sa percento starších ľudí v budúcnosti výrazne zvýši. To bude znamenať dramatické výzvy pretože títo ľudia potrebujú starostlivosť a podporu. Ich sofistikované monitorovanie UWB systémami môže značne pomôcť zabezpečiť ich zdravie a bezpečnosť. Iba v Nemecku, ročne viac ako 500 000 ľudí vo veku nad 65 rokov spadne v domácom prostredí [33], [34]. 3% z nich sa bez externej pomoci nemôže opäť postaviť, takže zostávajú v nepohodnej situácii počas niekoľkých hodín, alebo dokonca niekoľkých dní, kým získajú pomoc [34]. Implementácia UWB systémov v tomto prípade má aj niekoľko ďalších, síce okrajových, ale nezanedbateľne pozitívnych aspektov. A to, na jednej strane nepredstavuje zásah do súkromia monitorovanej osoby, ako tomu je v prípade použitia optických (kamerových) zariadení, a na strane druhej, nie je potrebné bezprostredné spojenie s monitorovanou osobou, ako tomu je v prípade použitia monitorovacích náramkov a pod. ktoré sú považované za rušivý alebo obmedzujúci element. Zároveň, sú tieto systémy v stave monitorovať sledovaný cieľ cez stenu, alebo cez iný dielektrický (nekovový) materiál – prípad súboru tzv. TWI (z angl. Through wall Imaging) aplikácie. Toto otvára perspektívu použitia moderných UWB radarových systémov pri *detekcii prežívšich po zemetraseniach a snehových lavinách*, kedy je časové okno na záchranu osôb, ktoré uviazli v zrútenej budove (alebo pod snehom), obmedzené iba na málo dní (alebo menej ako hodinu) po katastrofe. V tomto prípade je najdôležitejšou rýchla detekcia a lokalizácia umiestnenia obetí, ktoré prežili, s cieľom usmerniť záchranné sily čo najefektívnejšie [35]. Základná myšlienka spočíva, ako je uvedené vyššie, vo

vlastnosti elektromagnetických vln s frekvenčnou alokáciou v dolnej časti elektromagnetického spektra (do prib. 40 GHz) prenikajú cez stavebné materiály (s výnimkou kovov). V prípade penetrácie týchto vln cez dielektrický materiál, majú tieto tendenciu sa na každom dielektrickom rozhraní, alebo tzv. dielektrickej diskontinuite odraziť, a to nezávisle na tom či je to človek alebo nie. Situáciu sťažuje nehomogenita sutín (alebo snehu). Primárnou úlohou teda je rozlíšiť odrazené vlny od ľudského, tela od tých spôsobených nehomogénnym prostredím. Základné metódy používané pri GPR (z angl. Ground Penetrating Radar) za týchto podmienok zväčša zlyhávajú. Pri riešení tohto problému sa možno oprieť o fakt, že v prípade ľudského tela (za predpokladu, že človek žije) dochádza k jeho tvarovej variácii (dýchanie, priestorovo obmedzené pohyby rúk a nôh), zatiaľ čo prostredie ostáva stabilným. Tieto tvarové variácie spôsobujú časovú moduláciu rozptylu detekovaných vln, čo možno použiť pri spracovaní signálov a extrakcii potrebných informácií [35]-[37] pre záchranné zložky.

V. ZÁVER

Posledný výskum a vývoj na akademickej ale aj priemyselnej pôde ukazuje, že širokopásmové senzorné systémy emitujúce M-postupnosti sú veľmi zaujímavou alternatívou voči etablovaným širokopásmovým systémom a že vďaka svojim kľúčovým vlastnostiam majú enormný potenciál použitia či už teraz, tak aj v budúcnosti.

POĎAKOVANIE

Poďakovanie patrí celému tímu Imsens GmbH, kolegom na bývalej Katedre elektronického merania, Fakulty elektrotechniky a informatiky Technickej univerzity v Ilmenau, a v neposlednom rade aj kolegom Katedry elektroniky a multimediálnych telekomunikácií, Fakulty elektrotechniky a informatiky Technickej univerzity v Košiciach.

REFERENCES

- [1] A. Ruengwaree, "Design of UWB Radar Sensors", dissertation, Kassel University Press, 2007
- [2] J. Sachs, "Handbook of Ultra-wideband Short-Range Sensing, Theory sensors and applications", Berlin: Wiley-VCH, 2012.
- [3] J. D. Taylor, "Ultra-Wideband radar technology", CRC Press. Boca Raton 200, FL. 2000
- [4] M. I. Skolnik, "Radar Handbook", Mc Graw Hill, 1990
- [5] J. D. Taylor, "Ultrawideband Radar, Applications and Design", CRC Press, 2012
- [6] R. Aiello, A. Batra, "Ultra Wideband Systems, Technology and applications", Elsevier Inc., 2006
- [7] K. Sawiak, D. McKeown, "Ultra-Wideband Radio Technology", Wiley 2004
- [8] J. Sachs, P. Peyerl: A New Principle for Sensor-Array-Application. In: Proc. of 16th IEEE Instrumentation and Measurement Technology Conference. Venice, Italy : IMTC, May 1999, S. 1390-1395
- [9] P. Galajda, M. Kmec, A. Galajdová, M. Liptaj, Širokopásmové obvody, technológie a systémy, Košice , 1. Vyd. Technická univerzita 2016. - ISBN 978-80-553-2614-6
- [10] M. Kmec, R. Herrmann, J. Sachs, P. Peyerl, P. Rauschenbach, "Extended approaches for integrated M-sequence based UWB sensors". - In: Ultra-wideband, short-pulse electromagnetics 8 / Conference on Ultra-Wideband Short-Pulse Electromagnetics, UW BSP ; 8 (Albuquerque, NM) : 2006.07.09-14. - New York, NY : Springer (2007), S. 135-142
- [11] J. Sachs, M. Kmec, R. Zetik, Ultra Wideband Radar Assembly Kit, International Geoscience and Remote Sensing Symposium 2005, Seoul, Korea, August 2005
- [12] M. Kmec, M. Helbig, J. Sachs, P. Rauschenbach, "Integrated ultra-wideband hardware for MIMO sensing using pn-sequence approach," Ultra-Wideband (ICUWB), 2012 IEEE International Conference on , vol., no., pp.333,337, 17-20 Sept. 2012
- [13] R. Zetik, M. Kmec, J. Sachs, R. S. Thomä, Real Time MIMO Channel Sounder for Emulation of distributed Ultrawideband Systems, International Journal of Antennas and Propagation, Vol. 2014, Article ID 317683
- [14] A. Helmy, M. Ismail, "Substrate Noise Coupling in RFICs", Springer 2008
- [15] M. Kmec, M. Helbig, R. Herrmann, P. Rauschenbach, J. Sachs, K. Schilling, "M-Sequence Based Single Chip UWB-Radar Sensor" 14th International Symposium on Antenna Technology and Applied Electromagnetics and the American Electromagnetics, ANTEM/AMEREM 2010 Conference, Ottawa, ON, CA, July 2010 - published in Ultra-Wideband Short-Pulse Electromagnetics 10, eds. Frank Sabath, Eric L. Mokole, Springer Science+Business Media New York 2014
- [16] S. Cahill, E. Sanjuan, L. Levine, "Development of 100+ GHz High-Frequency MicroCoax Wirebonds", IMAPS San Diego, Oct. 8-12, 2006
- [17] Herrmann, R. "M-sequence based ultra-wideband radar and its application to crack detection in salt mines, " Ilmenau, Technische Universität, Dissertation, 2011
- [18] Sachs J, Kmec M, Herrmann R, Schilling K, Zetik R, Rauschenbach P (2008) Ultra-Wideband Pseudo-Noise Radar: Principle of function, state of the art, applications. NATO Specialist Meeting SET 120, 27-28 October 2008, Toulouse, France
- [19] Švecová M, Kocur D (2010) Target localization by the method of joining intersections of the ellipses. 11th International Radar Symposium IRS-2010, Vilnius, Lithuania, June 16-18, 2010, Volume 2, Vilnius, GEOZONDAS, 2010, p. 360-363
- [20] J. Sachs, M. Kmec, R. Herrmann, M. Helbig, K. Schilling.: Integrated Pseudo-Noise Device with Network Analyzer Performance for UWB Sensing and Component Test. Proceedings of the International Symposium on Signals, Systems and Electronics (ISSSE), Potsdam, Germany, 2012, 1-6
- [21] D. Kocur, J. Rovnakova, and M. Svecova, "Through wall tracking of moving targets by m-sequence uwb radar," Studies in Computational Intelligence, vol. 243, pp. 349-364, 2009.
- [22] D. Kocur et al., "Short-range UWB radar: Surveillance robot equipment of the future," 2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC), San Diego, CA, 2014, pp. 3767-3772. doi: 10.1109/SMC.2014.6974517
- [23] M. Helbig, M. Kmec, J. Sachs, C. Geyer, I. Hilger, G. Rimkus, "Aspects of antenna array configuration for UWB breast imaging," Antennas and Propagation (EUCAP), 2012 6th European Conference on , vol., no., pp. 1737-1741, 26-30 March 2012
- [24] F. Thiel, O. Kosch, F. Seifert, "Ultra-Wideband Sensors for Improved Magnetic Resonance Imaging, Cardiovascular Monitoring and Tumor Diagnostics," in Sensors 10, pp. 10778-10802, December 2010
- [25] M. Helbig, K. Dahlke, I. Hilger, M. Kmec, J. Sachs: Design and test of an imaging system for UWB breast cancer detection. Frequenz, 66 (2012), 387-394
- [26] J. Sachs, M. Helbig, R. Herrmann, M. Kmec, K. Schilling, E. Zaikov: Remote vital sign detection for rescue, security, and medical care by ultra-wideband pseudo-noise radar. Ad Hoc Networks, ELSEVIER, 2012, http://dx.doi.org/10.1016/j.adhoc.2012.07.002
- [27] J. Sachs, M. Helbig, M. Kmec, R. Herrmann, K. Schilling and P. Rauschenbach, Integrated dielectric spectrometer for wideband and highspeed measurements using pseudo-noise codes, Journal of Physics: Conference Series, Volume 434, conference 1, 2013
- [28] J. Sachs, M. Helbig, and K. Renhak. "Unsichtbares wird sichtbar – Mit Radar den Insekten auf der Spur: Neue Möglichkeiten zum Aufspüren

- von Insektenaktivitäten," presented at the HOBA'08, Duisburg (Germany), 2008.
- [29] J. Zender, J. Sachs, and B. Landsberger, "Non destructive vitality monitoring of pest infestations by low power radio waves in museum exhibition objects.," presented at the IPM 2016, 3rd International Conference on Integrated Pest Management for Cultural Heritage, Paris, France, 2016.
- [30] J. Sachs, S. Ley, T. Just, S. Chamaani, and M. Helbig, "Differential Ultra-Wideband Microwave Imaging: Principle Application Challenges," *Sensors*, vol. 18, 2018.
- [31] V. F. Lvovich, *Impedance Spectroscopy, Applications to Electrochemical and Dielectric Phenomena*, Wiley & Sons, Inc. 2012.
- [32] R. Simons, "Coplanar Waveguide Circuits, Components, and Systems", Wiley, 2001, pp. 15-21.
- [33] E. Berndt, H. Gothe, D. Oesterreich et al., *Marktpotentiale, Entwicklungschancen, gesellschaftliche und ökonomische Effekte der zukünftigen Nutzung von Ambient Assisted Living (AAL)-Technologie*, Fraunhofer IGD, Rostock, Darmstadt, Berlin 2009, 2009.
- [34] H. E. Krüger-Brand, "Ambient Assisted Living - Assistenzsysteme: Hightech für ein besseres Leben im Alter," *Deutsches Ärzteblatt* vol. 105(14): A-729 / B-636 / C-624, 2008.
- [35] J. Sachs, E. Zaikov, D. Kocur, J. Rovňáková, M. Švecová: *Ultra Wideband Radio Application for Localisation of Hidden People and Detection of Unauthorised Objects*. D13 Midterm report on person detection and localisation, Project RADIOTECT, COOP-CT-2006-032744, July 2008.
- [36] S. Venkatesh, C. R. Anderson, N. V. Rivera et al., "Implementation and analysis of respiration-rate estimation using impulse-based UWB," in *Military Communications Conference, 2005. MILCOM 2005. IEEE, 2005*, pp. 3314-3320 Vol. 5.
- [37] S. Gezici, and Z. Sahinoglu, "Theoretical Limits for Estimation of Vital Signal Parameters Using Impulse Radio UWB," in *Communications, 2007. ICC '07. IEEE International Conference on, 2007*, pp. 5751-5756.

Analysis of Electrophysical Processes in High Voltage Insulating Materials

Roman Cimbala

Department of Electrical Power Engineering
Technical University of Košice
Košice, Slovak Republic
roman.cimbala@tuke.sk,

Lukáš Kruželák

Department of Electrical Power Engineering
Technical University of Košice
Košice, Slovak Republic
lukas.kruzepak@tuke.sk

Abstract—V úvode sa publikácia zaoberá degračnými faktormi elektrickej izolácie v elektroenergetike. V ďalšej časti publikácie sa rozoberá impedančná spektroskopcia, konkrétne meranie povrchového odporu na povrchu pevných dielektrík. Jadro publikácie tvorí experiment, ktorý je zameraný na meranie povrchového odporu impregnovaného transformátorového papiera. V tomto experimente boli použité tri vzorky s rôznym transformátorovým olejom, pri použití paralelného a sériového modelu kondenzátora. Záver práce je zameraný na vyhodnotenie nameraných výsledkov.

Keywords—*Impedančná spektroskopcia, povrchový odpor, transformátorový papier, transformátorový olej, paralelný model, povrchová vodivosť.*

Abstract—In the introduction, the publication deals with the degradation factors of electrical insulation in electrical energy. In the next part of the publication, impedance spectroscopy is described, namely the measurement of surface resistance at the surface of solid dielectrics. The core of the publication is an experiment aimed at measuring the surface resistance of impregnated transformer paper. Three samples with different transformer oil were used in this experiment using a parallel and serial model of the capacitor. The conclusion of the thesis is focused on the evaluation of the measured results.

Keywords—*Impedance spectroscopy; surface resistance; transformer paper; transformer oil; parallel model; surface conductivity.*

I. INTRODUCTION

Insulation systems are one of the most important components in electrical equipment. When expanding the electrical industry, it is demanded to develop better insulation systems. The lifetime of the power plant depends strongly on the ability of its insulation system to prevent winding errors. The deterioration of the insulating materials leads to a distortion of its dielectric strength and subsequent failure of the electrical equipment.[1]

Many external influences could affect the life of the insulation systems. These external influences may include chemical contamination of the insulating surface, weakening and destruction of the molecular structure, or physical damage caused by improper use such as over-temperature operation or

excessive vibration. Transient voltage inside the coils, such as overvoltage caused by powering the frequency converter, may also gradually weaken electrical insulation and lead to premature failure. The satisfactory lifetime of electrical power plants typically ranges from 20 to 40 years. Therefore, it is very important to be able to determine the life of the insulation system as well as to know the causes and methods that help to prevent rapid degradation that can lead to a decrease in life. Therefore, it is important to focus on methods that will help us determine the life of the insulation system as a function of specific degradation factors, including thermal degradation.[1]

Trends in the production of electrical equipment, its development, and the use of such equipment in a wide variety of conditions, place increasingly high demands on the material used. Electrical devices as a whole can also be understood in terms of their functional parts. These are mainly mechanical, electrical, magnetic and dielectric systems. Insulators are substances primarily used due to their electro-insulating properties to separate two sites of varying potential. Dielectrics are substances of the same nature as insulators (also not conducting electrical current), but are used as substances capable of accumulating electric charge after an electric field is attached. From a safety and reliability point of view, they are just insulating materials that influence the stability of their properties and, above all, lifetime, what we require from the electrical equipment. Therefore, it is necessary to know how long the materials used will be able to fulfill the functional characteristics necessary for the safe and trouble-free operation of the equipment. It is therefore necessary to examine the course of degradation of insulating materials. For aging of the dielectric material, stress is used using heat cycles, alternating electric fields, humidity, mechanical stress, and more.

At the present time, a combination of two or more factors is increasingly used, the better the accelerated operating conditions. At different intervals, the degradation process stops and the dielectric properties are measured on the material. For testing the basic dielectric properties of the investigated materials, a number of test methods are used.[2]

Since the interface between two different dielectrics is the most critical area of electrical isolation systems, it is appropriate to monitor changes in the surface of these

dielectrics. At the interface of the two dielectrics, the relative permittivity of one material to the permittivity of the second material changes, which causes a step change in the distribution of the electric field intensity. Such changes result in different electrophysical processes on the surface of solid insulation and electrical stress. These processes over time lead to structural changes, especially on the surface of solid dielectrics. When combining a solid and liquid dielectric or a solid and gaseous dielectric, the liquid or gaseous component of the electro insulating system is circulating in these systems. This circulation mitigates degradation effects in gaseous and liquid dielectrics. However, for solid dielectrics, these changes are irreversible and it is therefore necessary to monitor these structural changes, especially at the interface of two dielectrics.[2]

II. DEGRADATION FACTORS AFFECTING THE AGING OF THE INSULATION SYSTEM

Aging, which is defined by the increasing deterioration of dielectric materials, permanently exacerbates their purposeful properties by physical and chemical changes over time. This phenomenon occurs through the influences and conditions the dielectric is exposed to. Aging, however, is more pronounced in organic matter. Inorganic substances do not appear to be exceptions. The lifetime of the insulation system depends largely on the properties of the dielectric materials. This is closely related to aging. The lifetime of the insulation system and the associated lifespan of the electrical equipment is the time when the system or device is capable of performing trouble-free operation. So the activity for which it was produced and used. Upon expiration of this lifetime, the material ages to such an extent that it is unable to continue to perform the required functions. By aging, conditional changes in the properties of the insulators are divided into changes that are reversible and irreversible. Reversible, that is, temporary changes will resolve as soon as they cease to exert the external influences that triggered the change. The material then acquires the original properties over time. Returns are physical in nature. Irreversible (permanent) changes are the result of complicated chemical and physical events. Changes are of a structural nature and the properties of the materials are getting worse. Changes may not necessarily occur in the whole material, but may be of superficial nature only. Then we talk about material corrosion. The factors that cause the transformation of dielectric and insulating materials are several, but usually they act several simultaneously.[3]

Factors causing dielectric degradation:

- temperature,
- air oxygen,
- mechanical stress,
- electric field,
- climate impacts,
- chemical effects,
- ultraviolet radiation, etc.

Thermal aging of organic insulators is the most common case of aging. Other factors only contribute to destruction caused by thermal stress. For insulators used in high voltage technology, the effect of the electric field is also applied. Irreversible changes that occur during thermal aging are due to a series of chemical reactions (oxidation, polymerization and polycondensation, depolymerization and decomposition of some material components). These processes occur at all temperatures, with these temperatures being accelerated. However, for the rate of aging, the quantity of thermal energy supplied is not decisive, but the temperature level.[4]

Effect of heat stress on aging of electrical insulation

One of the first attempts to numerically express the effects of thermal aging and its algebraic expression of aging versus time, Montsinger performed. He studied the lifetime of t_T paper insulation of conductors in oil transformers. It measured the loss of mechanical strength of the paper depending on the constant temperature. Based on its results, it then determined the equation (1). [4]

$$t_T = t_{T0} \cdot \exp[-M \cdot \vartheta_T] \quad (1)$$

Where t_T is the lifetime of the insulation,

$M[t]$ and t_{T0} are the material constants determined experimentally (t_{T0} is the service life t_T at temperature $\vartheta = 0$ °C)

ϑ_T [°C] is the constant temperature of aging.[5]

Montsinger experimentally found that the lifetime of t_T insulation dropped by half by increasing the temperature by $\Delta\vartheta = 8$ °C and vice versa, when the temperature dropped by $\Delta\vartheta = 8$ °C, lifetime was extended to 2 t_T . This rule is referred to as the Montsinger Rule of Eight Degrees. [5]

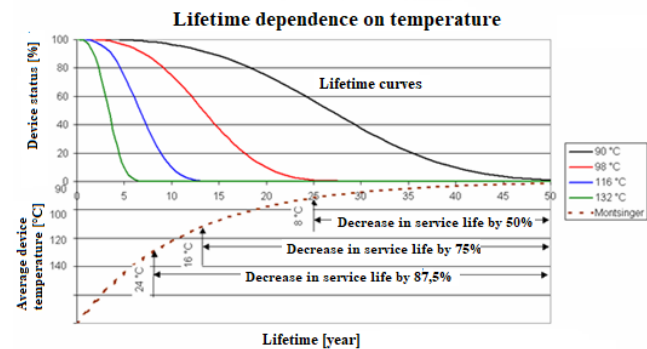


Fig. 1. Machine life at different temperatures.[5]

In Figure 1 we can observe changes in the life curve at 90 °C, which has an effect on electrical insulation. The life of insulation is fifty years. When the temperature increases to 98 °C, an increase of 8 °C, the service life is reduced to half. If the device has a temperature of 132 °C, its lifetime is only a tenth of its lifetime.

However, the Montsinger rule of eight degrees does not apply generally. Applies only to paper insulation in oil and for a narrow range of temperatures. A more detailed description of the thermal aging of the insulators in terms of the chemical

process is important for a better idea of the theory of aging. The term (1) is not supported by a theoretical analysis, but when organic matter is degraded by aging, it is a set of chemical processes. These reactions must be governed by a certain theoretical process, which is also subject to all other chemical processes.[5]

III. INVESTIGATION OF DIELECTRIC LOSSES

In the structure of each insulator, after the insertion into the external electric field, electrical energy is converted to thermal energy. Due to the transformation of this energy, the insulation is heated, which is undesirable for the electro-insulating systems and it is necessary to bring the heat to the surroundings. If this heat is not supplied, it would increase the loss and hence increase the temperature of the insulator, which would lead to its overheating and could lead to its destruction. This phenomenon is called dielectric loss and contains several factors that could be divided into three main groups:

- conductive losses,
- polarization losses,
- ionization losses.[6]

The cause of conductive losses is the movement of free and bound electric charge carriers, which results in a conductive current that passes not only through the dielectric itself but also over its surface.

Polarization losses mainly include relaxation and migration polarizations. As a result of the polarization phenomena, the delay of the charged electric charge carriers is a change in the external electric field, due to the efforts of this field to overcome and to direct the chaotic motion of the particles. Migration polarizations have the effect of creating a spatial charge due to the layering or the presence of impurities or possible non-homogeneity in the structure of the material. The energy losses themselves are due to the movement of the spatial charge. Information on the total polarization contribution to overall dielectric losses can be obtained from the polarization vector's dependence on the electric field strengths when the area bounded by the $P = f(E)$ curve is proportional to the size of the energy lost. In the case of elastic polarization, the dependence is linear and the loss does not arise if the material undergoes relaxation polarization processes. It is an ellipse-shaped dependence, in the case of ferroelectric substances it is the shape of a hysteresis loop.[6]

Ionizing losses are particularly evident in solid and liquid materials with a certain amount of gas in their volume. This gas can occur in lumens or bubbles where the electric field causes partial discharges, accompanied by the conversion of electrical energy to heat.

Dielectric losses occur both in single and alternating voltages. However, losses in the alternating electric field are much higher than the losses in a one-way electric field. While DC voltages are proportional to the size of the conductive current and the dielectric insulation resistance, in the case of AC voltage, in addition to conductive losses, polarization and ionization losses occur.[7]

A. Impedance spectroscopy

By means of an external electromagnetic field on the dielectric, the polarization is triggered, allowing current and voltage changes to be observed. Impedance Spectroscopy (IS) is used to record the responses caused by the electromagnetic field on the material, and on the basis of these changes determine the relationship between the composition of the material and the responses. It is important to observe the parameters that change in degradation and to determine the future degradation process with the mathematical-physical model.[7], [8]

The electrodes between the electrodes and the examining material of the electrical values may be carried out by two electrodes of the same shape with the same material and may be of a different format, such as a cylinder, prism, hemisphere or Rogowski electrode. The electrodes are supplied with pulses in the form of current or voltage and are compared to their changes. The properties of the measurement principle have not changed since time. It is one of the methods for indicating the properties, their relationships and the individual properties affecting the system, such as temperature, pressure and the voltage and current used and others.[8]

B. Impedance spectroscopy in the frequency domain

For monochromatic signals of one frequency, the current flows:

$$i(t) = I_m * \sin(\omega t + 0) \quad (2)$$

From this equation, there is no phase difference between voltage and current. The phase difference is 0 at a pure resistance load. Dependencies from time to time are expressed from system properties and periodic stresses are very complex. Therefore, differential equations are used in their handling. Capacity and induction response is expressed:

$$i(t) = [dv(t)/dt] * C \quad (3)$$

$$v(t) = [di(t)/dt] * L \quad (4)$$

To solve this system, Fourier transforms are used and the formulas are transformed into the form of:

where the imaginary unit $j = \sqrt{-1}$. Using Ohm's law, it simply expresses the relationship in the frequency domain between voltage and current. For current:

$$I(j\omega) = V(j\omega)/Z(j\omega) \quad (5)$$

For capacitance and complex quantity is given $Z(j\omega) = 1/j\omega C$ and for induction $Z(j\omega) = j\omega L$. The impedance function is based on the definition of a complex variable. The impedance of the electrical circuit is given by its value at a given frequency. A complex variable is referred to as $Z(\omega)$. The complex impedance can be expressed as the sum of the real and the imaginary component. Depending on

This work was supported by Ministry of Education Agency for structural funds of EU in frame of projects No. 26220120055 and 26220220182, VEGA 1/0340/18 and 2/0141/16 and APVV-15-0438

the vector, it appears in a plane with either rectangular or polar coordinates.[9]

$$\operatorname{Re}(Z) = Z' = |Z| \cdot \cos(\theta) \quad (6)$$

$$\operatorname{Im}(Z) = Z'' = |Z| \cdot \sin(\theta) \quad (7)$$

C. Benefits and limits impedance spectroscopy

Impedance spectroscopy IS is increasingly popular in material research. This measurement is simple and can be automated. This method can predict a change in the performance of chemical sensors and fuel cells. It is used as an experienced observation of the quality of the procedures and to describe the basic electrochemical and electrical processes. Using CNLS, it is possible to analyze the experimental data obtained by the given system and to predict the theoretical impedance $Z_t(\omega)$. Using a mathematical model, the parameters can be estimated and compared to randomly obtained data $Z_e(\omega)$. The analysis of the charge transfer processes is attempted on a physical model, made up of ideal resistors and capacitors, and corresponds appropriately to the observed responses.[9]

An unexpected problem with analyzes based on the same circuit is that the ordinary part of the fault-free circuit forms the properties of a concentrated constant. Most of the particles examined in the system space are independently decomposed and their microscopic properties can be independently delineated. Because of these properties, the ideal circuitry is not sufficient for describing the electrical response of the system. $Z_e(\omega)$ can not be solved by successive steps due to the impedance of the same system, with the final number of discrete elements. It has been found that the application of scattered non-frequency dependent elements in the same circuit improves the successive steps of the monitored impedance values for a system with different properties. [9], [10]

D. Surface resistivity

Surface resistivity refers to the resistance that occurs at the lead current along the surface of the insulating material. It can also be defined as the electrical resistance that exists between two parallel electrodes that touch the surface. The electrodes must be separated by a distance equal to the length of the contacts of said electrodes. The four ends of the electrodes form a square, so the resistance is expressed in ohms and sometimes in ohms per square meter. Surface resistivity is calculated as the fraction of the potential gradient with units of V/m and the current per unit length of electrodes, A/m. This is summed as the ratio of the DC voltage drop per unit length of the electrode to the current per unit of width. Surface resistance determines the conduction of any given material. The higher the surface resistivity, the lower the conductivity of the material, as it will have a low leakage current.[10]

The terms surface resistance and surface resistance can sometimes be confusing. Surface resistance, R_s is defined as the ratio of the direct current U to the current, I_s passing between two electrodes of a specified configuration that are in contact with the same side of the tested material.[10]

$$R_s = \frac{U}{I_s} \quad (8)$$

IV. EXAMINING THE SURFACE RESISTIVITY ON THE SURFACE OF THE IMPREGNATED TRANSFORMER PAPER

Three samples of impregnated transformer paper were prepared for experimental measurements. Each sample consisted of 5 pieces and 0.1 mm thick paper with a diameter of 94 mm. The paper weight was 35.46 g / m², 3 different transformer oils were used to impregnate the samples. The IT 100 transformer oil was used on the first sample, the second oil was MOGUL TRAF0 CZ-A and the last oil was SHELL DIALA S4 ZX-1, which the manufacturer claims to have excellent dielectric properties and chemical stability.

Prior to the measurement, the transformer oil samples were dried at 90 °C and transformer paper at 70 °C, drying for 24 hours. All samples were subjected to accelerated thermal degradation. The paper samples were placed in glass vials, in which a piece of copper was also inserted. In this experiment, changes in the loss factor on the surface of the transformer paper were investigated. In order to ensure equal volume representation of transformer oil in the samples between measurements, each sample was weighed at the exact digital weight before measurement (Figure 7a). Samples were placed in Petri dishes and concentric circular electrodes with radius $R_1 = 24.5$ mm and $R_2 = 25.5$ mm were used for measurement (Figure 7b). Before each measurement, bubble-free samples (Figure 7c) were placed between the transformer paper to prevent the influence of these air bubbles on the measurement. The Megger IDAX 300 instrument (Figure 7d) was used on the measurement itself, with a frequency range of 0.1 mHz to 10 kHz. The measurement voltage was 10 V, the measurements were made at room temperature (20 °C), air humidity was from 45 to 50%. The resulting values were graphically processed and evaluated.




Fig. 2. Use devices for experimental measurements, a) digital scale, b) concentric circular electrodes, c) vacuum chamber, d) Megger IDAX 300 instrument.

Processing and evaluation of results with oil-impregnated paper

An experimental parameter in this experiment was the measurement of surface resistance of impregnated transformer paper. A parallel and serial capacitor model was used to

determine the difference of the measured values for both connections. Surface resistance values for parallel wiring in the frequency band 0.1 mHz to 1 Hz, during the aging time of 0 h, 200 h and 450 h, were randomly observed for waveforms having a slightly decreasing character. This distribution is likely due to the presence of moisture in the sample. Due to aging, surface resistance should be reduced with increasing thermal degradation time. However, the presence of moisture caused that in this area the surface resistance value during the accelerated aging time was 450 hours over the course of the surface resistivity during the aging time of 200 hours, indicating desiccation of the sample during thermal degradation. Surface resistances at thermal degradation of 700h, 1000h and 1300h already correspond to the assumption that with increasing thermal degradation time, the surface resistance decreases in parallel. In the frequency range 1 Hz to 500 Hz up to 450 hours of aging, a sharp drop in surface resistance is observed with an increasing frequency in parallel connection, this is due to the already mentioned presence of moisture. By using a parallel capacitor model the frequency response decreases the reactance of the parallel capacitor, causing the current flowing through the capacitor to rise. The presence of moisture has helped to increase surface conductivity and reduce surface resistance. Surface resistance values, which accelerated aging time exceeded 450 hours, have a parabolic decreasing character, these changes in surface resistance before accelerated aging of 450 hours and are due to drying time after this time.

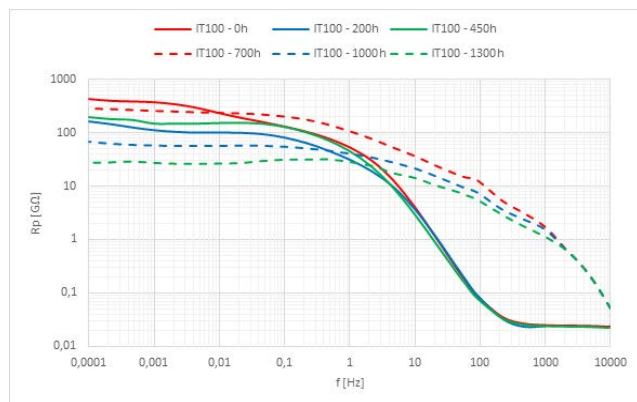


Fig. 3. Frequency dependence of surface resistance, paper sample impregnated with IT 100 oil, parallel model, Megger IDAX 300.




Fig. 4. Frequency dependence of surface resistance, paper sample impregnated with IT 100 oil, serial model, Megger IDAX 300.

By analyzing the surface resistivity during serial capacitor coupling, acceleration aging is observed for 450 hours, in the frequency range 10 Hz to 10 kHz, the surface resistivity slows down and the subsequent sharp drop. If the aging time of 450 hours is exceeded, this anomaly has not occurred. The surface resistivity process using a serial model is a decreasing curve in the frequency range of 0.01 Hz to 10 kHz. At lower frequencies (0.1 mHz to 0.01 Hz), the surface resistivity is almost straight lines, with decreasing surface resistivity depending on the accelerated aging time.

By comparing the surface resistance between the individual samples it was found that the most significant differences in measured values in accelerated degradation had a sample impregnated with IT 100 oil.




Fig. 5. Frequency dependence of surface resistance, paper sample impregnated with Mogul oil, parallel model, Megger IDAX 300.




Fig. 6. Frequency dependence of surface resistance, paper sample impregnated with IT 100 oil, serial model, Megger IDAX 300.

These differences are most visible in the frequency range of 0.1 mHz to 10 Hz using a parallel measurement model. In this frequency band, it has been shown to degrade oil, indicating a much lower chemical stability of the IT 100 oil relative to the Mogul and Diala Z4 oils. When increasing the frequency (10 Hz to 10 kHz), more degradation of the solid part (transformer paper) of the sample being examined appears. In the sample of IT 100 impregnated transformer paper, more pronounced deviations of the surface resistivity curves at frequencies above 10 Hz were observed compared to the samples impregnated with Mogul and Diala Z4 oil. These changes indicate that IT 100 impregnated paper is subject to degradation, with accelerated aging much faster than Mogul and Diala Z4 oils. Another reason for the deterioration of the results in the IT 100 impregnated sample was the presence of a piece of copper wire which was embedded in oil to accelerate thermal degradation. This copper piece worked with this degradation as a catalyst even though the copper was located in all oil samples, although it had the greatest impact on the IT 100 oil mentioned above. The most stable values for accelerated degradation had a sample impregnated with Diala Z4 oil. When comparing the measurement models used, the most significant changes are made using a parallel capacitor model. Therefore, it is preferable to use this model to detect changes in surface resistance.




Fig. 7. Frequency dependence of surface resistance, paper sample impregnated with Diala oil, parallel model, Megger IDAX 300.




Fig. 8. Frequency dependence of surface resistance, paper sample impregnated with Diala oil, serial model, Megger IDAX 300.

V. CONCLUSION

When looking at the frequency resistance of the surface resistance, decreasing surface resistance curves are observed with increasing frequency. By analyzing the graphical dependence of the surface resistance, the rate of surface resistivity at parallel connection in the frequency band from 1 Hz to 10 kHz is observed, and the subsequent decrease is due to the polarization of the oil paper insulation system. This increase in this frequency band is observed at accelerated thermal degradation times of 0 hours, 200 hours and 450 hours. At a time of degradation of 700 hours, 1000 hours and 1300 hours, this polarization graph does not occur. These changes have occurred by thermal degradation. Due to temperature, the surface structure of the transformer paper is likely to change and these changes could also be due to the presence of moisture contained in the transformation oil. After more than 450 hours of thermal degradation, moisture contained in paper and oil has evaporated and could cause different curves in the frequency range from 1 Hz to 10 kHz. This anomaly was observed in all three samples.

It can be concluded that changes in surface resistance in the frequency band from 0.1 mHz to 1 Hz due to accelerated aging are due to changes in the parameters of the liquid dielectric (transformer oil). At higher frequencies of 1 Hz to 10 kHz, changes in the solid component of the electro insulating system (transformer paper) were detected. Changes in the polarization process that occurred when the aging time of 450 hours in the solid dielectric was exceeded would be suitably examined with a larger frequency range measuring instrument.

REFERENCES

- [1] M. G. Minnick, "Accelerated thermal aging of polyester film: mechanisms affecting thermal endurance," Proceedings: Electrical Insulation Conference and Electrical Manufacturing and Coil Winding Conference (Cat. No.99CH37035), Cincinnati, OH, USA, 1999, pp. 337-342.
- [2] G. F. Lipsey and P. W. Juneau, "Factors Affecting the Aging Characteristics of Various Wire Coating Materials in Transformer Oil," in Transactions of the American Institute of Electrical Engineers. Part III: Power Apparatus and Systems, vol. 79, no. 3, pp. 73-77, April 1960.

- [3] S. J. Williamson, R. Wrobel, J. D. Booker, J. Yon and P. H. Mellor, "Effects of insulation ageing on the conductive heat transfer from the winding body into machine periphery/stator core pack," 8th IET International Conference on Power Electronics, Machines and Drives (PEMD 2016), Glasgow, 2016, pp. 1-6.
- [4] Y. Zhou, M. Huang, W. Chen, L. Lu, F. Jin and J. Huang, "Space charge behavior evolution with thermal aging of oil-paper insulation," in IEEE Transactions on Dielectrics and Electrical Insulation, vol. 22, no. 3, pp. 1381-1388, June 2015.
- [5] V. Wasserberg, H. Borsi and E. Gockenbach, "A novel system for the prolongation of the lifetime of power transformers by reduced oxidation and aging," Conference Record of the 2004 IEEE International Symposium on Electrical Insulation, Indianapolis, IN, USA, 2004, pp. 233-236.
- [6] S. M. M. Islam, M. A. R. Reza and M. A. Kiber, "A study of phantoms of multi-frequency Electrical Impedance Spectroscopy(EIS) system for early detection of breast cancer," 2013 International Conference on Informatics, Electronics and Vision (ICIEV), Dhaka, 2013, pp. 1-6.
- [7] S. Wang, T. Chen, K. Chen and C. Wei, "Design of divider circuit for electrochemical impedance spectroscopy measurement system," 2018 International Symposium on VLSI Design, Automation and Test (VLSI-DAT), Hsinchu, 2018, pp. 1-4.
- [8] C. Yang, D. Rairigh and A. Mason, "Fully Integrated Impedance Spectroscopy Systems for Biochemical Sensor Array," 2007 IEEE Biomedical Circuits and Systems Conference, Montreal, Que., 2007, pp. 21-24.
- [9] T. Chen, C. Wei and B. Liu, "Comparative frequency response analysis system for electrochemical impedance spectroscopy measurements," 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Orlando, FL, 2016, pp. 1910-1913.
- [10] J. Zbojovský, L. Kruželák and M. Pavlík, "Impedance Spectroscopy of Liquid Insulating Materials," 2018 International IEEE Conference and Workshop in Obuda on Electrical and Power Engineering (CANDO-EPE), Budapest, 2018, pp. 000249-000254.

Návrh a experimentálne vyhodnotenie vlastností difúzneho bloku pre obrazové šifrovacie algoritmy

Jakub Oravec

Katedra elektroniky a multi-
mediálnych telekomunikácií
FEI, Technická univerzita v Košiciach
Košice, Slovenská republika
jakub.oravec@tuke.sk

Ján Turán

Katedra elektroniky a multi-
mediálnych telekomunikácií
FEI, Technická univerzita v Košiciach
Košice, Slovenská republika
jan.turan@tuke.sk

Ľuboš Ovseník

Katedra elektroniky a multi-
mediálnych telekomunikácií
FEI, Technická univerzita v Košiciach
Košice, Slovenská republika
lubos.ovsenik@tuke.sk

Abstract—This contribution deals with solution of a diffusion block used in image encryption algorithms. After the introduction of the first generalized techniques for analysis of the image encryption algorithms, the level of pixel intensity diffusion is being more and more important. This paper presents two solutions of the diffusion block which were created during the doctoral study. After brief evaluation of their properties, the second solution which seems to be more universal is analyzed more thoroughly. The paper also contains calculated values of commonly used measures of pixel intensity diffusion level with some blocks of the chosen solution left out and the comparison of acquired values with those obtained by other image encryption algorithms.

Key words—diffusion block, diffusion levels, chaining, image encryption, Mojette transform

Abstract—Tento príspevok sa zaoberá riešením otázky difúzneho bloku v obrazových šifrovacích algoritmoch. Po uvedení prvých všeobecných techník analýzy takýchto algoritmov je dosiahnutá miera difúzie intenzít obrazových prvkov stále dôležitejšia. V článku sú uvedené dve riešenia difúzneho bloku, ktoré vznikli počas doktorandského štúdia. Po stručnom vyhodnotení ich vlastností je ďalej analyzované druhé riešenie, ktoré sa z hľadiska možných aplikácií javí ako univerzálnejšie. Príspevok taktiež obsahuje vypočítané hodnoty bežne používaných metrick úrovné difúzie intenzít obrazových prvkov pri vynechaní niektorých blokov zvoleného riešenia a porovnanie získaných hodnôt s hodnotami, ktoré dosiahli iné obrazové šifrovacie algoritmy.

KLúčové slová—difúzny blok, miery difúzie, Mojette transformácia, obrazové šifrovanie, reťazenie

I. ÚVOD

Prvé obrazové šifrovacie algoritmy boli popísané koncom deväťdesiatych rokov minulého storočia. Ku takýmto algoritmom patrí napr. technika navrhnutá J. Fridrichom v roku 1998 [1]. Myšlienka Fridrichovho algoritmu spočívala v preusporiadaní obrazových prvkov (*op*) zvoleného otvoreného obrazu a realizácii reťazenia ich intenzít. Tieto dve operácie je možné označiť aj ako konfúziu a difúziu intenzít *op*. Termíny konfúzia a difúzia zaviedol už v roku 1949 C. Shannon [2], ktorý taktiež popísal aj ich význam.

Pri konfúzii *op* dochádza k ich preusporiadaniam, čím sa potlačí vysoká miera korelácie susedných *op*. Difúzia *op* naopak závislosti medzi intenzitami *op* zavádza, avšak takým spôsobom, aby sa všetky tieto intenzity navzájom ovplyvňovali. Pri vhodne navrhnutom difúznom bloku v obrazových

šifrovacích algoritmoch by aj minimálna zmena intenzity jedného *op* mala spôsobiť totálne odlišný zašifrovaný obraz.

Miera difúzie obrazových šifrovacích algoritmov začala byť bližšie skúmaná od roku 2004. Ku prvým príspevkom, ktoré sa tejto problematike venovali patria články G. Chena a kol. [3] a Y. Maa a kol. [4]. Rastúci počet navrhnutých obrazových šifrovacích algoritmov spôsobil aj vytvorenie techník analýzy takýchto algoritmov. Ku prvým z týchto algoritmov patrí prístup K. Wanga a kol. z roku 2005 [5], ktorý poukázal na nevhodnú implementáciu chaotického zobrazenia v algoritme [3]. Zatiaľ čo uvedená technika slúži len na odhalenie vlastností jedného obrazového šifrovacieho algoritmu, neskôr boli navrhnuté aj prístupy, ktoré je možné využiť na analýzu vlastností obrazových šifrovacích algoritmov vo všeobecnosti.

Ku najvýznamnejším metódam analýzy obrazových šifrovacích algoritmov patrí prístup E. Solaka a kol. z roku 2010 [6]. Aj keď útok zverejnený v uvedenom príspevku bol zameraný hlavne na prelomenie Fridrichovho šifrovacieho algoritmu [1], plynú z neho všeobecné závery a je možné aplikovať ho na viacero obrazových šifrovacích algoritmov, ktoré pri šifrovaní nekombinujú otvorený obraz s pseudo-náhodnou postupnosťou (PNP). Solak a kol. v závere ich príspevku uvádzajú aj niekoľko možností potlačenia ich útoku. Preskúmanie niektorých z týchto možností bolo vykonané počas doktorandského štúdia. Útok prezentovaný v príspevku Solaka a kol. [6] (ďalej už len Solakov útok) bol v roku 2017 optimalizovaný E. Xieom a kol. [7].

Zvyšná časť tohto príspevku je členená nasledovne: kapitola II predstavuje transformáciu, ktorá sa používa v jednom z navrhnutých riešení difúzných blokov. Okrem toho táto kapitola opisuje dve metriky používané na vyhodnotenie vlastností difúzných blokov obrazových šifrovacích algoritmov. Kapitola III sa venuje stručnému popisu navrhnutých riešení. Podrobnejší opis jednotlivých krokov zvoleného difúzneho bloku nie je možné uviesť kvôli obmedzenému rozsahu tohto príspevku, je ho však možné nájsť v [8]. Kapitola IV obsahuje získané experimentálne výsledky a k nim patriace komentáre a porovnanie výsledkov získaných pre celý obrazový šifrovací algoritmus s hodnotami podobných algoritmov. Kapitola V sumarizuje vlastnosti navrhnutého riešenia difúzneho bloku.

II. POUŽITÉ TECHNIKY

A. Mojette transformácia

Mojette transformáciu (MoT) uviedli v roku 1995 J.-P. Guédon, D. Barba a N. Burger [9]. MoT slúži na reprezentáciu obrazov v odtieňoch sivej prostredníctvom tzv. binov. Biny MoT sú počítané ako súčty intenzít *op* pozdĺž myslenných priamok prechádzajúcich cez obraz (1):


$$bin(b, p, q) = \sum_{k=1}^w \sum_{l=1}^h Im(l, k) \cdot \delta(b + kq - pl), \quad (1)$$

kde $bin(b, p, q)$ je hodnota binu s parametrami (p, q) a poradovým číslom b ; $k = 1, 2, \dots, w$ je súradnica stĺpcov obrazu Im , w je jeho šírka; $l = 1, 2, \dots, h$ je súradnica riadkov obrazu Im , h je jeho výška a $\delta(x)$ je Kroneckerova delta funkcia, kde $\delta(x) = 1$ pre $x = 0$, inak $\delta(x) = 0$. Použitie Kroneckerovej delta funkcie a parametrického vyjadrenia priamky zaručuje, že sčítat' sa budú len intenzity tých *op*, ktorých stredom prechádza myslenná priamka.

Parametre binov (p, q) sa volia na základe dvoch pravidiel:

- jednotlivé hodnoty p_i a q_i sú nesúdeliteľné, teda ich najväčší spoločný deliteľ je rovný 1,
- všetky hodnoty q_i sú kladné, teda výsledné projekčné uhly $\theta_i = \arctan(q_i/p_i)$ sú z intervalu $\langle 0^\circ; 180^\circ \rangle$.

Poradové čísla binov b sa volia tak, aby bola intenzita *op* so súradnicami $[0, 0]$ použitá pri výpočte binu s poradovým číslom $b = 0$. Príklad poradových čísel binov pre dve rôzne projekcie v obraze s rozlíšením 4×3 *op* ukazuje Obr. 1.



Obr. 1. Príklad poradových čísel b binov MoT

B. Metriky na vyhodnotenie vlastností difúzných blokov

Na vyhodnotenie vlastností difúzných blokov obrazových šifrovacích algoritmov z hľadiska ich odolnosti voči diferenčným útokom sa používa nasledujúci postup:

- 1) Zo zvoleného otvoreného obrazu P_1 sa vytvorí totožná kópia, ktorá sa nazve ako P_2 .
- 2) V obraze P_2 sa náhodne zvolia súradnice jednej intenzity *op*, ktorá sa zmení o jednu intenzitnú úroveň (buď sa inkrementuje, alebo dekrementuje).

3) Dvojica otvorených obrazov P_1 a P_2 sa zašifruje rovnakým šifrovacím algoritmom s použitím rovnakého kľúča a ďalších parametrov.

4) Zo získanej dvojice zašifrovaných obrazov E_1 a E_2 sa určia hodnoty metrick odolnosti voči diferenčným útokom. Pre jednotlivé farebné zložky zašifrovaných obrazov E_1 a E_2 sa počítajú hodnoty metrick *NPCR* (angl. Number of Pixel Change Rate) a *UACI* (angl. Unified Average Changing Intensity) podľa (2), resp. (3).

$$NPCR = \frac{100}{h \cdot w} \sum_{l=1}^h \sum_{k=1}^w Diff_{mat}(l, k) [\%], \quad (2)$$

kde h je výška obrazov E_1 a E_2 , w je ich šírka, l a k sú súradnice riadkov a stĺpcov a $Diff_{mat}$ je rozdielový obraz, $Diff_{mat}(l, k) = 1$ ak $E_1(l, k) \neq E_2(l, k)$, inak $Diff_{mat}(l, k) = 0$.

$$UACI = \frac{100}{h \cdot w} \sum_{l=1}^h \sum_{k=1}^w \frac{|E_1(l, k) - E_2(l, k)|}{2^L - 1} [\%], \quad (3)$$

kde L je farebná hĺbka každej farebnej zložky obrazov E_1 a E_2 .

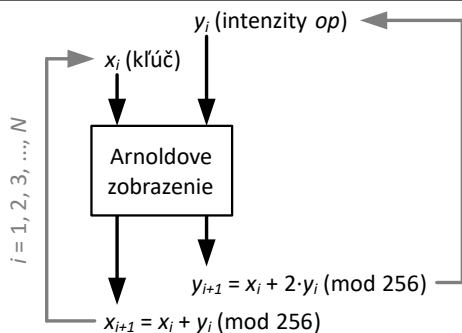
Vlastnosti metrick *NPCR* a *UACI* boli ďalej skúmané Y. Wuom a kol. v roku 2011 [10]. Hlavný prínos práce týchto autorov spočíva v určení tzv. *očakávaných hodnôt* (angl. expected values) metrick *NPCR* a *UACI*. Splnenie, resp. prekročenie očakávaných hodnôt zaručuje určitú mieru odolnosti voči diferenčným útokom. Táto miera závisí od použitej úrovně významnosti α (angl. significance level). Vo všeobecnosti platí, že pre úroveň významnosti α je miera odolnosti voči diferenčnému útokom $100 \cdot (1 - \alpha) \%$, teda pre $\alpha = 0,001$ je táto miera rovná $99,9 \%$. Wu a kol. takisto publikovali vypočítané očakávané hodnoty *NPCR* a *UACI* pre určité rozlíšenia obrazov.

III. NAVRHNUTÉ RIEŠENIA

Počas doktorandského štúdia bolo navrhnutých viacero riešení difúzneho bloku pre obrazové šifrovacie algoritmy. Medzi významnejšie riešenia patrí blok difúzie v asymetrickom šifrovacom algoritme, publikovaný v článku [11] a kombinácia dvoch blokov difúzie v algoritme [8]. Tieto riešenia budú pre účely tohto príspevku v ďalšom texte označované ako *Riešenie 1*, resp. *Riešenie 2*.

A. *Riešenie 1*

Toto riešenie využíva Arnoldovo zobrazenie (AZ) [12], ktoré patrí ku dvojrozmerným chaotickým zobrazeniam bez parametrov. AZ v každej iterácii zobrazuje body s dvojicami súradníc x_i a y_i do bodov so súradnicami x_{i+1} a y_{i+1} . *Riešenie 1* požíva bajty kľúča ako súradnice x_i a intenzity *op* obrazu ako súradnice y_i . Výsledné súradnice x_{i+1} , resp. y_{i+1} sa potom použijú ako bajty rozšíreného kľúča, resp. intenzity *op* zašifrovaného obrazu. Toto riešenie, ako aj rovnice AZ ilustruje Obr. 2.



Obr. 2. Súradnice pri AZ použitom v Riešení 1

Nevýhodou Riešenia 1 je skutočnosť, že šifrovanie každého *op* otvoreného obrazu vyžaduje jeden bajt kľúča. Kvôli tomu sa postupne rozširuje kľúč bajtami, ktoré závisia od intenzít *op* otvoreného obrazu. Pri dešifrovaní je však nutné získať hodnoty posledných bajtov rozšíreného kľúča, ktoré sú odlišné od kľúča použitého pri šifrovaní. Preto použitie difúzneho bloku s Riešením 1 vedie ku vytvoreniu *asymetrických* obrazových šifrovacích algoritmov. Pri niektorých aplikáciách môže byť táto vlastnosť vnímaná ako nevýhoda [11].

B. Riešenie 2

Kroky tohto riešenia boli navrhované tak, aby obrazové šifrovacie algoritmy, ktoré používajú toto riešenie boli symetrické. Tieto kroky sa dajú rozdeliť do dvoch blokov:

- 1) Blok "jednoduchého" reťazenia intenzít *op*.
- 2) Blok reťazenia intenzít *op* podľa intenzít *op* otvoreného, resp. zašifrovaného obrazu.

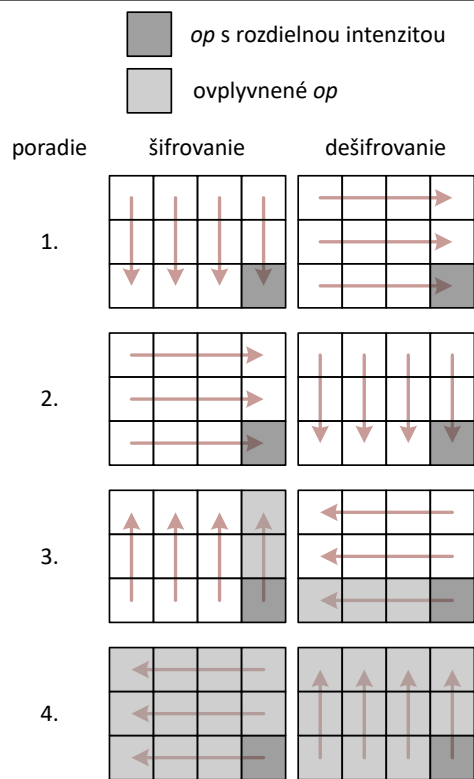
Pri šifrovaní sa tieto bloky použijú v uvedenom poradí, pri dešifrovaní je ich poradie opačné.

1) Blok "jednoduchého" reťazenia intenzít op

V tomto bloku dochádza ku vytvoreniu závislostí medzi intenzitami jednotlivých *op*. Reťazený obraz sa načíta celkovo v štyroch smeroch po vektoroch, ktoré obsahujú intenzity riadkov, resp. stĺpcov *op*. Každý načítaný vektor sa následne skombinuje s dvoma susednými vektormi. Táto kombinácia slúži na vytvorenie závislostí pri šifrovaní a zároveň aj pri dešifrovaní obrazu. Ak by kombinácia každého načítaného vektora používala iba jeden vektor, závislosti medzi intenzitami *op* by sa šírili iba pri jednej operácii (iba pri šifrovaní alebo dešifrovaní).

Pri kombinácii aktuálne načítaného vektora s dvoma vektormi sa používajú dve operácie. Vektor, ktorý nasleduje v smere načítania sa skombinuje s aktuálne načítaným vektorom prostredníctvom operácie XOR (angl. eXclusive OR) a vektor, ktorý bol načítaný pred aktuálne načítaným vektorom sa s ním skombinuje pomocou súčtu v aritmetike modulo 256. Smery načítania vektorov pri šifrovaní a dešifrovaní, ich poradie a najhoršie prípady šírenia difúzie intenzít *op* (vytvárania ich závislostí) ukazujú Obr. 3.

Ak je potrebné použiť vektor, ktorého súradnice sú mimo množiny súradníc obrazu, použijú sa korešpondujúce vektory



Obr. 3. Smery načítania vektorov intenzít *op* a najhoršie prípady šírenia ich difúzie

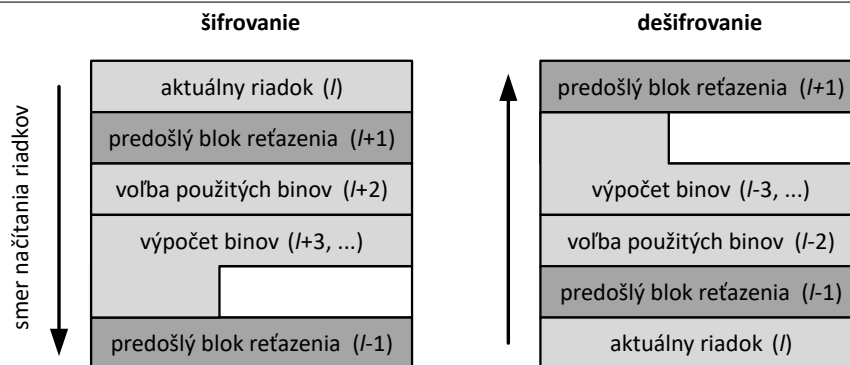
z opačnej strany obrazu. V prípade, ak má obraz súradnice riadkov $1, 2, \dots, h$ a súradnice stĺpcov $1, 2, \dots, w$ a je potrebné načítať riadky 0 alebo $h + 1$, resp. stĺpce 0 alebo $w + 1$, načítajú sa riadky h alebo 1, resp. stĺpce w alebo 1.

Pri dešifrovaní sa namiesto operácie XOR a sčítania v aritmetike modulo 256 použijú inverzné operácie. Zatiaľ čo pre operáciu XOR platí vlastnosť *involúcie*, teda táto operácia je sama sebe inverznou, miesto sčítania v aritmetike modulo 256 sa použije odčítanie v tejto aritmetike.

Závislosti intenzít *op*, ktoré vzniknú pri reťazení v tomto bloku sú *lineárne*. Nelinearitu, ktorá je pri aplikáciách v oblasti šifrovania žiadúcou, zabezpečuje nasledujúci blok. Pointou bloku "jednoduchého" reťazenia intenzít *op* je len vytvorenie závislostí medzi všetkými *op*. V prípade diferencného útoku a šifrovania dvojice podobných otvorených obrazov by sa aj malé rozdiely medzi týmito obrazmi mali prejaviť na intenzitách všetkých ostatných *op* obrazu.

2) Blok reťazenia intenzít op podľa intenzít op otvoreného, resp. zašifrovaného obrazu

V tomto bloku sa vytvára závislosť krokov obrazového šifrovacieho algoritmu na intenzitách *op* otvoreného, resp. zašifrovaného obrazu. Pre umožnenie dešifrovania je nutné zabezpečiť, aby boli rovnaké intenzity *op* získané z otvoreného obrazu pri šifrovaní a taktiež aj zo zašifrovaného obrazu pri dešifrovaní. Kvôli tomu sa obrazy v tomto bloku obrazového šifrovacieho algoritmu spracujú ako riadky intenzít *op*. Pri



Obr. 4. Riadky použité v bloku reťazenia intenzít op podľa intenzít op otvoreného, resp. zašifrovaného obrazu

šifrovaní sa riadky intenzít op načítajú zhora nadol a pri dešifrovaní sú riadky intenzít op načítané naopak – zdola nahor. Vďaka tomuto postupu sú intenzity op v riadkoch obrazov pri načítaní jednotlivých riadkov rovnaké.

Okrem zavedenia závislostí krokov obrazového šifrovacieho algoritmu na intenzitách op je úlohou tohto bloku aj spôsobenie *nelineárnych* rozdielov medzi intenzitami op pri šifrovaní alebo dešifrovaní podobných obrazov. Keďže v predošlom bloku boli vytvorené závislosti medzi intenzitami všetkých op , tento blok nemusí načítať intenzity op vo viacerých smeroch.

Na tieto účely sa používa MoT, ktorá z intenzít op obrazu vypočíta predpisom (1) biny. Podľa intenzít iných op sa následne vyberú biny, ktoré sa operáciou XOR skombinujú s aktuálne načítaným riadkom intenzít op . Súradnice riadkov intenzít op , ktoré sa používajú na tieto kroky ukazuje pre prípady šifrovania a dešifrovania Obr. 4.

Z Obr. 4 je zreteľné, že tento blok nevyužíva riadky intenzít op , ktoré boli použité v predošlom bloku “jednoduchého” reťazenia intenzít op . Na výpočet binov MoT sa používajú riadky intenzít op so súradnicami $l+3$ pri šifrovaní, resp. $l-3$ pri dešifrovaní, kde l je súradnica aktuálne načítaného riadku. Ak tieto riadky neobsahujú aspoň 144 intenzít op použijú sa nasledujúce riadky. Intenzity op sú načítané zľava doprava. V prípade, ak súradnica riadku $l+3$, resp. $l-3$ alebo súradnice ďalších riadkov $l+4, l+5, \dots$, resp. $l-4, l-5, \dots$ nepatria do množiny súradníc riadkov v obraze (sú menšie ako 1, resp. väčšie ako výška obrazu h), použijú sa namiesto nich riadky intenzít op s korešpondujúcimi súradnicami z hornej, resp. z dolnej časti obrazu $(1, 2, \dots, h, \text{ resp. } h, h-1, \dots, 1)$.

Zo získaných intenzít 144 op sa vypočíta 256 binov MoT. Parametre vypočítaných binov závisia od použitého kľúča, ktorý v algoritme [8] vygeneruje pomocou logistického zobrazenia dve postupnosti so 16 prvkami. Tieto prvky sú kvantované na prvky množiny $\{0, 1, \dots, 15\}$. Získané postupnosti sa použijú na cyklické posuny v rámci stĺpcov, resp. v rámci riadkov matice s rozmerom 16×16 prvkov. V tejto matici sa nachádzajú prvky množiny $\{0, 1, \dots, 255\}$ reprezentujúce parametre binov a ich poradové čísla. Vďaka preusporiadaniu matice sú teda preusporiadané aj parametre a poradové čísla binov [8]. Malá zmena intenzít op v riadku, ktorý volí biny použité na kombináciu teda spôsobí veľkú zmenu parametrov

a poradových čísel binov, čo znamená zavedenie *nelinearity* do krokov obrazového šifrovacieho algoritmu [8].

Parametre binov boli zvolené tak, aby spĺňali podmienky uvedené v kapitole II-A. Okrem toho parametre binov a ich poradové čísla spĺňajú aj ďalšie dve vlastnosti:

- $|p_i| > 3$ a súčasne $|p_i| \pmod{3} \neq 0$, teda intenzity op použité na výpočet každého binu sú vybrané z odlišných stĺpcov a z odlišných farebných zložiek obrazu (ak je obraz farebný) [8],
- poradové čísla binov b sú volené tak, aby boli všetky biny vypočítané práve z intenzít troch op , vďaka čomu by výpočty binov mali byť rýchle (pri zachovaní pozitívnych vlastností MoT) a zároveň by tieto výpočty mali trvať približne rovnakú dobu.

Parametre binov MoT (p, q) a ich poradové čísla b (pred ich preusporiadaním) ilustruje TABUĽKA I.

Pre každý aktuálne načítaný riadok intenzít op so súradnicou l sa vypočíta 256 binov MoT s parametrami podľa preusporiadanej verzie TABUĽKY I. Tieto biny sa použijú na zostavenie vektora vek_{biny} . Tento vektor má rovnaký počet prvkov ako aktuálne načítaný riadok intenzít op . Biny sa do vektora vek_{biny} ukladajú podľa intenzít op v riadku so súradnicou $l+2$ (pri šifrovaní), resp. $l-2$ (pri dešifrovaní). Po získaní hodnôt všetkých prvkov vektora vek_{biny} sa aktuálne načítaný riadok intenzít op s vektorom vek_{biny} skombinuje prostredníctvom operácie XOR.

Závislosť krokov obrazových šifrovacích algoritmov je v prípade tohto riešenia docieľená výberom parametrov a poradových čísel binov MoT podľa intenzít op v riadkoch obrazu so súradnicami $l+2$ (pri šifrovaní), resp. $l-2$ (pri dešifrovaní). Pri obrazoch s jednoduchou, resp. monotónnou scénou je potrebné zabezpečiť, aby boli vstupné obrazy pre blok reťazenia intenzít op podľa intenzít op otvoreného, resp. zašifrovaného obrazu vopred spracované. Toto spracovanie môže byť realizované napr. kombináciou s PNP alebo preusporiadaním intenzít op tak, aby intenzity op v riadkoch so súradnicami l a $l+2$, resp. $l-2$ neboli podobné. V prípade, ak by takéto predspracovanie nebolo aplikované, mohlo by dôjsť k analýze vlastností difúzneho bloku pri reťazení podľa podobných intenzít op .

TABUĽKA I
PARAMETRE BINOV MOĤ A ICH PORADOVÉ ČÍSLA

intenzita op	parametre binov ($p\ q$)	poradové číslo binu b
0 až 19	(-5 1)	{-56, -55, -51, -50, -46, -45, -41, -40, -36, -35, -31, -30, -26, -25, -21, -20, -16, -15, -11, -10}
20 až 35	(-5 2)	{-57, -55, -52, -50, -47, -45, -42, -40, -37, -35, -32, -30, -27, -25, -22, -20}
36 až 47	(-5 3)	{-58, -55, -53, -50, -48, -45, -43, -40, -38, -35, -33, -30}
48 až 55	(-5 4)	{-59, -55, -54, -50, -49, -45, -44, -40}
56 až 95	(-4 1)	{-47, -46, -45, -44, -43, -42, -41, -40, -39, ..., -10, -9, -8}
96 až 119	(-4 3)	{-53, -50, -49, -47, -46, -45, -44, -43, -42, -41, -40, ..., -32, -31, -30, -28, -27, -24}
120 až 127	(-4 5)	{-59, -55, -54, -50, -49, -45, -44, -40}
128 až 167	(4 1)	{-3, -2, -1, 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, ..., 34, 35, 36}
168 až 191	(4 3)	{-9, -6, -5, -3, -2, -1, 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 16, 17, 20}
192 až 199	(4 5)	{-15, -11, -10, -6, -5, -1, 0, 4}
200 až 219	(5 1)	{-1, 0, 4, 5, 9, 10, 14, 15, 19, 20, 24, 25, 29, 30, 34, 35, 39, 40, 44, 45}
220 až 235	(5 2)	{-2, 0, 3, 5, 8, 10, 13, 15, 18, 20, 23, 25, 28, 30, 33, 35}
236 až 247	(5 3)	{-3, 0, 2, 5, 7, 10, 12, 15, 17, 20, 22, 25}
248 až 255	(5 4)	{-4, 0, 1, 5, 6, 10, 11, 15}

C. Porovnanie navrhnutých riešení

Medzi prezentovanými riešeniami je viacero rozdielov. *Riešenie 1* vyžaduje použitie asymetrického kľúča, ale jeho výhodou je značná rýchlosť dosiahnutá použitím jednoduchého AZ. *Riešenie 2* je možné aplikovať v symetrických obrazových šifrovacích algoritmoch, avšak je potrebné rozdeliť reťazenie intenzít op na dva bloky, čo môže spôsobiť zníženie rýchlosti celého obrazového šifrovacieho algoritmu. Počas doktorandského štúdia bola väčšia pozornosť venovaná ďalším experimentom s *Riešením 2*, ktoré by malo umožniť vytvorenie obrazových šifrovacích algoritmov s väčším počtom aplikácií. Ako bolo už skôr spomenuté, pri tomto riešení je potrebné vhodne vybrať ďalšie bloky obrazového šifrovacieho algoritmu. Kvôli obmedzenému rozsahu tohto príspevku nie sú tieto bloky detailnejšie popísané, ich opis je možné nájsť v [8].

IV. EXPERIMENTÁLNE VÝSLEDKY

A. Vplyv použitých blokov *Riešenia 2* na hodnoty NPCR a UACI

Vplyv blokov použitých pri *Riešení 2* bol overený jednoduchým experimentom, pri ktorom sa používal obrazový šifrovací algoritmus popísaný v príspevku [8]. V tomto experimente boli postupne vytvárané varianty tohto obrazového šifrovacieho algoritmu, ktoré nepoužívali všetky bloky využívané pri difúzii intenzít op :

- *variant 1* predstavuje obrazový šifrovací algoritmus publikovaný v [8] bez zmien,
- *variant 2* nepoužíva blok reťazenia intenzít op podľa intenzít op otvoreného, resp. zašifrovaného obrazu,
- *variant 3* nepoužíva blok "jednoduchého" reťazenia intenzít op .

Pri výpočtoch hodnôt parametrov NPCR a UACI boli použité obrazy *lena*, *peppers* a *baboon* z databázy USC-SIPI [13]. Všetky uvedené obrazy mali rozlíšenie 512×512 op a farebnú hĺbku 8 bitov na op . Op , ktorý mal pri dvojici otvorených obrazov E_1 a E_2 odlišnú intenzitu bol zvolený na

TABUĽKA II
ZÍSKANÉ HODNOTY NPCR A UACI PRI VYNECHANÍ BLOKOV REĤAZENIA

parameter	variant	<i>lena</i>	<i>peppers</i>	<i>baboon</i>	očakávané hodnoty [10]
NPCR [%]	1	99,6111	99,6097	99,6089	> 99,5717
	2	97,8749	97,2263	97,4954	
	3	0,0016	0,0014	0,0019	
UACI [%]	1	33,4887	33,4926	33,4907	(33,3115; 33,6156)
	2	33,128	32,5977	32,8544	
	3	0,0001	0,0001	0,0001	

základe náhodného generovania jeho súradníc. Zmena intenzity bola vykonaná jej navýšením o jednu intenzitnú úroveň. Hodnoty NPCR a UACI uvedené v TABUĽKE II boli získané ako aritmetické priemery zo 100 opakovaných meraní, pri každom z nich prebehol nový výber súradníc op s pozmenenou intenzitou.

Hodnoty NPCR a UACI v TABUĽKE II poukazujú na skutočnosť, že pri použití *variantu 1* – obidvoch blokov *Riešenia 2* obrazový šifrovací algoritmus prezentovaný v príspevku [8] spĺňa očakávané hodnoty predstavené Wuom a kol. [10] pre úroveň významnosti $\alpha = 0,001$. Tým pádom zašifrované obrazy odolávajú diferenčným útokom s pravdepodobnosťou 99,9 %.

Variant 2 takéto hodnoty NPCR a UACI už nedosahuje. Kvôli nižším hodnotám NPCR a UACI klesá aj pravdepodobnosť odolania diferenčným útokom. Pre niektoré aplikácie je postačujúca aj nižšia úroveň tejto pravdepodobnosti, avšak je potrebné si uvedomiť, že obrazový šifrovací algoritmus s takouto architektúrou by dosahoval oproti ostatným obrazovým šifrovacím algoritmom výrazne horšie výsledky. Porovnaním hodnôt NPCR a UACI pre viacero obrazových šifrovacích algoritmov sa bližšie zaoberá kapitola IV-B.

Variant 3 ukazuje na najväčší nedostatok samotného bloku reťazenia intenzít op podľa intenzít op otvoreného, resp. zašifrovaného obrazu. Tým je skutočnosť, že kroky tohto bloku sa vykonávajú iba v jednom smere, teda sa nešíria do celého

obrazu. Z toho dôvodu sa pri zmene intenzity jedného *op* ovplyvnia už iba intenzity tých *op*, ktoré nasledujú pri načítaní, resp. intenzity tých *op*, ktoré sa skombinujú s binmi MoT, ktoré vznikli z ovplyvnených intenzít *op*.

B. Porovnanie dosiahnutých hodnôt NPCR a UACI s inými algoritmami

Obrazové šifrovacie algoritmy je možné porovnávať z viacerých hľadísk, napr. pomocou dosahovaných hodnôt NPCR a UACI. Ako už bolo spomenuté, *Riešenie 2* difúzneho bloku bolo aplikované v obrazovom šifrovacom algoritme popísanom v publikácii [8]. Získané aritmetické priemery 100 opakovaných meraní NPCR a UACI pre tento algoritmus a obraz *lena* s rozlíšením 512×512 *op* a farebnou hĺbkou 8 bitov na *op* z databázy USC-SIPI [13] ukazuje prvý stĺpec TABULKY III. Pri každom opakovanom meraní bol použitý iný náhodne generovaný kľúč a iné náhodne vygenerované súradnice *op* s pozmenenou intenzitou. V nasledujúcich stĺpcov sú uvedené výsledky aj pre algoritmy C. Fua a kol. [14], Y. Zhanga [15] a X. Chaia a kol. [16]. Všetky uvedené algoritmy používali na získanie hodnôt NPCR a UACI opísaný obraz *lena*.

TABULKA III
POROVNANIE HODNÔT NPCR A UACI S INÝMI ALGORITMAMI

parameter	alg. [8]	alg. [14]	alg. [15]	alg. [16]
NPCR [%]	99,61	99,62	99,6101	99,62
UACI [%]	33,4714	33,46	33,4679	33,45

Údaje uvedené v TABULKE III poukazujú na skutočnosť, že obrazový šifrovací algoritmus [8] využívajúci *Riešenie 2* difúzneho bloku dosahuje hodnoty NPCR a UACI porovnateľné s hodnotami získanými inými algoritmami. Pri vynechaní niektorého z blokov *Riešenia 2* (výsledky prezentované pre *varianty 2 a 3* v TABULKE II) sú hodnoty NPCR a UACI výrazne horšie.

V. ZÁVER

Tento príspevok sa zaoberal stručným popisom dvoch riešení difúzneho bloku pre obrazové šifrovacie algoritmy. Zatiaľ čo *Riešenie 1* je výhodné z hľadiska nízkej výpočtovej náročnosti, *Riešenie 2* je univerzálnejšie, keďže je ho možné použiť aj v symetrických obrazových šifrovacích algoritmoch. Po zhodnotení vlastností oboch riešení sa príspevok ďalej venoval overeniu miery difúzie intenzít *op* spôsobenej *Riešením 2*, ktoré bolo počas doktorandského štúdia používané pri návrhu obrazových šifrovacích algoritmov častejšie.

Miera difúzie intenzít *op* bola vyhodnotená na základe hodnôt parametrov NPCR a UACI. Bolo zistené, že pri použití *Riešenia 2* v obrazovom šifrovacom algoritme [8] sú získané hodnoty NPCR lepšie ako očakávané hodnoty, resp. získané hodnoty UACI sú v intervale očakávaných hodnôt [10]. Pri snahe o zrýchlenie *Riešenia 2* vynechaním niektorého z blokov však nastáva nežiadúci pokles hodnôt NPCR a UACI.

V budúcnosti je možné uvažovať o ďalšom štúdiu operácií používaných v difúznych blokoch obrazových šifrovacích algoritmov. Rast výkonnosti hardvéru alebo lepšie prispôbenie

softvérových prostriedkov môže totiž umožniť používanie zložitejších operácií, ktorých výsledkom bude dosiahnutie ešte lepších hodnôt NPCR a UACI.

POĎAKOVANIE

Práca na tomto príspevku bola podporená prostriedkami z výskumných grantov KEGA 023TUKE-4/2017 a VEGA 1/0772/17.

LITERATÚRA

- [1] J. Fridrich, Symmetric ciphers based on two-dimensional chaotic maps. V: *International Journal of Bifurcation and Chaos*, 1998, roč. 8, zv. 6, s. 1259-1284. ISSN: 0218-1274. DOI: 10.1142/S021812749800098X.
- [2] C. E. Shannon, Communication theory of secrecy systems. V: *The Bell System Technical Journal*, 1949, roč. 28, zv. 4, s. 656-715. ISSN: 0005-8580. DOI: 10.1002/j.1538-7305.1949.tb00928.x.
- [3] G. Chen, Y. Mao, C. K. Chui, A symmetric image encryption scheme based on 3D chaotic cat maps. V: *Chaos, Solitons and Fractals*, 2004, zv. 21, č. 3, s. 749-761. ISSN: 0960-0779. DOI: 10.1016/j.chaos.2003.12.022.
- [4] Y. Mao, G. Chen, S. Lian, A novel fast image encryption scheme based on 3D chaotic baker maps. V: *International Journal of Bifurcation and Chaos*, 2004, roč. 14, zv. 10, s. 3613-3624. ISSN: 0218-1274. DOI: 10.1142/S021812740401151X.
- [5] K. Wang, W. Pei, L. Zou, A. Song, Z. He, On the security of 3D cat map based symmetric image encryption scheme. V: *Physics Letters A*, 2005, zv. 343, č. 6, s. 432-439. ISSN: 0375-9601. DOI: 10.1016/j.physleta.2005.05.040.
- [6] E. Solak, C. Çokal, O. T. Yıldız, T. Biyikoğlu, Cryptanalysis of Fridrich's chaotic image encryption. V: *International Journal of Bifurcation and Chaos*, 2010, roč. 20, zv. 5, s. 1405-1413. ISSN: 0218-1274. DOI: 10.1142/S0218127410026563.
- [7] E. Y. Xie, C. Li, S. Yu, J. Lü, On the cryptanalysis of Fridrich's chaotic image encryption scheme. V: *Signal Processing*, 2017, zv. 132, č. C, s. 150-154. ISSN: 0165-1684. DOI: 10.1016/j.sigpro.2016.10.002.
- [8] L. Ovseník, J. Turán, T. Huszaník, J. Oravec, O. Kováč, M. Oravec, An image encryption algorithm with plaintext related channing. Príspevok zaslaný na recenzii do časopisu *Computing and Informatics*.
- [9] J.-P. Guédon, D. Barba, N. Burger, Psychovisual image coding via an exact discrete Radon transform. V: *Proceedings of International Conference on Visual Communications & Image Processing VCIP '95*, Taipei (Taiwan), apríl 1995, s. 562-572. ISBN: 978-08-1941-858-7. DOI: 10.1117/12.206765.
- [10] Y. Wu, J. Noonan, S. Agaian, NPCR and UACI randomness tests for image encryption. V: *Journal of Selected Areas in Telecommunications*, 2011, roč. 2, zv. 4, s. 31-38. ISSN: 1925-2676.
- [11] J. Oravec, J. Turán, L. Ovseník, T. Ivaniga, D. Solus, M. Márton, Asymmetric image encryption approach with plaintext-related diffusion. V: *Radioengineering*, 2018, roč. 27, zv. 1, s. 281-288. ISSN: 1210-2512. DOI: 10.13164/re.2018.0281.
- [12] V. Arnold, A. Avez, Ergodic problems of classical mechanics. New Jersey: W. A. Benjamin, 1968. 296 s.
- [13] Databáza obrazov USC-SIPI [online]. [cit. 2019-03-04]. Dostupné na internete: <http://sipi.usc.edu/database/>.
- [14] C. Fu, J.-J. Chen, H. Zou, W.-H. Meng, Y.-F. Zhan, Y.-W. Yu, A chaos-based digital image encryption scheme with an improved diffusion strategy. V: *Optics Express*, 2012, roč. 20, zv. 3, s. 2363-2378. ISSN: 1094-4087. DOI: 10.1364/OE.20.002363.
- [15] Y. Zhang, A chaotic system based image encryption algorithm using plaintext-related confusion. V: *Indonesian Journal of Electrical Engineering and Computer Science*, 2014, roč. 12, zv. 11, s. 7952-7962. ISSN: 2502-4760.
- [16] X. Chai, Z. Gan, M. Zhang, A fast chaos-based image encryption scheme with a novel plain image-related swapping block permutation and block diffusion. V: *Multimedia Tools and Applications*, 2017, zv. 76, č. 14, s. 15561-15585. ISSN: 1380-7501. DOI: 10.1007/s11042-016-3858-4.

Fuzzy Cognitive Maps for Control Tasks in Intelligent Space

Michal Puheim

Department of Cybernetics and Artificial Intelligence
Technical University of Košice
Letná 9, 042 00 Košice, Slovak Republic
michal.puheim@tuke.sk

Ján Vaščák

Department of Cybernetics and Artificial Intelligence
Technical University of Košice
Letná 9, 042 00 Košice, Slovak Republic
jan.vascak@tuke.sk

Abstract—The main objective of this paper is to present an application of fuzzy cognitive maps for control of the intelligent space based on a paradigm of the internet of things. The paper provides a brief overview of various methods and tools applicable to control complex systems. It introduces the methodology of situational control aided with the means of artificial intelligence focused on utilization of fuzzy cognitive maps. Extensions to basic fuzzy cognitive maps are proposed and implemented using a novel programming library with its appropriate web-based application programming interface, which is then used to prototype a specific model of situational control of intelligent space for navigation of a mobile robot.

Keywords—fuzzy cognitive maps; robot navigation; situational control; intelligent space

I. INTRODUCTION

A control of complex systems is currently a very active topic, especially with regard to the rise of the internet of things, intelligent spaces and ubiquitous robotics. In order to solve problems in this area, it is possible to successfully utilize various means of artificial intelligence, such as fuzzy cognitive maps (FCM). The implementation strategies for control of complex systems is possible by using several approaches, including the situational control.

This paper provides a summary of the work as presented in the dissertation[1]. The main goal of this work was an application of fuzzy cognitive maps for control of the intelligent space considered as complex system. We applied a methodology of situational control in order to propose a general model of control and also implemented a specific control strategy for the situational frame of robot navigation.

In order to deal with this task, several additional goals had been set. We considered it viable to modify the basic conception of FCM in order to enable and simplify modeling of complex systems. It was also necessary to create various software tools, that made the implementation of control strategies possible, therefore we proposed to create a novel FCM library along with appropriate application programming interface (API) and user interfaces. Using these tools, we created a situational model for control of the intelligent space and defined a control strategy for a situational frame of robot navigation. The model was verified in a simulation.

The rest of this paper is organized accordingly to the source [1] as follows: In section II we initiate the discussion with an overview of control and modeling of complex systems, where we introduce the methodology of situational control.

In section III we provide an overview of several means and tools of artificial intelligence applicable for control of complex systems, specifically focusing on methods of computational intelligence, such as artificial neural networks, fuzzy inference systems and evolutionary optimization.

In section IV we introduce fuzzy cognitive maps (FCM) as a selected method of computational intelligence, specifically chosen to achieve established goals. We discuss various aspects of FCM, including its applications, basic description, formal definition and inference model.

Section V is specifically focused towards applications of FCM to system control. Several extensions to a basic FCM design are proposed, including three-term and neural relations. A goal of these extensions is to improve FCM applicability to model and control complex systems. In addition to expert oriented FCM design, we introduce additional possibilities for automatic adaptation of FCMs using either methods from the area of neural networks or evolutionary optimization.

In section VI we provide a brief introduction to the internet of things (IoT) and intelligent spaces (IS). We further analyze background technologies that make implementation of these paradigms possible, including basics of modern network communication and its associated computing models such as cloud, fog and edge computing. In addition, we include a brief description of a specific example of intelligent space and discuss its specific application for control of service robots using the paradigm of ubiquitous robotics. Finally, we demonstrate an unambiguous confirmation of IS as a complex system, hence arguing the possibility to utilize all the methods applicable to control complex systems.

In section VII we compose the requirements for software tools necessary to implement control structures in scope of IoT and intelligent spaces. We propose and describe an implementation of a novel FCM library along with a corresponding API available via network HTTP protocol.

In section VIII we synthesize our ideas and offer a proposal for situational control of intelligent space using a formatter composed of various network services. In order to demonstrate applicability of the proposed control structure, we show a simulation which implements an exemplary model of control strategy for the situational frame of robot navigation.

The final conclusion in section IX describes the main contributions of the work[1] and propose further research and development options.

II. CONTROL AND MODELING OF COMPLEX SYSTEMS

An arbitrary system may be considered as “purposely defined set of elements and links between them, which is separated from other objects in space and time by a real or virtual boundary”[2]. It is already clear from this definition that a particular system and its characteristics may vary considerably depending on the different baseline requirements. For this reason, the concept of a complex system can be attributed to a wide range of controlled objects and relevant control subsystems.

For our purposes we will define a complex system as a system consisting of the final number of elements (systems, subsystems, elements) and their interconnections, which are subject to the following characteristics [3][4][5][6][7][8]:

- There is a large number of elements that can be readjusted (either added or removed).
- Relationships between the elements defining the structure of the system may change as well (including the elements themselves).
- Hierarchy of the organizational structure of the components of the system (regardless of whether it is a management or controlled system).
- The right of autonomous decision-making of elements (the organization of the system is often decentralized, so that individual elements have large degree of autonomy).
- Change of space (dimension of space) in which the system is located and in which it operates.
- Change in the organizational structure of the system (i.e. links and relations of elements may be changed through organizational interventions in the course of system control in order to fulfill the predetermined global objectives).

Situational control is an important methodological practice applicable to control of complex systems [2]. The starting point for using the methodology is the assumption that the controlled system can be found in infinitely large number of states, while the amount of resources enabling its control is usually limited [6]. When using the situational control, a formal model is integrated into the control system, which allows to anticipate the consequences of individual decisions and to choose the most appropriate solution with regard to the chosen control criteria [4]. In other words, for the different situations in which the system may be located, we assign pre-prepared decisions (control strategies), which count is usually much smaller than the number of possible situations [7].

The proposal for situational control of complex system is a challenging process consisting of several steps. In principle, these steps can be divided to the planning or design stage and subsequently to the operational control stage [4]. The planning stage begins with:

- 1) a description of the controlled complex system,
- 2) a definition of global control objectives,
- 3) and a proposal of situational classes (frames), which can group several similar situations or states of the system.

The relevant control strategies are then assigned to the individual situational classes. Each situational class covers at least one control strategy, but there may also be cases where one class covers several strategies. In the event that one specific strategy covers several different situational classes, it is appropriate to consolidate these classes and, where

appropriate, to revise the proposal in general. To ensure effective operation of the control system, the number of classes and strategies should be minimized [6].

The operational control of the complex system then deals with a parameterization of pre-prepared control strategies according to the current state of the system and their use in system control. The goal is to offset the deviations from the required system state in real time [4]. The control process contains three fundamental decision-making steps [4]:

- 1) The situational classification of the current state.
- 2) The choice of a corresponding control strategy.
- 3) The realization of particular control functions.

The implementation of these processes is related to the nature of a specific complex system. It also depends on the chosen methods which include conventional methods (e.g. mathematical-statistical methods, multi-criterial decision-making, group decision-making, etc.) or smarter approaches including various methods of computational intelligence [4][6], briefly described in the next section.

III. COMPUTATIONAL INTELLIGENCE FOR CONTROL AND MODELING OF COMPLEX SYSTEMS

Artificial intelligence deals with creation of systems that have the ability to deal with tasks that are expected to be solved only by a person with knowledge of the problem domain [9]. The basic features of intelligent technologies include the following capabilities [9]:

- Learn from data and gain knowledge.
- Store knowledge acquired in the past.
- Use obtained knowledge in future problem-solving.

Modern approaches based on methods of computational intelligence (also known as subsymbolic artificial intelligence or soft computing) are characterized by a non-symbolic representation of knowledge. They represent the “bottom-up” approach, which is inspired mainly by low-level perception processes, biological processes, evolutionary principles and natural phenomena. The prevailing philosophy is connectionism, which assumes that simple parts can be combined to assemble sophisticated systems with high abstract intelligence [10]. The most representative method of computational intelligence are artificial neural networks, fuzzy systems and evolutionary algorithms.

An artificial neural network (see Fig. 1) is a massive parallel processor that can store knowledge of the solution to the specific problem and use it to solve similar problems in the future [11]. The basic structural and processing unit of the network is an artificial neuron that influences other neurons through one-way links, synapses. The strength of influence between two neurons is directly proportional to the value of the synaptic weight corresponding to the link. The values of weights are the main parameters determining the function of the network and therefore represent the stored knowledge [11].

The operation of an artificial neural network can be divided into two phases. During the learning phase during which the knowledge is stored in the network through a goal-oriented adaptation of the synaptic weights. This process is often performed by supervised learning, where the corresponding output data is available for the input data. The results of network propagation therefore can be compared with the reference data and used to train the network. After the training, during the life phase, the knowledge obtained in the learning process is used to address a problem (e.g. classification,

optimization, aggregation, etc.). In this phase, synaptic weights are no longer changing [11].




Fig. 1. Multi-layer feed-forward neural network with two hidden layers [1].

Evolutionary algorithms represent a set of methods applicable to optimize the parameters of various systems [12]. The optimization is based on the evolution of the population of individuals, where each individual represents a particular solution to the optimization problem. These solutions are gradually changed by the algorithm using processes similar to those applied in natural selection, such as reproduction and mutations. A general approach of the evolutionary algorithm is shown on Fig. 2.

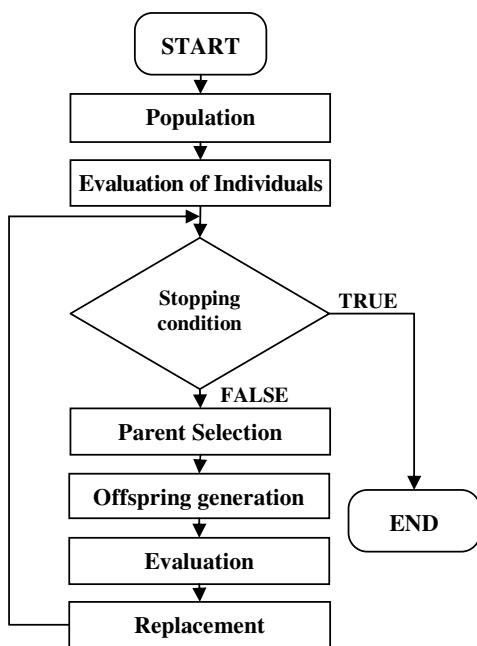


Fig. 2. General scheme of evolutionary algorithm [1].

Fuzzy logic is often used to control nonlinear systems. The notion of fuzzy (unclear, blurry, vague) refers to the fact that some logical expressions cannot be clearly defined as either true or false, but rather than partially true or partially false. An advantage of this approach is that the solution to the problem can be expressed in a way easily understood by a human, so that his experience can be used to improve the solution. A starting term in this area is fuzzy set. Compared to a conventional crisp set which defines membership of elements either as true or false, the fuzzy set defines a probability of membership for every element using a function in range from 0 to 1. This function hence represents the element's degree of membership to the set.

Fuzzy sets are basic building blocks for creation of more complex logical structures with broader applications. An example of such a structure is a linguistic variable (see Fig. 3), which is formally defined as the ordered tuple [13]:

$$LV = \{N, T(N), U, G, M\}, \tag{1}$$

where N is a name of the linguistic variable (e.g. age), $T(N)$ is a set of linguistic terms (e.g. young, adult, senior), U is the universal set, G are syntactic rules, which define the formation of names and terms, and M are semantic rules, which assign an appropriate fuzzy set to each linguistic term [1].

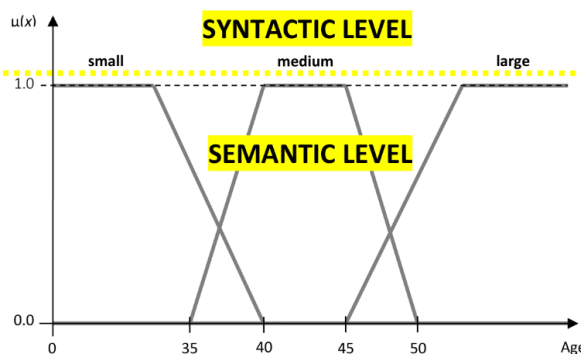


Fig. 3. Fuzzy linguistic variable [1].

A particular useful application of linguistic variables is to create fuzzy rules. Any traditional crisp production rule can be fuzzified by using linguistic variables (e.g. age, height, weight) and specific linguistic terms (small, medium, large) into a fuzzy production rule such as [1]:

```

IF <age is low> & <weight is high>
THEN <life hazard is high>
  
```

Similar fuzzy rules can be used for design and implementation of fuzzy inference systems (FIS) that are applicable to control of various processes. There are two basic types of FIS. The structure of a fuzzy rule which is displayed above is used in Mamdani FIS, which is among the oldest types of FIS. It creates a whole new fuzzy set as its output. However, other derived types of FIS are currently being used, e.g. Takagi-Sugeno-Kang FIS [14], which produces its output not as a fuzzy set, but rather an analytical function. Therefore, the rules are defined as [1]:

```

IF <x1 is high> & <x2 is low>
THEN <y=f(x1, x2)>
  
```

In practice, FIS can be used to deal with various tasks, e.g. development of expert systems, classifiers, predictors, nonlinear approximation models, system models, etc. For the purposes of system control it is possible to use it in the design of fuzzy controllers (see Fig. 4).

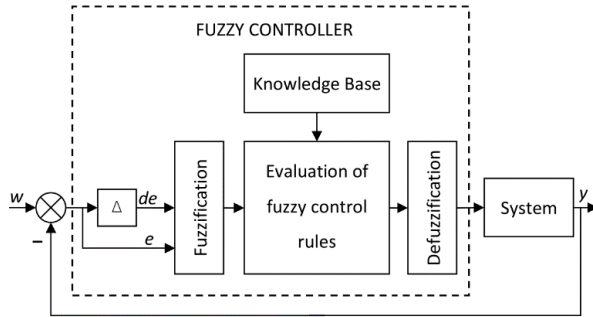


Fig. 4. Structure of fuzzy controller [1].

IV. FUZZY COGNITIVE MAPS

Fuzzy cognitive maps (FCM) can be considered as a special type of a fuzzy inference system, whose structure and method of inference is very similar to that of Takagi-Sugeno-Kang model. The advantage of FCM is a simplification of display of rules in a graphic form that is clear and transparent also for a relatively large number of rules, as opposed to its explicit expression. This feature is particularly important when modelling systems with a large number of relations and interactions between individual elements[1].

FCMs are widely used as an inference tool for modeling both qualitative and quantitative complex relationships across a broad range of various technical and non-technical systems in a simple and comprehensible way. In the last decade, FCMs has played an important role in applications in many areas of research including social and political science, engineering, information technology, robotics, expert systems, medicine, education, prediction, environment and other [15]. An example of FCM is depicted on Fig. 5.




Fig. 5. Example of fuzzy cognitive map [1]

There are several definitions of the FCM. For instance, Chen [16]define it as a quadruple:

$$FCM = (C, W, \alpha, \beta), \tag{2}$$

where $C = \{C_1, C_2, \dots, C_n\}$ is a finite set of cognitive units (concepts), $W = \{w_{11}, w_{12}, \dots, w_{mm}\}$ is a finite set of oriented connections between concepts, $\alpha \rightarrow [0, 1]$ is a membership function of a concept defining a grade of membership of real-world values corresponding to this concept, and $\beta \rightarrow [-1, 1]$ defines relations between individual concepts [1].

A general rule to evaluate the activation value of the concept C_j in every simulation step is to determine the influence of other preceding concepts C_i (where $i = 1 \dots m$), which are connected to the concept C_j (see Fig. 6) [1].




Fig. 6. Activation of concept depends on values of preceding concepts [1].

V. SYSTEM CONTROL AND MODELING USING FUZZY COGNITIVE MAPS

FCMs are suitable to deal with two main problem types: The first one deals with a creation of a regression model of the system [17]. It is the most frequent task for which FCM is used. Its goal is to use an FCM to create a corresponding real-system model. Conventional FCMs are most commonly used for modeling closed systems without external inputs. However, after some modification of the structure and computation process, it is also possible to model open systems [18].The second type deals with encoding of the attractor leading to specific goal state of the system. In this case an FCM is used to control the system in order to converge from any initial state into the desired target state. In this case, we do not necessarily have to set all the FCM parameters because the model of the controlled system can be pre-defined. The goal is to determine only the parameters (weights) of the selected controller concepts [17].

In order to utilize FCMs for control of complex systems, we proposed Three-Term Relation Neuro-Fuzzy Cognitive Map (TTR NFCM)[19] as a novel hybrid method designed particularly to model complex systems. The proposed method enhances the conventional FCMs by adding two new features. The first one is an inclusion of historical values or trends into the concept update formula using the Three-Term Relations (TTR), which are inspired by methods from the control engineering, especially the Proportional-Integral-Derivative controllers [1][19]. The TTR method evaluates activation values of concepts in a similar manner to Fig. 6, however it utilizes three weights per single relation. The concept update formula is hence defined as[19]:

$$A_j(t+1) = p \left(\sum_{i=1}^n w_{ij}^p P_i(t) + w_{ij}^v V_i(t) + w_{ij}^d D_i(t) \right) \tag{3}$$

where A_j is an activation value of subsequent concept C_j , p is activation function and $w_{ij}^p, w_{ij}^v, w_{ij}^d$ are relation weights between concepts C_i and C_j . Three-Term components P_i (proportional), V_i (moving-average) and D_i (differential) are derived from an activation value A_i of preceding concept C_i and defined according to Fig. 7.




Fig. 7. Three-Term Relation between two concepts [19].

While utilizing the TTR, the concepts will react to the last state (or the last activation value of the concept) similarly to the conventional FCM, thanks to the proportional component P_i . The additional moving average component V_i enables the concepts to react to the long-term trends. This can mitigate short-lived disturbances, noise, or implicit oscillations within the map. The concepts can also react to the sudden changes faster than usual thanks to the derivative component D_i . Conveniently, there is only single tunable parameter T , which determines the number of previous states considered within the moving average component V_i [1].

An additional feature of TTR NFCM is the replacement of simple linear weights between concepts by small feed-forward artificial neural networks, which modifies the FCM into the hybrid Neuro-Fuzzy Cognitive Map (NFCM) [1][19].




Fig. 8. Neuro-Fuzzy Cognitive Map displayed as an unwrapped graph[19].

In order to create a system model based on FCM, it is necessary to parameterize the model using either expert design or automated methods. Several automated methods are available for learning of FCMs, most of which are based on ideas from the field of artificial neural networks. Machine-learning algorithms can train FCM, i.e. purposefully modify the strength of interconnections (weights) between concepts, similarly to synapses between neurons in neural networks [20]. These methods often use a backpropagation of least-mean-square (LMS) error, hence we often refer to them as LMS methods.

Another interesting approach to adaptation of system parameters is to use interactive evolutionary optimization (IEO), an example of which was demonstrated in [21], where we applied IEO for adaptation of FCM controller of a mobile robot driven on a simulated racing track. The results were comparable to traditional non-interactive evolution (by self-organizing migrating algorithm) that used analytic fitness function. The relative comparison of results is shown in Tab. I. A simulator software is available at [22].

Tab. I. RELATIVE COMPARISON OF FCM AND AN-FIS CONTROLLERS[21]

Controller	C1	C2	C3	C4	C5	C6
FCM1	0,756	0,978	0,982	0,664	0,871	1

FCM2	1	0,937	1	1	0,601	0
FCM3	0,825	1	0,984	0,816	0,713	1
FCM4	0,853	0,961	0,978	0,781	0,753	1
FCM5	0,783	0,978	0,974	0,743	0,777	0
AN-FIS	0,553	0,417	0,974	0,585	1	0

Notes: The criterion C1 represents the average angle of the robot trajectory related to the center of the track. The smaller the value is the more stable the solution is. The criterion C2 represents relative average acceleration or deceleration. Again, lower value is better since control is smoother and more stable. The criterion C3 represents the total length of the trajectory (lower is better). The criterion C4 represents the average speed (higher is better). The criterion C5 represents the time necessary to complete the circuit (lower is better). The criterion C6 shows the number of collisions, which should be prevented (lower is better). The best results are displayed in bold [21].

The main advantage of IEO is its application even in case when it is impossible to express the fitness function in an exact analytical form. However, there are also some drawbacks, where the most obvious one is human fatigue. The evaluation process during IEO is very time demanding for a human evaluator, who may be subject to exhaustion and consequent errors, which is obviously undesirable[1].

With this consideration, we proposed another novel approach[23] which combines automatic heuristic optimization with interactive optimization into hybrid semi-interactive evolutionary optimization (S-IEO). The main advantage of the method is the overall speed-up of the optimization process along with a reduction of expert involvement and fatigue[1].

The S-IEO changes the typical IEO algorithm in several areas. The human evaluator is provided with a complementary heuristic function that can be used to help with evaluation, or it may be used to let the evolution run automatically, without intervention, provided that the current progress is considered satisfactory. Human evaluator may intervene in evolution as soon as it seems appropriate, or he may decide to intervene regularly, i.e. every 10th generation in order to remove individuals which are considered unfit for further evolution[1].

According to preliminary results from our work-in-progress [23], the overall program runtime of S-IEO was decreased by 42 % compared to the non-interactive evolution and by 14 % compared to the fully-interactive evolution. The evolution time of both S-IEO and the fully-interactive version is comparable but significantly lower (by approx. 60 %) to that of the non-interactive version, since without human evaluator it has to explore significantly higher portion of the search space. Very promising are the results tied to human fatigue. It is clear, that both the unused waiting time and also the interaction time are lower by almost 70 % in favor of S-IEO [1].

VI. INTELLIGENT SPACE AS COMPLEX SYSTEM

The Internet of Things (IoT) is a recent paradigm that aims to cross barrier between the physical and digital world. The main idea is to “integrate the state of the things that form the world into software applications, making them benefit from the world’s context information” [24]. IoT allows common everyday objects in our environment to become active participants in mutual communication with people, by sharing information with other members of IoT network, and to be able to recognize events, changes in their surroundings and respond to them in an appropriate manner autonomously[1].

It is obvious, that computer networks may connect devices with various hardware architectures and operating systems. However, even in spite of variability of hardware and software, the communication and data exchange between different

devices can be established using recognized communication protocols. Since the matters of inter-computer communication are complex, a whole system of protocols has been established by the International Organization for Standardization (ISO). The proposed reference model was marked as Open Systems Interconnection (ISO/OSI) [25]. It has separated network communication in seven layers, including physical layer, data-link layer, network layer, transport layer, session layer, presentation layer and application layer [1].

Without any doubt, the most used internet service is a World Wide Web (www), which applies the Hypertext Transfer Protocol (HTTP) running on the top-most layers of ISO/OSI. HTTP enables a connection between clients and servers using a request-response communication. It uses several methods, from which the most utilized are GET, which is used to request data from a specific resource on a server, and POST, which is used to send data to a server or upload a resource. Since www-related services are so prevalent, the HTTP protocol has started to be used in new, previously unconsidered ways, especially with regards to the rise of IoT. HTTP requests can be used to send commands to various IoT devices, to receive information from sensors and to create human-computer interfaces. HTTP is frequently used for creation of Application Programming Interfaces (API), which can be used with cloud computing services [1].

Current progress of IoT is related very tightly to the advancement and application of cloud computing tools and services. Cloud computing is characterized by on-demand services provided as needed without requiring human intervention, as well as broad network access, resource pooling which serves multiple consumers at once, and rapid elasticity where services scale according to the demand. Cloud services are also often metered, providing transparency of utilized resources to both the consumer and provider of the service [26].

However, the cloud solutions may not be suitable in all cases, especially for transfer and processing of large amounts of data. The solution to this issue can be found in application of fog computing closer to the edge of the network. Fog computing provides intermediary computation, storage, and networking services located between end devices and traditional cloud servers [27]. It's a hybrid system-level architecture paradigm where the possibilities of cloud computing, distributed processing and analytics power are brought closer to the edge of a network. It does so in a different way than edge computing, which aims to bring the intelligence, analytics, computing, communications etc. directly into the devices at the edge [1].

An Intelligence Space (IS) is a specific manifestation of the Internet of Things (IoT) in which *“the actions of numerous networked controllers controlling different aspects of a common environment are orchestrated by pre-programmed pre-emptive processes (e.g., intelligent software agents) in such a way that it enhances experiences and capabilities of its occupants;”* either humans or machines [28]. The term often describes a place with considerable distribution of sensors and intelligent devices which are interconnected via communicating technologies often using the IoT paradigm. Such spaces may include a room, a corridor, a street or even entire city equipped with sensors and actuators. The goal of sensors is to acquire data about actions in the surrounding environment. Actuators use these data in order to interact with inhabitants of the space, humans and robots [29].

As an example of IS we propose an implementation [30] at the Center for Intelligent Technologies (CIT) [31]. The implementation utilizes several types of sensors, including 16

IP Cameras with microphones, 6 Kinects and also other IoT sensors, for acquisition of environment variables such as light intensity, temperature, air quality, loudness, ultrasound, infrared light, etc. In addition, we expect utilization of RFID cards and readers, E-beacon technologies and more. As a basis of the computing infrastructure, we assume the utilization of two main fog-computing servers, six mini-PCs which process the inputs from Kinect sensors and several other PCs serving as dedicated micro-servers for remote monitoring and control. The robotic hardware includes Aldebaran Nao, SONY AIBO, TheCorpora Qbo, Robotnik TurtleBot and other robots [30]. Fig. 9 displays an overview of the IS using the camera monitoring web application [32]. A floor plan of the IS is shown in Fig. 10 [30].




Fig. 9. Monitoring system of IS at CIT [32].




Fig. 10. Portion of the floor plan of IS at CIT [30].

In order to calculate a projected data flow from sensors, we estimated that IP cameras produce MJPEG streams of HD video at rate of approximately 10 Mb/s for each camera. Kinect sensors produce streams which are at least 1,6 times as much (colored image + grayscale depth map + contour image). With a total count of 16 cameras and 6 Kinects and estimated data generation at a rate of 250 Mb/s, it is definitely not feasible to perform its processing on cloud services, and therefore it needs to be processed locally on fog computing infrastructure. For audio and other data, we consider an option to use cloud services directly, since these are not so bandwidth demanding [30].

The proposal[30] assumes to use two local networks bridged via fog computing servers (see Fig. 11). The first, hidden network (LAN1) connects the bandwidth-demanding cameras and Kinects directly to the servers via high capacity 1 Gb/s optical connection. The second, publicly open network (LAN2) connects other devices, including low bandwidth wireless IoT sensors, robots, users' PCs and other clients. The access to video sources (on LAN1) is possible via an

interfacing application deployed on the fog computing servers [30].

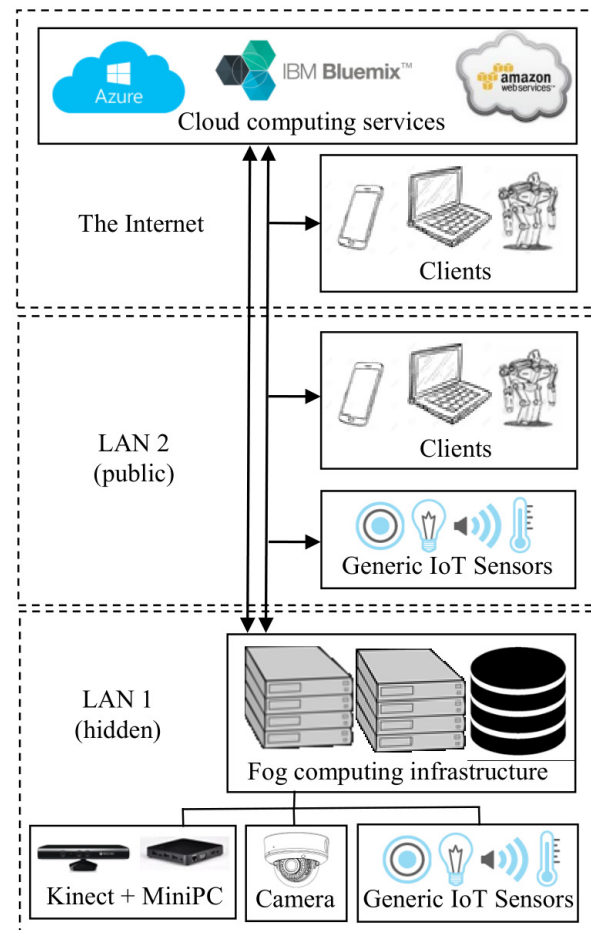


Fig. 11. Networking Proposal of IS at CIT [30].

Service robots are considered as a promising feature of IS [32][33][34], even though fully autonomous control of robots is still considered a challenging task, which necessarily deals with various problems such as robot localization, object tracking, path planning, navigation, movement control, obstacle detection, avoidance etc. Since these problems are difficult to be solved by a single autonomous unit, the attention of researchers and businesses is being focused towards so-called ubiquitous robotics [32][35], which consider a robot in an intelligent space as an agent consisting of three separate components [36]: real mobile robot, virtual robot model (avatar), separated sensory system in a surrounding environment. This combination of independent components enables a robot to perform more complex tasks than a traditional autonomous unit, thanks to the use of additional sensors located within IS and additional computing capabilities provided by either fog or cloud computing infrastructure.

Since we aim to apply a methodology of situational control intended to be used for management and control of complex systems, we would like to justify its application by an unambiguous confirmation of the intelligent space as a complex system. In general, a complex system can be described as such a system, where there is a large number of forming elements, which total quantity, mutual relations and organization structure can be changed at any time. The

elements form a hierarchical structure while retaining the right of autonomous decision-making [5]. In comparison, the internet is probably the most complex system humans have ever designed. It forms the hierarchical structure as the network of networks, where each network utilizes similar globally recognized technologies and protocols. Each network device cooperates according to the ISO/OSI model, which is hierarchical by its definition. Since the intelligent space is based on paradigms of the global internet and IoT, it can be assumed as complex system and therefore, all the management and control methodologies (including situational control) may be applied. A proper control of intelligent space naturally requires appropriate software tools, powerful enough to fit various use cases [1]. For this purpose, we propose a novel fuzzy cognitive maps library and corresponding application programming interface, described in the following sections.

VII. SOFTWARE TOOLS FOR CONTROL OF INTELLIGENT SPACE USING FUZZY COGNITIVE MAPS

Considering all of the relevant features and deficiencies of existing FCM tools[37], we proposed a list of basic requirements for a new FCM library applicable to modeling and control of complex systems. According to the list, the library needs to provide the following properties and features[37]:

- Map design, including commands for definition of concepts and commands for mutual connections of concepts.
- Setup membership functions, i.e. define fuzzification and defuzzification of concept values (transformation from real-world values to fuzzy values and vice-versa).
- Definition of casual relations between concepts, including nonlinear and dynamic relations.
- Concept initialization via commands capable to manually setup concept activation values (in case of use of input nodes with controllers and sensors[38]).
- Update of FCM during a runtime. The updated activation values of map concepts need to be computed in a reasonable time. Therefore, it is beneficial to support parallelized and scalable algorithms.
- Automated FCM adjustment of relations using basic learning methods. Other specialized methods should be easily implemented via appropriate interface.
- Model import/export (i.e. file input/output), preferably in standardized format compatible with other FCM libraries and applications.

In addition to these basic features, the library should be easily deployed on various platforms and operating systems. It should use as few third-party dependencies as possible and be independent from expensive or proprietary runtime frameworks. Preferably, the library should use an open source licensing in distribution to enable simple updates depending on additional requirements of a specific application or a user[1][37].

The final library proposal (see Fig. 12) is based on definition of an FCM object, which is accessible via high-level commands. In addition, we introduced a direct access to the Concept object, which makes it possible to use auxiliary low-level commands. For example, the setup of membership functions for individual concepts is possible through a group of a low-level commands available directly via the Concept object. Similarly, the setup of relations is enabled through the Concept object as well. With the final proposal, these basic operations are available via the main FCMobject[1]:

- addition, removal, renaming and initialization of concepts within the map,
- configuration of default relations and membership functions for new concepts,
- connecting and disconnecting concepts,
- import and export of FCM model,
- calculation of FCM updates during runtime.

Additionally, these low-level commands are available via the Concept object[1]:

- setup and evaluation of input MF,
- setup and evaluation of output MF,
- setup and interaction with concept relations including:
 - attaching and detaching concepts from a relation,
 - forward propagation of activations of preceding concepts through the relation,
 - backpropagation of error to preceding concepts,
 - adaptation of relation according to the error.

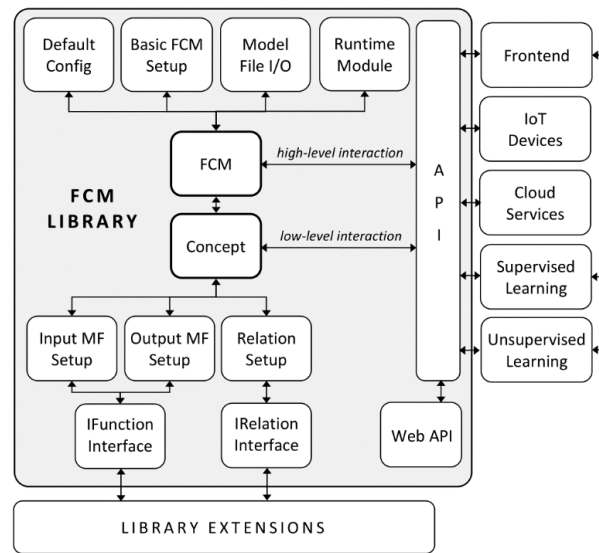


Fig. 12. System diagram of the final proposal for FCM library[1].

The proposal assumes support for supervised learning via least-mean-square methods and error backpropagation directly integrated into the implementation of each individual type of relation. Each concept can have expected values set-up which can be thereafter compared with calculated values and finally, the error can be backpropagated, if the implementation of selected relation supports it. The implemented backpropagation functionality can be called via respective low-level interaction commands. Additional types of relations can be added to the library using predefined interface IRelation, which expects implementation of the specific methods including[1]:

- get() – returns adaptable parameters of the relation (R),
- set(params) – sets parameters of R to specified values,
- attach(concept) – adds a new preceding concept to R,
- detach(concept) – disconnects the concept from R,
- propagate() – calculates a new value for the concept,
- backprop(error) – backpropagates the error through R,
- adapt(error, learning rate) – adapts R according to error.

A similar interface IFunction is also specified for additionally defined membership functions. It requires the implementation of these methods[1]:

- `get()` – returns adaptable parameters of the function (F),
- `set(params)` – sets parameters of F to specified values,
- `getDerivative()` – returns derivative of F (if possible),
- `evaluate(input)` – calculates the output of the function.

Additional learning methods are not directly included within the library, but are easily available via external scripts which can adjust any of the FCM parameters using all of the available commands. Examples of such scripts are available in [39].

The final implementation of the FCM library, titled as a *Python Open Fuzzy Cognitive Maps Library* (PyOpenFCM), is based on the proposal and provided as a standalone Python module consisting of the following main classes [1][40]:

- *FCM* – main class with methods to configure concepts and to calculate FCM updates.
- *Concept* – represents a single FCM concept.
- *Config* – default configuration for functions & relations.
- *IFunction* – interface for membership SISO (single input, single output) function $out=f(in)$.
 - *PiecewiseLinear* – simple piecewise linear function.
 - *Polynome* – simple polynomial function.
 - *Sigmoid* – simple sigmoid function.
 - *Predefined* – function predefined by equation string.
- *IRelation* – interface for MISO relation (multiple input, single output) between concepts.
 - *RSimpleSigmoid* – standard linear connection with sigmoid thresholding function.
 - *R3Term* – three-term weighted connection with sigmoid thresholding function.
 - *RNeural* – multilayer perceptron neural network.

The UML class diagram of the library is shown on Fig. 13.

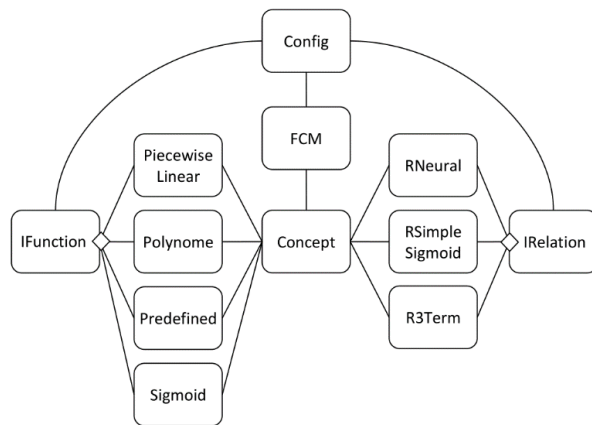


Fig. 13. Class diagram of the final PyOpenFCMimplementation [40].

In addition to being implemented as a Python module, the library also provides a web application programming interface (Web API) available through a complementary service application. The application is created as a Web Server Gateway Interface (WSGI) using a Flask Python Microframework [41]. It can be used to create an FCM server performing remote computations for network devices including robots, sensors and actuators. The Web API enables use of all of the library commands within HTTP requests. In addition to these basic commands, there are additional functionalities (see Fig. 14) [1]:

- creation and storage of maps on the server,
- listing of created maps,
- deletion of created maps,
- export and serialization of maps as JSON strings,
- import of maps from JSON strings.
- command line interface (CLI),
- graphical user interface (GUI).

VIII. FUZZY COGNITIVE MAPS FOR CONTROL OF INTELLIGENT SPACE

All of the ideas presented in previous sections lead to a synthesis that is an overall proposal for situational control of intelligent space and an implementation of a specific control strategy applicable for a situational class of robot navigation. The object of interest is the Intelligent Space (IS) [30] described in section VI. As it was previously noted, the space includes several types of sensors including cameras and microphones, ambient sensors for various physical values, and finally, several types of mobile robots. The goal objectives and requirements for control of IS can be characterized in several levels. First of all, the control should satisfy the needs of its inhabitants being either humans or robots, while humans should always have a priority in case of any conflict. Secondly, the proposal should comply with current legislation and internal organizational rules, if used to automatically generate necessary documentation (including attendance books, visitor lists, cleanup records, etc.). Finally, the system should minimize energy and resource consumptions by employing optimized control strategies and algorithms [1].

There is a large number of conditions or situations which can determine the current state of the intelligent space. According to the methodology of situational control, these situations need to be categorized into classes, where each class consists of several related and similar situations. The proposal for this situational decomposition is shown in Fig. 15[1].

In order to control the IS, we propose to utilize the general model of the situational control by formatter (see Fig. 16), which is suitable to be applied with a range of distributed IoT sensors, that can be linked to associated analyzers providing information for the central database. For further control, we propose a modern event-driven approach[42] which is currently a default paradigm in software engineering. Event logs stored in the database are evaluated by appropriate event handlers with regard to a specific situational class. Further actions are then initiated by an action dispatcher and executed using a range of distributed software controllers (implemented as network services either within fog or edge computing layers) which control devices within the IS, including actuators and robots[1].

With regard to the implementation of the proposal, we have realized only a set of particular control functions needed for navigation of a mobile robot. This control strategy is required in several situational frames including robot performed cleanups, patrols and user requested assistance. In order to control a robot on pre-planned, waypoint-based trajectory, two separate control elements are necessary. A navigator component is used for a proper selection of a current waypoint, switching between waypoints based on their distance and a calculation of an angular deviation from the optimal trajectory. A controller component is used to directly actuate various motors and other actuators of the robot in order to keep it on a track towards its destination. The control actions are based on the information from the navigator component

(i.e. an angular deviation and a distance from the next waypoint, acceleration, speed, etc.) [1].

In our implementation [1], the controller utilizes three-term relations (see Fig. 17) in order to reduce a number of necessary concepts to a minimum. Optimal values of relational weights are found by a *semi-interactive evolution* applied within a simulated model of IS. Localization of the robot is expected to be determined externally, using camera detection. The location analyzer converts a set of 2D coordinates of a robot, detected within an image, into a respective set of 2D coordinates related to the plan of the intelligent space. The conversion is performed by an FCM with *pre-trained neural relations* (see Fig. 18)[1].

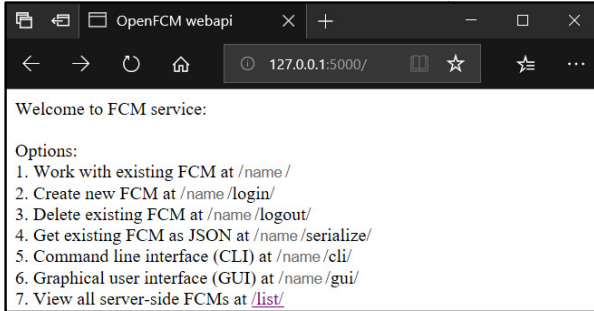


Fig. 14. Online FCM service provided by the library[1].

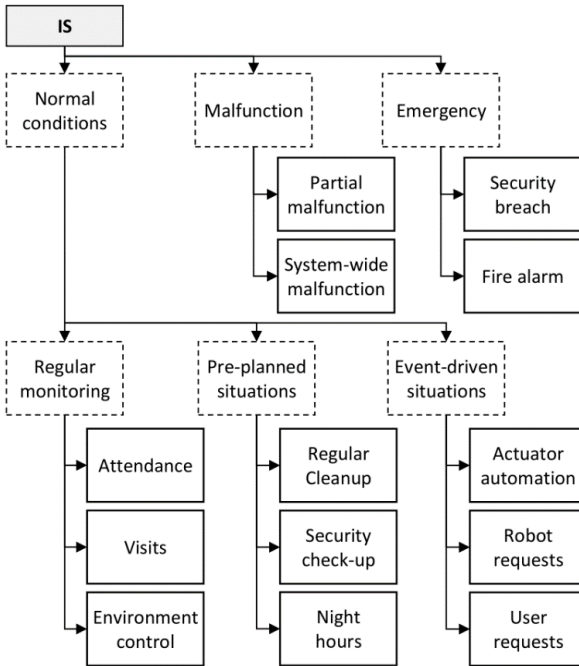


Fig. 15. Proposal for situational decomposition of IS[1].

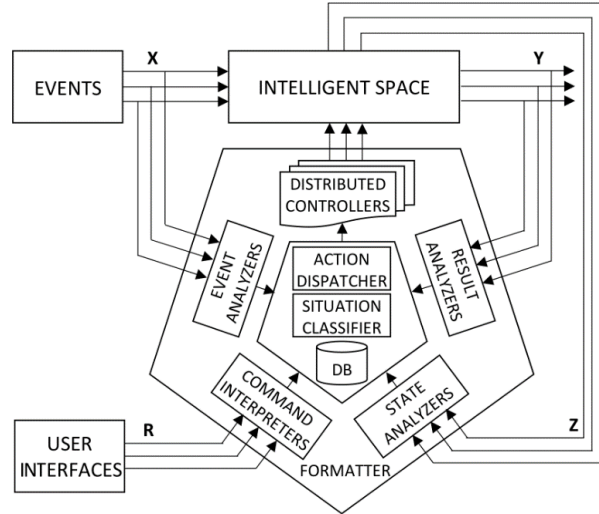


Fig. 16. Proposed model for control of IS[1].




Fig. 17. Three-term FCM controller of a wheeled mobile robot[1].




Fig. 18. Location analyzer based on FCM with neural relations[1].

The implementation [1] of a control strategy for the purpose of robot navigation (see Fig. 19) requires several devices and software programs in cooperation. The devices include a mobile robot which operates within the IS and one or more cameras that overview the entire operational area of the robot. Required software programs include detection analyzers that acquire robot coordinates within camera images, location analyzers that provide a robot localization within the IS, a navigator service that guides a robot on a pre-defined path and a controller service that generates control signals for robot motors. In addition, there are several superior services on a higher level of control hierarchy, including path planner, action dispatcher and other formatter modules (according to Fig. 16). The initiation and execution of the control strategy proceeds as follows[1]:

- 1) A specific situation (i.e. user request) evokes the action dispatcher that initiate the control strategy.
- 2) After a consideration of an initial position of the robot and its destination, a path planner module generates a waypoint-based route, which is sent to the navigator.

- 3) A navigator component subscribes to necessary services, including controller and localization FCM services.
- 4) A communication between individual devices and services is realized directly using a subscription-based paradigm (via direct HTTP requests). Since all of the required modules establish a direct mutual communication, extensive database lookups are avoided, which mitigates a risk of possible communication bottleneck through a database.
- 5) The control strategy proceeds until the robot reaches its destination.
- 6) Finally, a navigator component generates a termination event, unsubscribe from the linked services and conclude the control strategy. The IS continues to operate in normal working conditions.

In order to examine the proposed control strategy and evaluate a feasibility of application of all of the implemented FCM-based services, we have created a simplified model [39] of IS. It employs eight standalone cameras situated in various spots within the IS to provide localization of the robot. Each camera is provided with its respective location analyzer service based on FCM model. The robot control is performed by two main components: a waypoint-based navigator and an FCM-based controller. A visualization of the simulation is shown on Fig. 67. A complete [video recording](#) is available at [43].

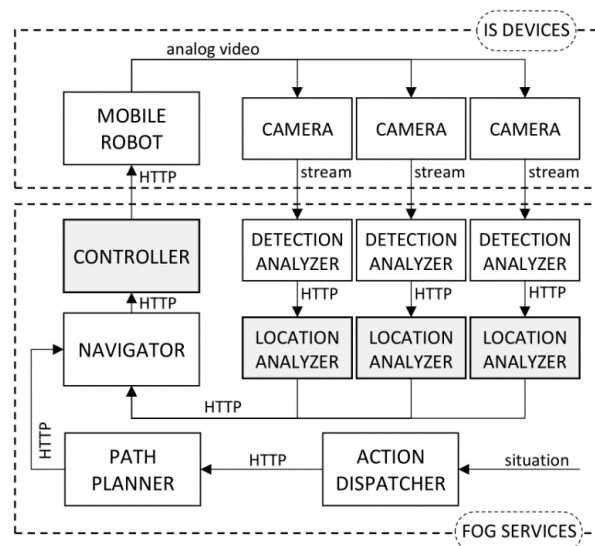


Fig. 19. A navigation system for IS with FCM services in gray[1].

Our experiments with a simulation have concluded with several findings. While it has proven the overall applicability of the proposed control strategy for robot navigation, it is important to admit, that an overall accuracy of robot movement could be improved. However, this was in line with our expectations, since the simulation was very demanding on computing resources. We have executed a whole simulation on a single computer processing several scripts running in parallel. One of those was the simulated environment, second was the FCM controller and additionally, there were eight simulated cameras with complementary location analyzers. This resulted in an average simulation step of 1 second. This time can be theoretically improved to the order of milliseconds, hence improving the overall precision of the controller. Since all of the employed FCM based components are implemented as network services using the Web API of the

PyOpenFCM library, every model can be potentially implemented on a separate server, within either edge, fog or cloud computing layer. This can effectively increase the overall performance of the solution[1].




Fig. 20. A simulated model of IS. Cameras are shown in red, their respective vision fields are shown in light green. A robot is displayed as a blue triangle. Its path is defined by waypoints marked as dark green dots [39].

IX. CONCLUSION

The main contributions or our work[1] can be listed as follows: The successful simulation of intelligent space has confirmed the applicability of FCMs to model and control complex systems. We have accomplished a significant simplification of FCM design with help of a novel FCM library supporting designs with a use of complex three-term and neural relations between individual concepts. In addition, we have demonstrated feasibility of automatic adaptation of FCMs using either LMS error backpropagation or evolutionary optimization. And finally, we have proven applicability of FCMs as remote controllers available via network either in fog or cloud computing layer[1].

The future work will consist of exploring the options to further improve FCM adaptation focused on optimization of speed of training and improving accuracy of created models. It is also worth to focus on improving the efficiency of network controllers, by optimizing the hierarchical structure of network devices and services participating on formatter control, thus reducing latency and amount of data transferred across the network. Naturally, the ultimate goal should be to implement all of the proposed algorithms in real conditions, and possibly commercializing the ideas[1].

REFERENCES

- [1] Puheim, M. 2018. "Fuzzy Cognitive Maps for Control of Intelligent Space." Dissertation. Košice, FEI, DCAI, TUKE.
- [2] Madarász, L. et al. 2012. "Systémová analýza a syntéza," Elfa, s.r.o., pp. 303, ISBN 978-80-8086-193-3.
- [3] Sarnovský J., Madarász, L., Bízík, J., Csontó, J. 1992. "Riadenie zložitých systémov," pp. 384, Alfa, Bratislava. ISBN 80-05-00945-3.
- [4] Madarász, L., Vaščák, J., Andoga, R., Karof, T. 2010. "Rozhodovanie, zložitost' a neurčitost'," pp. 396, Elfa s.r.o. Košice. ISBN 978-80-8086-142-1.
- [5] Madarász, L. 2005. "Inteligentné technológie a ich aplikácie v zložitých systémoch," pp. 346, Elfa, s.r.o., Košice, FEI TU. ISBN 80-89066-75-5
- [6] Andoga R. 2006. "Hybridné metódy situačného riadenia zložitých systémov," Dissertation, pp. 120, KKUI FEI TU v Košiciach.

- [7] Madarász, L. 1996. "Metodika situačného riadenia a jej aplikácie," pp. 212, Elfa Košice. ISBN 80-88786-66-5
- [8] Madarász, L. 1982. "Základné princípy situačného riadenia a formalizácie rozhodovacích procesov pri riadení zložitých hierarchických systémov." Dissertation, pp. 95, EF VŠT Košice.
- [9] Sinčák, P., Kostelník, P., Novotný, P. 2001. "Strojová inteligencia, inteligentné technológie – súčasnosť a budúcnosť." Riadenie a informatika, FEI TU Košice. ÚTRaR SAV Bratislava, pp. 1-5.
- [10] Olej, V. 2004. "Modelovanie ekonomických procesov na báze výpočtovej inteligencie." M&V, Milady Horákovéj 262, Hradec Králové, pp. 160, ISBN 80-903024-9-1.
- [11] Sinčák, P., Andrejková, G. 1996. "Neurónové siete – Inžiniersky prístup. Dopredné neurónové siete." I. diel. Elfa, s.r.o., Košice, pp. 110, ISBN 80-88786-38-X.
- [12] Mach, M. 2009. "Evolučné algoritmy: Prvky a princípy." 1. vydanie, elfa s.r.o., Košice, pp. 250, ISBN 978-80-8086-123-0
- [13] Vaščák, J. 2008. "Fuzzy logika v regulácii. Podrobný úvod do problematiky fuzzy riadenia," TUKE, FEI, KKUL.
- [14] Takagi, T., Sugeno, M. 1985. "Fuzzy identification of systems and its applications to modeling and control," IEEE Transactions on Systems Man and Cybernetics, Vol. SMC-15, pp. 116-132.
- [15] Papageorgiou, E. I., Salmeron, J. L. 2013. "A Review of Fuzzy Cognitive Maps research during the last decade," IEEE Transactions on Fuzzy Systems, vol. 21, no. 1, pp. 66-79.
- [16] Chen S. M., "Cognitive-Map-based Decision Analysis Based on NPN Logics", Fuzzy Sets and Systems, Elsevier, Vol. 71, No. 2, pp. 155-163, 1995
- [17] Gregor, Michal., Groumpos, P. P. 2013. "Training Fuzzy Cognitive Maps Using Gradient-Based Supervised Learning", IFIP Advances in Information and Communication Technology, Volume 412, pp. 547-556.
- [18] Vaščák, J. 2013. "Príklady aplikácií fuzzy kognitívnych máp v robotike," Sborník príspevků z letní školy Mezioborové přístupy informatiky a kognitivní vědy. Hradec Králové. Gaudeamus. pp. 74-92. ISBN 978-80-7435-311-6
- [19] Puheim, M., Vaščák J., Madarász L. 2014. "Three-Term Relation Neuro-Fuzzy Cognitive Maps." In: CINTI 2014 : 15 th IEEE International Symposium on Computational Intelligence and Informatics : Proceedings : November 19-21, 2014, Budapest. - Danvers : IEEE, 2014 P. 477-482. - ISBN 978-1-4799-5337-0
- [20] Papageorgiou, E.I. 2012. "Learning Algorithms for Fuzzy Cognitive Maps – A Review Study," IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews, vol.42, no.2, pp. 150-163.
- [21] Mls, K., Cimler, R., Vaščák, J., Puheim, M. 2017. "Interactive evolutionary optimization of fuzzy cognitive maps." In: Neurocomputing. Vol. 232, p. 58-68. ISSN 0925-2312
- [22] Puheim, M. 2015. "pyRoSim - Python Robotic Simulator." GitHub source code repository. [Online]. Available: <https://github.com/mpuheim/pyRoSim> [Accessed: 7-August-2018].
- [23] Puheim, M., Vaščák, J. 2017. "Semi-Interactive Population-Based Optimization of Fuzzy Cognitive Maps". Unpublished manuscript.
- [24] Zhang, D., Ning, H., Xu, K. S., Lin, F., Yang, L. T. 2012. "Internet of Things." J. UCS 18 : 1069-1071. doi: 10.1007/978-3-642-32427-7
- [25] ISO/IEC 7498-1:1994. "Open Systems Interconnection -- Basic Reference Model: The Basic Model."
- [26] Mell, P. and Grance, T., 2010. "The NIST definition of cloud computing." Communications of the ACM, vol. 53, iss. 6, p. 50
- [27] Singh, N. K. 2015. "Seminar Report on Fog Computing," CochIn University of Science and Technology, August 2015.
- [28] Augusto, J. C., Callaghan, V., Cook, D., Kameas, A., Satoh, I. 2013. "Intelligent Environments: a manifesto." In: Human-centric Comp. and Information Sciences, 2013, doi:10.1186/2192-1962-3-12
- [29] Hvizdoš, J., Vojtko, M., Koscelanský, M., Haluška R., Pavlov J. 2017. "Applications of Remote Controlled Robotics in the Intelligent Space." In: SAMI 2017. - Danvers : IEEE, 2017 S. 117-121. - ISBN 978-1-5090-5654-5
- [30] Čurová, D., Haluška, R., Hucec, T., Puheim M., Vaščák J., Sinčák, P. 2017. "Intelligent space at center for intelligent technologies – system proposal." In: SAMI 2017. - Danvers : IEEE, 2017 S. 191-195. - ISBN 978-1-5090-5654-5
- [31] Center for Intelligent Technologies. 2016. "Ai-cit.sk" [Online]. Available: <http://www.ai-cit.sk/>. [Accessed: 30-July-2018].
- [32] Hvizdoš, J. 2018. "Ubiquitous Robotics in Intelligent Space: New Approaches in Navigation of Ubiquitous Robots." PhD Thesis. Košice, FEEL, DCAI, TUKE.
- [33] Koscelanský, M. 2017. "Robot Localization in Intelligent Space." Master thesis. Košice, FEEL, DCAI, TUKE.
- [34] Vojtko, I. 2017. "Sensory Systems Based on RFID Technology in the Intelligent Space." Bachelor thesis. Košice, FEEL, DCAI, TUKE.
- [35] Vaščák, J. 2017. "Internet of Things, Robotics and Computational Intelligence: Towards the Synergy of Autonomous Systems." Habilitation thesis. Košice, FEEL, DCAI, TUKE.
- [36] Kim, T. H., Choi, S. H. and Kim, J. H., 2007. "Incorporation of a software robot and a mobile robot using a middle layer." Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on, vol. 37, no. 6, pp. 1342-1348.
- [37] Puheim, M., Vaščák, J., Madarász, L. 2015. "A Proposal for Multi-Purpose Fuzzy Cognitive Maps Library for Complex System Modeling." In IEEE 13th International Symposium on Applied Machine Intelligence and Informatics. January 22–24, 2015. pp. 175-180. ISBN: 978-1-4799-8220-2
- [38] Vaščák, J., Madarász L. 2010. "Adaptation of Fuzzy Cognitive Maps – a Comparison Study," Acta Polytechnica Hungarica, Vol. 7, No. 3, pp. 109-122.
- [39] Puheim, M. 2018. "PyIoTsim – Python IoT Simulator." GitHub source code repository. [Online]. Available: <https://github.com/mpuheim/PyIoTsim> [Accessed: 4-August-2018].
- [40] Puheim, M. 2018. "Python Open Fuzzy Cognitive Maps Library – Documentation." [Online]. Available: <https://mpuheim.github.io/PyOpenFCM/docs/html/index.html> [Accessed: 12-August-2018]
- [41] Ronacher, A. 2018. "Flask." [Online]. Available: <http://flask.pocoo.org/> [Accessed: 14-August-2018]
- [42] Parsons D. 2012. "Event-Driven Programming." In: Foundational Java. Springer, London. ISBN 978-1-4471-2478-8
- [43] Puheim, M. 2018. "Situational Control Strategy for Robot Navigation." Youtube video. [Online]. Available: <https://youtu.be/Y1oM9p-VfjE> [Accessed: 2-November-2018]

Analysis and Forecasting of Electricity Prices on the Polish Power Exchange

Michal Kolcun

Department of Electrical Power Engineering
Technical University of Košice
Košice, Slovak Republic
michal.kolcun@tuke.sk

Karolina Rusek

Department of Electrical Power Engineering
Technical University of Košice
Košice, Slovak Republic
karolina.rusek@tuke.sk

Abstrakt - článok prezentuje problém modelovania pre účely prognózovania. Modelovanie procesov zahŕňa mnoho dôležitých štádií, ako je určenie potenciálneho súboru premenných, výber optimálneho súboru podľa prijatého kritéria, výber matematickej formy modelu a vyhodnotenie výsledkov získaných z modelu. Správne riešenie každého z týchto stupňov umožňuje predpokladať, že prognózy s použitím tohto modelu splnia prijaté predpoklady a splnia očakávania, najmä pokiaľ ide o presnosť a stabilitu modelu.

Kľúčové slová: elektrizačná sústava, energetický trh, energetická burza, model, výber premenných cien energií, prognózovanie

Abstract - the article in the essential part, it presents the problem of modeling for forecasting purposes. Modeling of processes encompasses many important stages such as determining the potential set of variables, selecting the optimal set according to the adopted criterion, selecting the mathematical form of the model, and assessment of results obtained from the model. Proper resolution of each of these stages allows one to presume that forecasts made using this model will fulfill the adopted assumptions and meet expectations, mainly concerning the model's accuracy and stability.

Key words: electric power system, energy market, energy exchange, model, selection of energy price variables, forecasting

PPE-Polish Power Exchange (Towarowa Gielda Energii - TGE)
NPS- National Power System
EU- European Union

I. INTRODUCTION

The creation of the energy market and its liberalization are a consequence of the introduction of Directive 96/92/EC and the act of 1997 - Energy law [1]. These steps contributed to the creation of electricity exchanges, as well as to the search for effective methods of analyzing, modeling and forecasting the variability of both volume and prices [2], [3], [4]. The goal of making forecasts is mainly determined by who the forecast is intended for and what its horizon is. Long-term forecasts

indicate the behavior of a certain process in future years and are used to e.g. develop investment plans or plan actions in the fields of social and economic policy. Short-term forecasts are mainly used in operational activities, for example power load forecasts in the National Power System and forecasts of electricity prices on exchanges. Price forecasts of energy carriers may concern different areas in the geographic sense. Full integration of the European Market along with electricity trading under Market Coupling will make forecasts on this market very significant for all EU member states. Climate change forecasts concern the entire global economy. The electricity-related energy market has specific features that clearly distinguish it from other markets. Here, one can mention the lack of a possibility to store energy, limited capacity for substitution, and the natural monopoly of the system's operators. The seasonality of energy consumption is distinct, and is accompanied by large price fluctuations on the exchange [5], [6].

Investigations of the influence of selected factors related to the construction of prognostic models are the subject of this doctoral dissertation. These factors are decomposition of time series, choosing the appropriate procedure for the selection of variables, and selection of the class of the model itself. The cognitive goal is to investigate the significance of these factors with respect to the model's correctness, understood according to the category of obtained accuracies of forecasted processes. In many studies concerning the construction of prognostic models, attention is generally paid to selection of model's class without deeper analysis of the process itself. The applicative goal is to create forecasts of energy prices using real data from exchanges. In the theoretical part, studies involve analysis of time series of electricity prices on the Polish Power Exchange (PPEE), and in the practical part, the results of these studies are used to create real-life forecasts of these prices.

Research concerning forecasting of the variability of energy prices on the Day-Ahead Market was undertaken as part of this doctoral thesis. The National Power System (NPS) is characterized through presentation of the structure of energy production and consumption, the structure of energy generation, and cross-border energy exchange. The characteristics of PPE (Polish Power Exchange) are discussed and existing markets are characterized. Selection of a specific model is conditioned by the nature of the variability in the studied process, the number of observations and availability of the required data. Price fluctuations on PPE are processes of

high variability and are often non-stationary over longer time-periods, whereas some models require stationarity of the modeled process. The legitimacy of selecting the topic of modeling energy prices on PPE arises from expectations of accurate and reliable forecasting of all branches and sectors of the national economy. Research was focused on modeling the process within a short-term horizon.

II. NATIONAL POWER SYSTEM IN POLAND

This section contains a synthetic picture of the most important information about the National Power System (NPS). The structure of the most important structures making up the NPS are presented. To illustrate the NPS, power values over the course of several years, volumes of production, consumption, import and export of electricity are given, along with the dynamic of changes. Poland's full-fledged involvement in the European Multi Regional Coupling (MRC) market implies electricity exchange with many countries, but with limitations arising from the throughput of connections between the Polish power system and power systems of other EU member states [7]. The last part of this section contains information about the activities and involvement of the Polish operator, which is PSE, with regard to cross-border connections enabling the creation of a unified electricity market and participation in it. A brief characterization of the institutions taking part in creating the MRC, mainly ENTSO-E.

The concept of the National Power System (NPS) means the cooperation of units generating electricity, units responsible for transmission and distribution, and the systems controlling its operation. The electricity market is playing an increasingly significant role in the functioning of the NPS [8]. The energy market has brought about the possibility of competition between electricity generators, which they are engaging in. Enterprises concerned with the transmission and delivery of energy to end-users operate under conditions of a natural monopoly. An important, dynamically growing segment of the Energy Market is the Polish Power Exchange - PPE.

The NPS currently consists of four basic sectors. A simplified organizational diagram of the energy sector is given in Figure 1.




Figure 1. Basic Sectors in the NPS

source: Original work

Operational management of NPS technical resources is performed by dispatching services, in the following hierarchical structure:

- National Power Dispatching Center (NPDC),
- Areal Power Dispatching Center (APDC)
- Plant Dispatching Centers (PDC),
- Regional Dispatching Centers (RDC).

The NPDC and five APDCs are the dispatching services of the Transmission System Operator (TSO) while PDCs and RDCs are the services of individual Distribution System Operators (DSO). Their responsibilities and scopes of duties, relationships with regard to cooperation, are regulated by the Energy law act [9] and detailed regulations.

Power values in division into four categories in the NPS, over the course of 4 years chosen as an example, are given in Table 1 and illustrated in a chart - Figure 2.

Table 1. Structure of power in the NPS [MW]

Powers [MW]	Year			
	12/31/2013	12/31/2014	12/31/2015	12/31/2016
Installed power	38671	39343	40362	41396
Mean annual power generating capacity from	37743	38199	38892	40491
Mean available power	26627	26363	26763	28140
Mean annual power demand	22155	22301	22529	22832

source: Original work based on data from ARE S.A.




Figure 2. Structure of power in the NPS

source: original work

Chart Figure 2 shows that the installed power in the National Power System in successive years fluctuates within narrow limits due to shortages usually arising from shutdowns of overexploited generating units and their replacement with new investments commissioned for exploitation [8]. The case is similar with regard to powers in other categories.

In 2016, throughout the entire country, energy production amounted to 162,626 GWh, and a total of 166,100 GWh were consumed, 14,012 GWh were imported, and 12,911

GWh were exported. Starting from 2013, both national electricity production and consumption are at very similar levels, as shown by the chart in Figure 3. During the period of the last 17 years, electricity consumption has grown by 20%, and production has increased by nearly 13% over the course of this same period. This imbalance has been offset by reducing losses at various stages, replacing old equipment with new, much more energy-efficient equipment, and through import [8].




Figure 3. Gross national electricity production and consumption [GWh]
source: Original work based on data from PSE [14]

Numerical data concerning gross electricity production, consumption and the dynamic of changes (calculated on a year-to-year basis) in both production and consumption is given in Table 2 and in chart.

Table 2. National energy consumption and energy production during the years 2010-2016

Year	Gross national energy production [GWh]	National energy consumption [GWh]	Dynamic of production	Dynamic of consumption
2000	144,417	138,043		
2001	144,574	137,843	100.1%	99.9%
2002	143,233	136,165	99.1%	98.8%
2003	150,751	140,590	105.2%	103.2%
2004	153,362	144,069	101.7%	102.5%
2005	156,024	144,838	101.7%	100.5%
2006	160,848	149,847	103.1%	103.5%
2007	159,528	154,170	99.2%	102.9%
2008	155,567	154,980	97.5%	100.5%
2009	150,923	148,718	97.0%	96.0%
2010	156,342	154,987	103.6%	104.2%
2011	163,153	157,909	104.4%	101.9%
2012	159,853	157,013	98.0%	99.4%
2013	164,580	160,059	103.0%	101.9%
2014	159,058	161,224	96.6%	100.7%
2015	164,944	164,610	103.7%	102.1%
2016	162,626	166,100	98.6%	100.9%
Mean dynamic			100.8%	101.2%

source: Original work based on source: PSE [14]

Table 3. Import and export of electricity during the years 2013-2016

Energy [GWh]	Year			
	2013	2014	2015	2016
Energy import	7801	13508	14459	14012
Energy export	12322	11342	14793	12911

source: Original work based on Source: PSE [14]

Table 3 and chart Figure 4 present the level of electricity export and import for the last 4 years.




Figure 4. Import and export of electricity

source: Original work based on data from PSE [14]

As can be seen, a large jump took place in 2013 with regard to import. In the other 3 years, import fluctuates around a similar level. Greater fluctuations are present in electricity export [8].

The National Power System is connected with many power systems of neighboring countries. Connection of Poland's and Sweden's systems with a direct current cable has afforded Poland fully-fledged participation in the European Multi Regional Coupling market. The new connection with Lithuania also has an influence on increasing exchange. Currently, Poland has power connections with the Czech Republic, Slovakia, Lithuania, the Ukraine, Sweden, and Germany [4]. Coupling of electricity markets is a complicated process that is evolving for the ultimate purpose of bringing about a unified, integrated European Market Coupling [10], [11]. The total throughput of connections between the Polish power system and systems of EU member states amounts to 2000-3000 MW (depending on the configuration of the system's operation) and is limited by the transmission capacities within the national system. The current status of cross-border connections is shown in Figure 5.

Chart Figure 6 shows how electricity exports and imports have changed, along with the trend line. Up to 2013, the growth rate of import is clearly higher. Starting from 2014, equalization of energy export and import is observed.

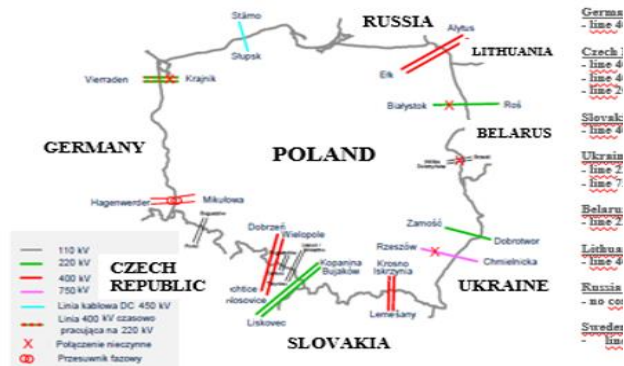


Figure 5. Status of cross-border connections, status in 2017

source: [15]

Currently, Poland has energy connections with the Czech Republic, Slovakia, Lithuania, the Ukraine, Sweden and Germany. Coupling of electricity markets is a complicated process that is evolving for the purpose of ultimately bringing about a unified, integrated European market.




Figure 6. Cross-border electricity exchange

source: original work based on data from PSE [14]

Delays in market coupling limit the full capabilities of commercial exchange. Table 4 contains a list of cross-border connections of the national system.

Table 4. Cross-border connections of the Polish power system


Connection	Voltage level [kV]	Maximum tolerable power [MW]	Maximum tolerable current loading capacity [A]
Krainik - Vierraden	400	296	778
Mikulowa - Hagenwerder	400	1385	2000
Wielopole - Albrechtice	400	1385	2000
Wielopole - Nojovice	400	1385	2000
Bujaków - Liskovec	220	400	1050
Kopanina - Liskovec	220	400	1050
Slupsk - Stámo	450 (direct current)		
Białystok - Roś	220	231	608
Wólka Dobrzynska - Brześć	110	120	-
Dobrotwór - Zamość	220	251	660
Rzeszów - Chmielnicka	750	1300	1500
Krosno Iskrzynia - Lemieřany	400	831	1200
Ek - Alytus	400	500	-

source: Original work based on PSE [14]

The current throughput of cross-border connections meets the goal set by the Council of Europe, which defines a minimum 10% transmission capacity of cross-border connections with respect to installed power in the national power system [12]. It is predicted that the development of cross-border connections will enable exchange of 20% of domestically consumed energy by 2020 and 25% by 2030.

III. ENTITY STRUCTURE OF THE WHOLESALE ENERGY MARKET

Polska Grupa Energetyczna S.A. (PGE) noted the greatest market share, of nearly 36%, in the subsector of electricity generation in 2016. On the market of sales to end-users, the leader is TAURON Polska Energia S.A., with a share of 10.2%. The market share of the three largest entities in terms of energy introduced into the network, including energy supplied by generating entities directly to end-users, was nearly 55% in 2016. It shrank by 2.5% compared to the year 2015. The three largest generating entities, operating in the capital groups: PGE Polska Grupa Energetyczna S.A., TAURON Polska Energia S.A. and ENEA S.A. collectively hold slightly over half of the installed power in the national power system, and their total production of electricity nationwide was up to 60%. The share of capital groups in electricity introduced into the network is shown in 7 [12].



Source: Data of the Ministry of Energy and ERO

Note! In 2016, the German energy concern RWE Polska S.A. changed its name to Innogy Polska S.A.

Figure 7. Share of capital groups in the volume of electricity introduced into the network. (Status as of 31 December 2016)

source: [13]

The exchange makes public information concerning DAM listings according to date of supply, including prices, trading volume and index values. The IRDN, sIRDN, offIRDN, IRDN24, IRDN8.22, IRDN23.7 and PPe24 indexes are determined for hourly instruments (without block instruments)[11], [12].

The PPe24 index is the base instrument for electricity derivatives, i.e. futures contracts. The PPeBase index is determine on the basis of both hourly and block instruments. These two indexes are defined as follows:

PPe24 index determined as the arithmetic mean of prices determined on the DAM for the given date of supply during the first Fixing, i.e.:

$$TGe24 = \sum_{i=1}^j \frac{M_i}{j} \tag{1}$$

Where:

j – number of hours on the day of supply,

M_i – fixing price for the j -th hour

PPeBase index determined as the arithmetic mean of hourly prices determined on the DAM for the given day of supply. This index is a comprehensive source of information about prices on the DAM, accounting for all types of instruments and listing systems on this market. The PPe24 and PPeBase indexes are determined as follows:

$$TGeBase = \sum_{i=1}^j \frac{M_i}{j} \tag{2}$$

Where:

j – number of hours on the day of supply (23 to 25),,

M_i – weighted average for the j -th hour, expressed by the formula:

$$M_j = \sum_{i=1}^n P_i \left(\frac{V_i}{V_j} \right) \tag{3}$$

n – number of transactions in given hour,

P_i – price determined for i -th transaction,

V_i – trading volume in the i -th transaction, for the given hour of electricity supply,

V_j – trading volume for given hour of electricity supply.

Over the last several years, the trading volume of electricity on all markets of the PPE increased over two-fold, from slightly over 81 TWh in 2010 to nearly 187 TWh in 2014. In 2010, electricity generation was at a level of approx. 160 TWh, meaning that approx. 50% of the volume of national production was traded on the PPE. Six years later, this trading volume fluctuated around nearly 120% of the volume of national production [8]. This signifies dynamic growth of the Polish market’s liquidity, making it one of the most liquid in the region of Central and Eastern Europe [12]. Figure 8 shows changes in electricity trading volume from 2010 on the PPE.




Figure 8. Electricity trading volume on the PPE.

source: [11]

Chart Figure 8 shows that the increase in electricity trading volume concerned the futures market, the Intraday Market and the Day-Ahead Market alike. The rate of trading volume growth on PPE’s electricity futures market was similar to the dynamic of changes occurring on the futures market of the largest European electricity exchange, i.e. the German EEX. Figure 9 shows the shares of markets in electricity trading volumes on the PPE in 2015, while Figure 10 shows the structure of electricity trading volume in the years 2015-2016 on the main markets managed by PPE S.A.




Figure 9. Shares of Markets in trading volumes on the PPE in 2015

source: [11]




Figure 10. Structure of electricity trading volume in the years 2015-2016 on markets managed by PPE S.A.

source: [13]

A small but varied price change is observed on the wholesale electricity market. The average price of energy on the DAM in 2015, weighted by volume, amounted to PLN 155.66/MWh and was nearly PLN 30/MWh lower – i.e. 16% lower – compared to 2014, when the price was PLN 184.75/MWh. The situation was reversed in 2016, when a slight increase was noted on the wholesale market in comparison to 2015. The average price on the Day-Ahead Market in 2016 was PLN 159.22, PLN 2.27/MWh higher than in 2015. A similar tendency was noted on the Balancing Market when, in 2016, the price of CRO was PLN 164.19/MWh, which was higher by PLN 6.88/MWh in comparison to the year 2015.

The main factor behind the slight increase in prices on this market in 2016 was the growth of demand for power in the NPS as well as the change in the structure of electricity generation. In 2016, approx. 730 MW of new capacity was created in wind power plants, however the entire RES sector did not bring about the expected growth of production in this subsector. Production from inexpensive power plants fired by brown coal decreased substantially, by over 4%, in 2016. This drop was compensated by greater production in more expensive power plants fired by gas, the production of which increased

significantly compared to 2015, by 37.8% to the level of 5.8 TWh [11].

The CFM noted a slight drop in prices. The average weighted price in 2015 of the BASE_Y-16 contract was PLN 164.37/MWh and was PLN 4.88/MWh lower than the price in 2014. The case was similar in 2016, when the transactional price of the BASE_Y-17 contract reached the level of PLN 159.26/MWh, meaning that it dropped by over 3% compared to the BASE_Y-16 contract's price. Prices and their changes as a percentage are given in Table 9 for both the DAM and CFM (for the Base_Y-15, Base_Y-16 and Base_Y-17 instruments).

Table 5. Dynamic of price changes on the DAM and CFM

DAM				
2014	2015	2016	2015/2014	2016/2015
184.75 zł	155.66 zł	159.22 zł	84.25%	102.29%
CFM BASE_Y-RR contracts				
169.25 zł	164.37 zł	159.26 zł	97.12%	96.89%

source: original work




Figure 11. Average monthly energy prices in 2016 on the SPOT and BM markets as well as average monthly temperatures.

source: [11]

Figure 11 contains charts of average monthly electricity prices on the SPOT and BM markets, along with average monthly temperatures. They provide a certain perspective on how final average annual prices were shaped.

IV. DYNAMIC MULTIDIMENSIONAL REGRESSION MODEL WITH SELECTION OF PREDICTORS

The results of fitting models for every hour, expressed as the measure of mean absolute percentage error (MAPE) and the

results of validating forecasts are given in Table 6, Table 7. Mean errors from each of the modeled 24 hours are given in the last column of Table 7. To better illustrate the results, charts Figure 12, Figure 13, Figure 14 show characteristic validation forecasts for hours with min, max error and mean error. Calculations were carried out for hourly models, and hourly results made it possible to determine daily forecasts. The chart presented in Figure 43 below illustrates the distribution of hourly errors on the background of mean error for validation forecasts. The chart shows that approx. 50% of hourly errors are smaller than the mean error.

Table 6. Mean hourly errors of fit of models and validation forecasts

h1	h2	h3	h4	h5	h6	h7	h8	h9	h10	h11	h12
MAPE% of model's fit											
3.25	3.11	3.29	3.32	3.60	3.74	4.62	4.77	4.58	4.88	4.51	4.68
MAPE% of validation forecast											
3.15	2.87	3.31	3.27	2.94	3.36	5.51	4.75	4.58	4.80	5.03	4.69

source: original work

Table 7. Mean hourly errors of fit of models and validation forecasts ctd.

h13	h14	h15	h16	h17	h18	h19	h20	h21	h22	h23	h24	MAPE%_sre
MAPE% of model's fit												
4.51	4.63	4.53	4.42	4.33	4.76	4.76	4.64	5.06	4.65	4.29	4.28	4.30
MAPE% of validation forecast												
5.02	4.22	4.35	4.38	4.51	4.05	4.68	4.55	4.61	4.06	3.80	4.62	4.21

source: original work

Cells in tables, with errors: min, mean and max for fitting and for validation forecasts are distinguished by highlighting.




Figure 12. Chart of hourly real and forecasted prices for minimum MAPE%

source: original work




Figure 13. Chart of hourly real and forecasted prices for mean MAPE%,

source: original work




Figure 14. Chart of hourly real and forecasted prices for maximum MAPE%,

source: original work




Figure 15. Distribution of hourly errors on the background of mean error

source: original work

Knowing hourly forecasts, daily forecasts were also determined. Mean daily errors for validation forecasts are given in Table 8.

Table 8. Mean daily errors of validation forecasts.

Date		MAPE%	Date		MAPE%	Date		MAPE%
4/2/2017	Sun	5.38%	4/21/2017	Fri	5.52%	5/10/2017	Wed	2.22%
4/3/2017	Mon	3.86%	4/22/2017	Sat	6.76%	5/11/2017	Thu	5.77%
4/4/2017	Tue	2.87%	4/23/2017	Sun	4.86%	5/12/2017	Fri	3.03%
4/5/2017	Wed	4.03%	4/24/2017	Mon	1.67%	5/13/2017	Sat	4.56%
4/6/2017	Thu	2.79%	4/25/2017	Tue	3.82%	5/14/2017	Sun	2.37%
4/7/2017	Fri	1.86%	4/26/2017	Wed	3.48%	5/15/2017	Mon	2.69%
4/8/2017	Sat	4.66%	4/27/2017	Thu	3.65%	5/16/2017	Tue	5.65%
4/9/2017	Sun	4.95%	4/28/2017	Fri	1.96%	5/17/2017	Wed	3.54%
4/10/2017	Mon	3.62%	4/29/2017	Sat	4.89%	5/18/2017	Thu	4.03%
4/11/2017	Tue	10.27%	4/30/2017	Sun	2.90%	5/19/2017	Fri	3.16%
4/12/2017	Wed	3.27%	5/1/2017	Mon	2.74%	5/20/2017	Sat	4.30%
4/13/2017	Thu	5.89%	5/2/2017	Tue	3.00%	5/21/2017	Sun	9.83%
4/14/2017	Fri	3.84%	5/3/2017	Wed	2.44%	5/22/2017	Mon	3.96%
4/15/2017	Sat	7.74%	5/4/2017	Thu	4.75%	5/23/2017	Tue	4.55%
4/16/2017	Sun	8.06%	5/5/2017	Fri	3.53%	5/24/2017	Wed	3.47%
4/17/2017	Mon	3.63%	5/6/2017	Sat	3.02%	5/25/2017	Thu	4.75%
4/18/2017	Tue	5.98%	5/7/2017	Sun	2.39%	5/26/2017	Fri	2.15%
4/19/2017	Wed	3.41%	5/8/2017	Mon	2.46%	5/27/2017	Sat	4.26%
4/20/2017	Thu	3.80%	5/9/2017	Tue	2.83%	5/28/2017	Sun	4.23%
Mean error 4.12%								

source: original work

Charts Figure 16, Figure 17, Figure 18 show 3 characteristic days on which min, mean and max error occurred, respectively. Chart Figure 19 shows daily errors on the background of mean error from all days. Approx. 60% of daily errors are lower than the mean error determined from all forecasted days.




Figure 16. Chart of daily real and forecasted prices for day with minimum MAPE%.

source: original work




Figure 17. Chart of daily real and forecasted prices for day with mean MAPE%

source: original work




Figure 18. Chart of daily real and forecasted prices for day with maximum MAPE%

source: original work




Figure 19. Distribution of daily errors on the background of mean error.

source: original work

V. SUMMARY AND CONCLUSIONS

Advanced works on synchronization of the electricity networks of Baltic States with the continental European network are bringing the moment at which these systems will be connected closer, albeit with difficulties and delays. Collaboration between operators of multiple national systems will improve the energy security of every participant in the common market. According to assumptions, construction of cross-border connections is to end in 2025. The realization of these assumptions will surely accelerate the process of creating the Market Coupling and thus increase interest in Fixing prices. The growing significance of PPE, the running and expanding common platform for electricity trading in the EU (Market Coupling), naturally raises interest in the exchange on the part of entities on the electricity market in various aspects. One of the more important and obvious aspects is predicting energy prices to the best possible extent, and this is a strong impulse in the direction of creating prognostic models of prices on PPE, particularly of energy prices on Fixing II. Interest in forecasts of prices on PPE is also growing in relation to the project of introducing the obligation of 100% electricity sale on the exchange. There are already energy groups, like PGE or Tauron, who are directing their entire production to PPE, recognizing that this has an influence on liquidity and transparency of the market, to the benefit of both consumers and suppliers.

Conducted analyses of price series in the context of creating forecasts demonstrated that the best system of variability after decomposition (filtering), along with consideration of the size of the set, is the hour / successive day of week system - filtered out from the source series. The system with the lowest variance, which proved to be series divided into day of the week, with division of every day into successive hours, was not taken into account due to a small sample size of data, since one of the models was a neural network, which required sets with a very large number of observations. Observations for one year, with listings in this system, enable the creation of series with 52 observations. This sample size is sufficient for many models, with the exception of network models.

Forecasting of prices in general is considered to be very difficult, mainly in the sense of required accuracies. Even models that are very expanded and complicated in terms of the algorithms applied, with a high number of input variables, do not guarantee high accuracy. For example, ARE is working on a model for price forecasting called TradeARE. The model has been tested since the end of March 2017. For a certain period, daily forecasts of electricity prices on the DAM (Fixing I) were presented. There is currently no information about forecasts of electricity prices on the DAM on ARE's websites. The model of TradeARE, as indicated by its description, employs several forecasting methods, and optimization, simulation and data mining methods have been implemented in it. The model requires many input variables, among which the most important are:

1. Forecast of demand for electricity,

2. Available generating potential of CDUs, accounting for the scope of planned and unplanned shutdowns and overhauls,
3. Generating potential of nCDUs, accounting for the scope of planned and unplanned shutdowns and the nature of their operation, including wind power plants and other renewable energy sources,
4. Capability and quantity of planned inter-system exchange,
5. Network limitations.
6. Generating costs in the power system, along with the costs of CO₂ emission allowances,
7. Operational Power Reserve (ORM) and Response Cold Reserve (IRZ),
8. Meteorological and hydrological conditions.

This simplified description of the model shows the degree of complexity and multitude of required input data. Knowledge of exchange and system data originating, among other things, from PPE, PSE, foreign exchanges, and from transmission network operators of neighboring countries, is necessary on every forecasted day.

This work was supported by the Scientific Grant Agency of the Ministry of Education of Slovak Republic and the Slovak Academy of Sciences by the projects VEGA No. 1/0372/18.

VI. REFERENCES

- [1] Ustawa z dnia 10 kwietnia 1997 r. – Prawo energetyczne (Dz. U. 2012 poz. 1059 z późn. zmianami)
- [2] Amjadi N., Keynia F. (2011), A new prediction strategy for price spike forecasting of day-ahead electricity markets, "Applied Soft Computing", Vol.11(6).
- [3] Amjadi N., Keynia F. (2011), A new prediction strategy for price spike forecasting of day-ahead electricity markets, "Applied Soft Computing", Vol.11(6).
- [4] Niedziółka S. Rynek energii w Polsce, Wydawnictwo Difin, S.A. Warszawa 2010 r. ISBN: 978-83-7641-292-4
- [5] Chatziagiannis D., Dourbois G., Biskas P., Bakirtzis A., 2016, European day-ahead electricity market clearing model, Power Systems Computation Conference (PSCC).
- [6] Fijorek K., Mróz K., Niedziela K., Fijorek D., Prognozowanie cen energii elektrycznej na rynku dnia następnego metodami data mining, Rynek Energii, 2010, nr 6 (91)
- [7] Decyzja nr 994/2012/UE w sprawie ustanowienia mechanizmu wymiany informacji w odniesieniu do umów międzyrządowych w dziedzinie energii między państwami członkowskimi a państwami trzecimi.
- [8] Kolcun M., Rusek K., Analysis of prices for electricity at the Polish Power Exchange, Polish Journal of Management Studies ISSN 2081-7452, Czestochowa University of Technology, 2018, vol. 17, No.1, 155-164.
- [9] Prawo energetyczne, Ustawa z dnia 10.04.97, (Dz.U. 2012, poz. 1059 z późn. zm.).
- [10] Rozporządzenie Komisji (UE) nr 838/2010 z dnia 23 września 2010 r. w sprawie ustanowienia wytycznych dotyczących mechanizmu rekompensacji dla operatorów działających między systemami przesyłowymi i wspólnego podejścia regulacyjnego do opłat przesyłowych, Dz.U. L 250.
- [11] <https://tge.pl/pl/10/zakres-dzialalnosci>
- [12] <http://raport.pse.pl/pl/aktywny-udzial-w-rozwoju-ryнку-energii-elektrycznej#wspolpraca-regionalna>
- [13] <https://www.ure.gov.pl/pl/publikacje/seria-wydawnicza-bibli/jaki-model-rynkuenerg/>
- [14] <https://www.pse.pl>
- [15] [http://orka.sejm.gov.pl/opinie8.nsf/nazwa/363_20170222_1/\\$file/363_20170222_1.pdf](http://orka.sejm.gov.pl/opinie8.nsf/nazwa/363_20170222_1/$file/363_20170222_1.pdf)

Modelovanie tém v textových prúdoch dát

Miroslav Smatana

Katedra kybernetiky a umelej inteligencie
Technická univerzita v Košiciach
Košice, Slovensko
miroslav.smatana@tuke.sk

Peter Butka

Katedra kybernetiky a umelej inteligencie
Technická univerzita v Košiciach
Košice, Slovensko
peter.butka@tuke.sk

Abstrakt—V predloženej práci sa venujeme problematike modelovania tém zo vstupnej množiny textových dokumentov. Modelovanie tém patrí medzi štandardné metódy analýzy textových dát a svoju popularitu si získalo najmä v posledných rokoch s príchodom sociálnych médií a digitalizácií dokumentov. Tieto texty často obsahujú užitočné informácie, pričom modelovanie témy (ktoré sa snaží odkrývať skryté tematické vzťahy zo vstupnej množiny dokumentov) nám ponúka nové možnosti ich prehľadávania, vyhľadávania a sumarizácie. Existuje niekoľko metód ktoré riešia problém extrakcie tém, avšak bolo predstavených len málo metód schopných spracovávať prúdy textov v reálnom čase, ktoré tvoria v súčasnosti drvivú väčšinu textových. Preto sme sa v tejto práci rozhodli venovať problematike spracovania textových prúdov dát. Práca popisuje navrhovanú metódu na extrakciu tém z prúdov dát a taktiež platformy na spracovanie veľkých dát, v rámci ktorej je táto metóda implementovaná.

Keywords—*veľké dáta; modelovanie témy; prúdy dát; neuronové siete; autoenkodér*

Abstract— In this paper, we are dealing with the problem of topic modeling from an input text corpus. Topic modeling represented a standard method for text analysis and grown its popularity in recent years with a large number of digital documents, especially from social media. Those data usually contain useful information, and topic modeling represents a new way for their browsing, searching and summarizing. There exist several topic modeling methods, but only a small part of them are dealing with the processing of data streams in real-time. For that reason, we aim our work to develop a method which will be able to extract topics from data streams and its implementation using a big data platform.

Keywords—*big data; topic modeling; data streams; neural networks; autoencoder*

I. ÚVOD

Marketing stále závisel na dátach. Ich správne pochopenie a použitie môže spoločnosti priniesť konkurenčnú výhodu, naopak ich ignorovanie môže stať firmu jej postavenie na trhu. V kontexte marketingu sú tieto dáta chápané ako informácie o zákazníkoch, názory na produkty, názory na spoločnosť a pod.

V minulosti boli tieto typy dát získavané pomocou dotazníkov, rozhovorov, a na ich základe vytvárali spoločnosti rozhodnutia.

V súčasnosti s príchodom sociálnych médií, ktoré sú momentálne vnímané ako jeden z najsilnejších komunikačných prostriedkov a začínajú vytláčať štandardné

komunikačné prostriedky ako telefónne hovory a SMS správy, sa v marketingu otvárajú nové možnosti získavania a analýzy dát. Sociálne médiá sú zdrojom enormného množstva príspevkov. Tieto príspevky zvyčajne odrážajú názory a postoje používateľov na udalosti vo svete, produkty, osoby, organizácie a pod. Pri ich zbere a následnej analýze sa stretávame s niekoľkými výhodami [1]:

- nie je potrebná interakcia s používateľom;
- zo sociálnych médií je možné získať oveľa viac dát ako pomocou klasických metód;
- získané dáta sú často bližšie skutočnosti ako pomocou klasických metód, kde si používatelia dávajú väčší pozor na svoje odpovede.

Taktiež dáta získané touto formou majú niekoľko nevýhod [1]:

- v množstve získaných dát je často zložitá a časovo náročná nájsť tie ktoré budú pre spoločnosť užitočné;
- mnoho z príspevkov získaných takouto formou obsahuje len odkaz na iné webové stránky, videá, obrázky, čo ich spracovanie robí náročnejším.

Dáta zo sociálnych médií môžu byť následne využité na niekoľko typov analýz ako napríklad [1]:

- analýza krízových situácií v čase - v prípade vojnového konfliktu je možné sledovať časový vývoj toho, ako ľudia reagujú a na základe toho vykonať adekvátne kroky;
- zavedenie nového produktu na trh - sledovanie používateľských reakcií, či sa im produkt páči alebo aké ma nedostatky;
- cielený marketing - napríklad sledovanie jednotlivých častí mesta a zisťovanie čo v ktorých častiach ľudí zaujíma a na základe toho im ponúkať produkty;
- ochrana reputácie - sledovanie príspevkov, ktoré píše o danej spoločnosti a ak sú tieto príspevky negatívne snažiť sa čo najskôr reagovať.

Ako je možné vidieť, analýza príspevkov zo sociálnych médií môže hrať významnú úlohu v marketingu. Jednou z možností takejto analýzy je použitie metód modelovania tém, ktoré nám ukázali nové možnosti pre prehľadávanie,

vyhľadávanie a sumarizáciu veľkého množstva textových dát. Cieľom modelovania témy je vytváranie skupín slov (reprezentujúcich tému), ktoré sa spolu často vyskytujú. Avšak ak chceme dáta zo sociálnych sietí využiť čo najefektívnejšie, potrebujeme ich analyzovať v reálnom čase, kde tieto príspevky sú vo forme prúdov dát. Ich spracovaniu je v súčasnosti prispôbené len malé množstvo metód. Preto sme sa v tejto práci rozhodli zaoberať modelovaním témy a taktiež návrhom platformy na spracovanie veľkých dát, ktorá by bola schopná tieto textové dáta spracovať a vizualizovať.

II. MODELOVANIE TÉM

Modelovanie tém je jednou z možností automatickej analýzy veľkého množstva textových dokumentov, ktoré sa snaží hľadať skryté tematické štruktúry v kolekcií vstupných dokumentov a vytvárať skupiny slov (témy), ktoré sa spolu vyskytujú dostatočne často. V dobrom modelovaní témy tieto skupiny slov dávajú význam ako napríklad "loď, kapitán, prístav" a "farma, pole, dobytok". Vďaka tomu nám modelovanie témy ponúka nové možnosti pre hľadanie, prehľadávanie a sumarizáciu textových dokumentov.

Jednou z možností ako rozmyšľať nad procesom modelovania témy je predstaviť si, že máme niekoľko zvýrazňovačov rôznych farieb a text z ktorého chceme extrahovať témy. Následne prechádzame text a zvýrazňovačmi vyznačujeme kľúčové slová tak, aby slová ktoré rozprávajú o rovnakej téme boli zvýraznené rovnakou farbou. Potom sú tieto slová vybrané z textu a zoskupené podľa farby [2].

Doposiaľ bolo vyvinutých niekoľko metód a ich modifikácií určených na modelovanie tém. Ako jedna z prvých metód môže byť vnímaná metóda latentnej sémantickej analýzy (LSA) [3], pretože sa snaží hľadať skryté sémantické štruktúry v texte. Aj keď táto metóda nie je priamo považovaná za metódu modelovania tém, jej rozšírenia sa stali základom pre tieto metódy. Príkladom je pravdepodobnostná latentná sémantická analýza [4], ktorá bola základom pre metódu Latentnej Dirichletovej Alokácie (LDA) [5]. Neskôr vzniklo niekoľko modifikácií LDA. Petterson a kol. [6] vo svojej práci používajú informácie o slove ako ďalší atribút, radšej ako určité explicitné obmedzenie. Okrem LDA a jej modifikácií vzniklo aj niekoľko iných metód ako napríklad hierarchický Dirichletov proces [7], modelovanie témy založené na metóde MASVI (Moving Average Stochastic Variation Inference) [8]. Prevažná väčšina týchto metód dosahuje kvalitné výsledky na rozsiahlych textoch, avšak na analýzu krátkych textov ako príspevky zo sociálnych sietí nie sú vhodné. Pre tieto potreby však bolo vyvinutých niekoľko metód ako napríklad Phan a kol. [9], Sridhar [10], Quan a kol. [11]. Tieto modely reprezentujú modely schopné spracovávať vstupné dáta v dávkach, avšak v súčasnosti sa do popredia dostávajú prúdy dát. Blei a Lafferty prezentovali metódu nazvanú Dynamic Topic Models (DTM) [12] **Chyba! Nenašiel sa žiaden zdroj odkazov.**, ktorá patrí medzi pravdepodobnostné časové modely. DTM je schopný pracovať s diskretným priestorovým modelom. Wang a kol. prezentovali Continuous Time Dynamic Topic Models (cDTM) [13], ktorý rieši problém diskretizácie klasického DTM. Ďalšou z metód schopných extrakcie tém v čase je prístup prezentovaný v [14], ktorý je založený na HDP.

V tejto práci sa budeme venovať modelu extrakcie tém založenom na neurónových sieťach, ktoré si nachádzajú v posledných rokoch v oblasti modelovania tém čoraz väčšie zastúpenie. Salakhutdinov a Hinton [14] prezentovali vo svojej práci model nazvaný Replicated Softmax (RSM). Larochelle and Lauly [16] prezentovali DocNADE, ktorý predstavuje neurálny autoregresívny model tém. Ďalšími z prác, ktoré sa venujú modelovaniu tém založenom na neurónových sieťach sú: Neural Variational Inference Model (NVDM) [17], Neural Topic Model NTM [18], k-kompetitívny autoenkodér KATE [19], ProdLDA [20] alebo model z oblasti extrakcie evolúcie tém v čase popísaného v práci [21].

III. NEURÓNOVÉ SIETE

Neurónová sieť (NN) [22] je výpočtový systém inšpirovaný prírodnými biologickými systémami (ako napr. ľudský mozog). NN je zložená z veľkého množstva vysoko prepojených elementov nazývaných neuróny (pomenovanie po neurónoch v ľudskom mozgu), ktorých cieľom je spolupracovať na vyriešení špecifického problému. Tak ako u ľudí je pri NN snaha dosiahnuť aby sa učili z dostupných príkladov a využiť získané vedomosti v budúcnosti. Aby sme boli schopný naučiť NN potrebujeme tréningové príklady $(x(i), y(i))$, kde $i \in \{1, \dots, n\}$ reprezentuje index i -tého tréningového príkladu z množiny n príkladov. x reprezentuje vstupné príznaky a y reprezentuje výstupné príznaky, ktoré chceme pomocou NN predpovedať. Napríklad v medicíne môžu pacienti reprezentovať tréningové príklady, ich symptómy reprezentujú vstupné príznaky a choroba reprezentuje výstup ktorý chceme predpovedať.

Pre popis komplexnejšej NN, je potrebné najskôr popísať najjednoduchšiu NN, ktorá pozostáva z jedného neurónu (štruktúra neurónu je zobrazená na Obr. 1). Neurón je výpočtová jednotka do ktorej vstupuje vstup $\{x_1, x_2, \dots, x_n\}$, generuje výstup y a pozostáva z nasledujúcich častí:

Synaptické váhy $\{w_1, w_2, \dots, w_n\}$ – slúžiace na prepojenie neurónov a sú nositeľmi informácií v NN.


- in – reprezentuje vstup do neurónu – a je funkciou vstupov $\{x_1, x_2, \dots, x_n\}$. Vo väčšine prípadov je táto funkcia jednoduchou sumou vstupov a ich synaptických váh:

$$in_i = \sum_{j=1}^n w_{i,j} x_j \quad (1)$$

- $f(in)$ – predstavuje aktivačnú funkciu. Existuje niekoľko typov aktivačných funkcií, ale pre potreby tejto práce sme sa rozhodli použiť sigmoidálnu aktivačnú funkciu:

$$f(in) = \frac{1}{1 + \exp(-in)} \quad (2)$$


- $out(x)$ – výstupná funkcia, ktorá je zvyčajne identickou funkciou - $out(x) = x$



Obr. 1 Štruktúra neurónu

NN je štruktúra, ktorá spája veľké množstvo neurónov tak, že výstup jedného neurónu je vstupom do iných neurónov. Príklad takejto komplexnejšej neurónovej siete so 4 neurónmi je zobrazený na Obr. 2, kde L1 reprezentuje vstupnú vrstvu, L2 reprezentuje skrytú vrstvu (výstupne hodnoty neurónov tejto vrstvy nie sú obsiahnuté v tréningových príkladoch), L3 reprezentuje výstupnú vrstvu a $a(i,j)$ reprezentuje výstup j-tého neurónu v i-tej vrstve. Počet vrstiev udáva hĺbku NN a na základe NN na Obr. 2 bude výstup NN vypočítaný nasledovne:

$$y = f^{(3)}(f^{(2)}(f^{(1)}(x))) \tag{3}$$



Obr. 2 Príklad neurónovej siete so 4 neurónmi

A. Autoenkodér

Autoenkodér (AE) je typ neurónovej siete, ktorá sa snaží predikovať svoj vstup na výstupe. Zvyčajne sa tento typ NN používa na redukciiu dimenzií príznakového priestoru alebo učenie príznakov. AE je možné chápať ako NN, ktorá sa skladá z dvoch častí: funkcie enkodéra $h = f(x)$ a funkcie dekodéra $r = g(h)$. Enkodér sa používa na extrahovanie redukovaných dimenzií alebo príznakov a dekodér sa používa na rekonštrukciu originálneho vstupu na základe týchto redukovaných dimenzií. Príklad AE je zobrazený na Obr. 3, kde $X \approx R$ a Z je reprezentácia vstupu s redukovanou dimenzionalitou.

IV. AUTOENKODÉR PRE POTREBY MODELOVANIA TÉM

V tejto kapitole predstavíme navrhovaný autoenkodér (TopicAE), ktorého cieľom je modelovať správanie generatívnych metód na modelovanie tém, čo znamená, že na skrytej vrstve sa aktivuje len malé množstvo neurónov (tém) pre každý vstup (dokument) a každý z týchto neurónov (tém) by mal byť aktivovaný len pre niekoľko dokumentov.

Pre dosiahnutie takéhoto správania sme modifikovali chybovú funkciu štandardného autoenkodéra na skrytej vrstve pridaním penalizácií pre témy:

$$J_{\text{topic}}(t) = J(t) + \Omega(t), \tag{4}$$

pričom $\Omega(t)$ je definované takto:

$$\Omega(t) = \alpha \sum_{i=1}^m \text{KL}(\rho || \rho'_i) + \beta \sum_{i=1}^m \text{KL}(\zeta || \zeta'_i) + \gamma \sum_{i=1}^h \text{KL}(\sigma || \sigma'_i), \tag{1}$$


kde α, β, γ sú váhy jednotlivých penalizácií tém v chybovej funkcii (zvyčajne nastavené na 1), m je počet tréningových príkladov, h je počet neurónov v skrytej vrstve. $\text{KL}(\rho || \rho'_i)$ predstavuje penalizáciu založenú na KL divergencii zvolenej nasledovne:

$$\text{KL}(\rho || \rho'_i) = \rho * \log \frac{\rho}{\rho'_i} + (1 - \rho) \log \frac{1-\rho}{1-\rho'_i} \tag{5}$$

ρ'_i je priemerná hodnota aktivácie neurónov na skrytej vrstve pre i-ty tréningový príklad, ζ'_i je medián aktivácií neurónov na skrytej vrstve pre i-ty tréningový príklad, σ'_i je priemerná hodnota aktivácií i-teho neurónu na skrytej vrstve pre množinu tréningových príkladov a ρ, ζ, σ sú konštanty (zvyčajne malé číslo blízke 0 napr. 0,05) a pre dosiahnutie podobnej distribúcie tém ako pri klasických metódach modelovania tém by malo platiť $\zeta < \rho$.

Témy z TopicAE je možné získať zo skrytej vrstvy, kde každý neurón predstavuje jednu z tém. Pre nájdenie slov, ktoré popisujú danú tému je potrebné aktivovať (nastaviť jeho hodnotu na 1) daný neurón na skrytej vrstve (tému) a hodnoty ostatných nastaviť na 0 a následne vypočítať aktivácie neurónov na výstupe, kde tieto neuróny reprezentujú jednotlivé slová.

Aby bolo možné využiť TopicAE na zobrazenie vývoja tém v čase stačí ak vstupné dáta zoradíme chronologicky a preúčame TopicAE po každom zázname alebo v dávkach.




Obr. 3 Príklad autoenkodéra


A. Experimenty

Kvalitu modelovania tém v prúdoch dát pomocou navrhovaného prístupu sme overovali na dátovej množine The Reuters Dataset¹, ktorá obsahovala 10788 dokumentov. Na porovnanie kvality navrhovaného prístupu s metódami LDA a LSI sme navrhli prístup vyhodnocovania kvality metód modelovania tém pri ktorom sme používali 2 kvalitatívne metriky: súdržnosť s využitím metriky UMass (na ohodnotenie kvality získaných tém) [23], a normalizovanú vzájomnú informáciu (Normalized Mutual Information - NMI) [24], ktorá slúži na porovnanie rozdielnosti extrahovaných tém.

Na Obr. 4 je možné vidieť, že nami navrhovaný prístup dosahoval lepšie výsledky súdržnosti tém pri aplikácii na úlohu extrakcie tém v čase a taktiež je možné vidieť, že dosahuje stabilné hodnoty súdržnosti v jednotlivých časoch. Z **Chyba! Nenašiel sa žiaden zdroj odkazov.** je vidieť, že aj hodnoty NMI boli porovnateľné s ostatnými metódami a taktiež dosahovali stabilné hodnoty. Okrem kvality extrahovaných tém sme sa taktiež zamerali na testovanie škálovateľnosti navrhovaného prístupu. V Tab. 1 sú zobrazené porovnania rýchlosti extrahovania tém zo vstupných dát s dôrazom na rôznorodosť počtu tém a veľkosti spracovávanej dávky dát. Ako je možné vidieť čas spracovania narastá tak s počtom extrahovaných tém, ako aj s veľkosťou spracovávanej dávky.



Obr. 4 Porovnanie priemernej súdržnosti pre LDA, LSI a TopicAE pre prúdy dát z Reuters datasetu (dataset bol rozdelený na 10 časových úsekov t1...t10)



Obr. 5 Porovnanie priemernej NMI pre LDA, LSI a TopicAE pre prúdy dát z Reuters datasetu (dataset bol rozdelený na 10 časových úsekov t1...t10)

V Tab. 2 je príklad vývoja tém v čase pre vybranú tému získanú pomocou TopicAE. V tabuľke môžeme vidieť ako sa menia kľúčové slová pre danú tému medzi jednotlivými dávkami v 10 rôznych časoch.

Tab. 1 Porovnanie rýchlosti extrakcie tém zo vstupnej množiny dokumentov s ohľadom na rôznu veľkosť dávok dát a počtu tém (všetky modely boli spúšťané pri 50 iteráciách pre prvú dávku a 10 iteráciách pre ostatné dávky dát).

	Priemerný čas spracovania prvej dávky dát [s]	Priemerný čas spracovania dávky dát [s]
dávka = 1079, počet tém = 50	42	8.3
dávka = 1079, počet tém = 100	49.6	9
dávka = 1079, počet tém = 200	61.4	13.8
dávka = 3000, počet tém = 50	105	20.5
dávka = 3000, počet tém = 100	135.6	27
dávka = 3000, počet tém = 200	174.8	34
dávka = 100, počet tém = 50	5	0.9
dávka = 100, počet tém = 100	6.2	1.1
dávka = 100, počet tém = 200	8.2	1.6

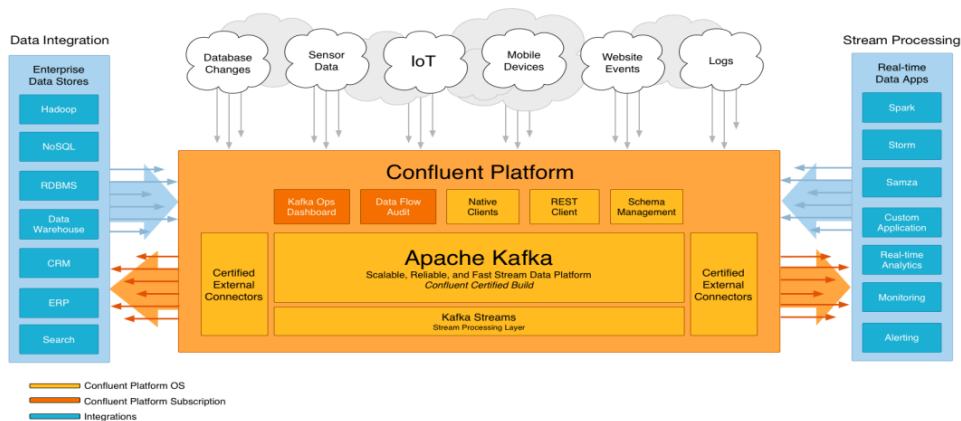
V. PLATFORMA NA SPRACOVANIE VEĽKÝCH PRÚDOV TEXTOVÝCH DÁT

Ako sme videli napríklad pri experimentoch škálovateľnosti TopicAE pre spracovanie prúdov dát, s narastajúcim počtom spracovaných dát narastal aj čas ich spracovania. Jednou z možností ako ich spracovanie urýchliť je použiť prístupy na spracovanie veľkých dát. V tejto práci sme navrhli jednoduchú, škálovateľnú platformu zobrazenú na Obr. 7, ktorá sa skladá z 4 hlavných častí:

- Integrácia/orchestrácia dát – pre potreby integrácie dát je použitá platforma spracovania prúdov dát Confluent², ktorá je kolekcia servisov, nástrojov a postupov určených pre integráciu a výmenu dát v reálnom čase medzi jednotlivými časťami systému. Confluent predstavuje v istom zmysle nervový systém našej platformy. Jednotlivé časti sú zobrazené na Obr. 6. V našej platforme nevyužívame všetky časti platformy Confluent, ale využívame len 4 vybrané služby a nástroje [25]:
 - Apache Kafka - predstavuje systém odosielanie správ pracujúci v reálnom čase, ktorý je odolný proti chybám a škálovateľný.

¹ <https://martin-thoma.com/nlp-reuters/>

² <https://www.confluent.io/>



Obr. 6 Vizualizácia Confluent platformy a jej častí [25]

- REST Client - ponúka jednoduché riešenie pre prácu s Apache Kafka. Umožňuje zasielanie a prijímanie správ cez Kafku pomocou RESTfull HTTP služieb.
- Schema Management - je určené pre serializáciu správ posielaných v Kafke do Avro formátu.
- Certified External Connectors - sú nástroje určené pre jednoduché streamovanie dát medzi Kafkou a inými dátovými systémami (v našom prípade medzi Kafkou a ElasticSearch).
- Modelovanie tém – v časti modelovania tém sú streamované dáta spracované pomocou frameworkov Apache Spark³, Keras⁴ a TensorFlow⁵. Spark predstavuje analytický framework určený pre spracovanie veľkých dát a framework Keras a Tensorflow sú použité pre implementáciu TopicAE.
- Ukladanie dát – Dáta sú ukladané v distribuovanom úložisku ElasticSearch⁶.
- Vizualizácia dát – Posledným krokom je vhodná vizualizácia výsledkov analýzy koncovému používateľovi. V tejto časti je možné použiť vlastné riešenie alebo prepojiť ElasticSearch s už existujúcimi vizualizačnými nástrojmi ako napr. Kibana⁷.

Tab. 2 Príklad vývoja tém v čase extrahovaných pomocou TopicAE

T1	T2	T3	T4	T5
Billion	Billion	Week	Week	Week
Week	Dlrs	Billion	Say	Say
Barrel	Week	Dlrs	Dlrs	Money
Rose	Rose	Rose	Barrel	March
Bank	Stock	Barrel	Money	Dlrs
Year	Barrel	Say	Supply	Supply
Stock	Fell	Fell	Rose	Ended
Crude	Supply	Supply	Bond	Growth
Fell	Year	Dollar	Stock	Barell
december	money	government	billion	Rose
T6	T7	T8	T9	T10
Week	Week	Week	Week	Week
March	Ended	Barrel	barrel	Say
Ended	Barrel	Distillate	Distillate	Barrel
Demand	March	Gasoline	Gasoline	Gasoline
Say	Distillate	Weekly	Weekly	Distillate
Crude	Gasoline	Demand	Demand	Stock
Economic	Crude	Stock	Stock	Weekly
Stock	Stock	Ended	Ended	Demand
Distillate	Say	Say	Say	Ended
supply	petroleum	crude	crude	crude

Celá platforma je implementovaná pomocou nástroja Docker⁸, ktorý slúži na virtualizáciu na úrovni operačného systému. Vďaka tomu je možné túto platformu nasadiť v priebehu niekoľkých minút. Pretože pilotná verzia našej platformy je nasadená na 3 serveroch rozhodli sme sa použiť Docker Swarm⁹ pre ľahšie manažovanie a škálovanie platformy.

³ <https://spark.apache.org/>

⁴ <https://keras.io/>

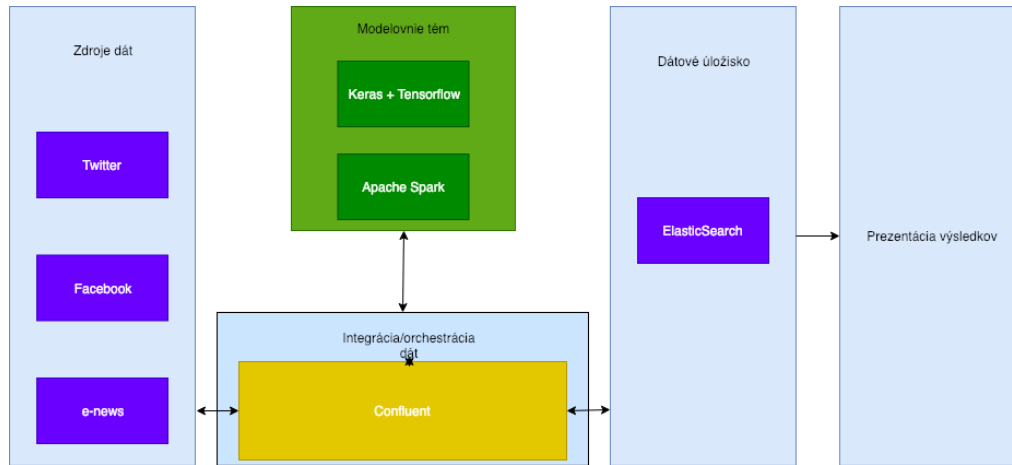
⁵ <https://www.tensorflow.org/>

⁶ <https://www.elastic.co/products/elasticsearch>

⁷ <https://www.elastic.co/products/kibana>

⁸ <https://www.docker.com/>

⁹ <https://docs.docker.com/engine/swarm/>



Obr. 7 Návrh Big Data platformy pre modelovanie tém

VI. ZÁVER

V predloženej práci sme sa venovali metódam modelovania témy a problémom s tým spojených. V práci bol prezentovaný prístup určený pre extrakciu tém zo vstupnej množiny dokumentov založený na neurónových sieťach. Výhodou navrhovaného prístupu je jeho schopnosť pracovať aj s prúdy textových dát a ako bolo možné vidieť z experimentov tak extrahovať kvalitnejšie témy ako porovnávané metódy. V práci bol taktiež prezentovaný návrh platforma na spracovanie veľkých prúdov textových dát.

PodĎakovanie

Tento príspevok vznikol s podporou APVV projektu č.APVV SK-AT 2017-0021.

Referencie

- [1] M. Smatana, P. Butka, "Topic Modeling in Social Networks as Decision Support System," Marketing Identity 2015, Trnava: FMK, 2015. ISBN 978-80-8105-779-3.
- [2] M. Brett, "Topic Modeling: A Basic Introduction," [Online]. [Dátum 2017-01-25]. Dostupné na internete: <http://journalofdigitalhumanities.org/2-1/topic-modeling-a-basic-introduction-by-megan-r-brett/>.
- [3] T. Landauer a kol., "An introduction to latent semantic analysis," Discourse Processes, vol. 25, 1998.
- [4] T. Hofmann, "Probabilistic latent semantic indexing," Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval, ACM, 1999, s. 50-57.
- [5] D. Blei, Y. Ng, M. Jordan, "Latent dirichlet allocation," Journal of machine Learning research, 2003, s. 993-1022.
- [6] J. Petterson a kol., "Word features for latent dirichlet allocation," Advances in Neural Information Processing Systems, 2010, s. 1921-1929.
- [7] Y. Teh a kol., "Sharing Clusters among Related Groups: Hierarchical Dirichlet Processes," NIPS, 2004, s. 1385-1392.
- [8] X. Li, J. Ouyang, Y. Lu, "Topic modeling for large-scale text data," Frontiers of Information Technology & Electronic Engineering, 2015, s. 457-465.
- [9] X. Phan, L. Nguyen, S. Horiguchi, "Learning to classify short and sparse text & web with hidden topics from large-scale data collections," Proceedings of the 17th international conference on World Wide Web, ACM, 2008, s. 91-100.
- [10] V. Sridhar, "Unsupervised topic modeling for short texts using distributed representations of words," Proceedings of NAACL-HLT, 2015, s. 192-200.
- [11] X. Quan a kol., "Short and Sparse Text Topic Modeling via Self-Aggregation," IJCAI, 2015, s. 2270-2276.
- [12] D. Blei, J. Lafferty, "Dynamic topic models," Proceedings of the 23rd International Conference on Machine Learning, New York, 2006, s. 113-120.
- [13] C. Wang, D. Blei, D. Heckerman, "Continuous time dynamic topic models," 2012.
- [14] A. Beykikhoshk a kol., "Discovering topic structures of a temporally evolving document corpus," Knowledge and Information Systems, 2018, s. 599-632.
- [15] R. Salakhutdinov, G. Hinton, "Replicated Replicated Softmax: an Undirected Topic Model," NIPS, 2009, s. 1607-1614.
- [16] H. Larochelle, S. Lauly, "A Neural Autoregressive Topic Model," NIPS, 2012, s. 2708-2716.
- [17] Y. Miao, L. Yu, P. Blunsom, "Neural Variational Inference for Text Processing," ICML, 2016.
- [18] Z. Cao a kol., "A Novel Neural Topic Model and Its Supervised Extension," AAAI, 2015, s. 2210-2216.
- [19] Y. Chen, M. Zaki, "KATE: K-Competitive Autoencoder for Text," KDD, 2017, s. 85-94.
- [20] P. Gupta a kol., "Deep Temporal-Recurrent-Replicated-Softmax for Topic Trends over Time," NACCL HLT, 2018, s. 1079-1089.
- [21] A. Srivastava, Ch. Sutton, "Autoencoding Variational Inference For Topic Models," ICLR, 2017.
- [22] I. Goodfellow, Y. Bengio, A. Courville, "Deep Learning," MIT Press, 2016.
- [23] D. Mimno a kol., "Optimizing semantic coherence in topic models," Proceedings of the Conference on Empirical Methods in Natural Language Processing. Association for Computational Linguistics, 2011, s. 262-272.
- [24] S. Emmons, S. Kobourov, M. Gallant, K. Börner, "Analysis of network clustering algorithms and cluster quality metrics at scale," PloS one, vol. 11(7), 2016.
- [25] "What is the Confluent Platform?," [Online]. [Dátum: 2019-02-12] Dostupné na internete: <https://docs.confluent.io/2.0.0/platform.html>

Ampacity of Overhead Power Lines

M. Špes,

Katedra elektroenergetiky, Fakulta elektrotechniky
a informatiky, TUKE
Košice, Slovensko
Michal.Spes@tuke.sk

L. Beňa

Katedra elektroenergetiky, Fakulta elektrotechniky
a informatiky, TUKE
Košice, Slovensko
Lubomir.Bena@tuke.sk

Abstract— This paper deals with powerline ampacity systems, specifically depending ambient conditions on transmission capacity of power line. Ambient conditions vary on the hydro meteorological impacts and local impacts. The hydro meteorological impacts include ambient temperature, wind speed and amount of sunlight radiation. Local impacts include location management and level of environmental pollution. Current capacity of conductors is defined as the maximum amount of current that can flow without damaging the conductor. It depends primarily on the electrical and mechanical properties of the conductor, their ability to spread the heat generated and the ambient conditions. The proposal of powerlines as each electricity device are subject to the valid standards. Standard EN 50341 defines the environmental conditions for calculating the maximum current capacity. In general, the environmental conditions are not constant over time. Depend on the climatic conditions of the country, area, that are different climatic nature. This paper deals with the calculation of the maximum current capacity of conductor of overhead transmission line based on ambient climatic conditions according to the equations defined in the IEEE Std 738-1993. The article describes average weather conditions in Slovakia and its impact on the determination of the maximum current capacity. Article compares the maximum current capacity given by ambient conditions referred to a standard and current capacity determined by average weather conditions.

Keywords— current capacity; ambient conditions; overhead lines; power lines; EN 50341; ACSR Conductor

I. INTRODUCTION

Power lines are technological devices that transfer electrical power from primary sources or secondary sources to the point of consumption or to the consumer.

Power lines can be realized as overhead lines or as isolated lines. In terms of implementation, they are preferred overhead lines. The main reasons are lower investment costs and lower operating costs. Another reason is simple maintenance of overhead lines.

We know these distributions systems in Slovak Republic:

- Low voltage system: 0,4kV
- Medium voltage system: 6kV; 10kV; 22kV; 35kV
- High voltage system: 110kV

- We know these transmissions systems in Slovak Republic:
- High voltage system: 220kV
- Ultra-high voltage system: 400kV

Extensive development of renewable sources requires expansion of transmission capacity of power lines. Despite the fact that power lines are an integral part of the system but their expansion is in seclusion interests.

For these reasons, it is necessary to seek other means of safeguarding the power transmission system. One possibility is operational methods which we monitor the temperature of the electrical wire and ambient influences. These indicate the current permissible current.

To determine the allowable current of the conductor is necessary to determine all factors influencing temperature of the conductor. Subsequent calculation can be determined at any given time under the conditions of maximum load capacity.

This method uses the current power lines and investment represents only the cost of computing software.

II. THE CURRENT STATUS OF THE TRANSMISSION CAPACITY OF ELECTRICAL LINES

Congestion problems of power lines appeared with massive development of renewable sources of high output. We mean solar and wind power plants if we talk about renewable sources [1] [2]. They are often connected to one end of the power system. Electric power that they supply is often necessary to transfer over long distances. This leads to overload of local power system [2].

The construction of new transmission lines has been in the past and at present is due to timetable and also a commitment to a huge problem.

- The problem of financing the construction of new lines
- The massive construction of renewable energy sources without respecting energy studies
- Contradiction environmental activists

The problem of the low capacity transmission lines are beginning to be observed not only in emergency situations but also in the normal operation [3].

Size of the transmitted power is defined as follows:

$$S = U \cdot I \quad (1)$$

Where:

S – Apparent power

U – RMS Voltage

I – RMS Current

Thus, the size of the transmitted power can be increased by changing the size of the current, voltage, or both parameters simultaneously.

Methods for increasing the transmission capacity:

- Increase ampacity
- Operational modalities
- Methods of increasing voltage
- Extensive solutions [3]

The author presents his main ideas, mathematical formulations and their derivation. This part should be accompanied by exact references.

III. INCREASE AMPACITY

Ampacity is the maximum current that can flow through the conductor, without the damage in the short or long term [4].

This current is primarily derived from the maximum permissible temperature, the determination of which varies depending on ambient conditions, particularly then at ambient temperature and the speed and wind direction [4].

Ampacity is thus dependent on these factors:

- Electrical and mechanical properties of the conductor material
- Thermal insulation properties of the material in cables
- The thermal capacity and conductivity of the guide body and its ability to transfer heat to the surroundings
- Environmental conditions

Conductor temperature also affects the size of the ampacity because it prolongs the wires and bring them closer to the ground and increase resistivity [5].

Since the sag depends on the temperature and is difficult to measure, it focuses research on the possibility of detecting the temperature of the conductors from which it then derives sag.

Due to the quadratic dependence of temperature on the size of the amount of current flowing through you can make a general idea about the differences Ampacity as shown in Fig. 1, when the conductor 400 mm² increase permissible operating temperature of 10 °C means an increase Ampacity of about 50 to 100 A.

For most prevalent the conductors ACSR this temperature increase means a change sag of 10-15 cm [5].




Fig. 1 The dependence of the capacity on the temperature conductors [5]

A. The methods depend on the conductors

The first option to increase ampacity is provided maintaining conductors. This method consists in increasing the maximum permissible operating temperature. The most older foreign power lines were rated for an operating temperature of 50°C. The maximum allowable operating temperature of the conductor ACSR is 90-100°C. With this method it is necessary to take into account the increase sag. Therefore, it is necessary to exchange and shortening of the insulator [6].




Fig. 2 Replacement of insulators used to increase the height of wires above ground

The second option is replacement conductors. This is an option when the conductors are not adequately dimensioned with respect to the standard. Where we have a reserve in the load bearing structures for the conductors of larger cross section. Despite the high prices occurs to extend the life of power lines. When using a high temperature conductors ampacity can be increased by up to 100%. Of course it is necessary to reckon with the fact that with an increase in temperature of aluminum, increases own resistivity. Among other things, occurring also further the warming due to reactive losses [7] [8] [9].




Fig. 3 Comparison of the structure the conductors ACSR and ACCC [9]

IV. OPERATIONAL MODALITIES

This solution consists in the expression of the actual temperature of the electrical conductor and the full exploitation towards the real limits that vary depending on environmental conditions. These are mainly on flow velocity of wind and ambient temperature [10].

Proposal for a new power line is in accordance with standards designed to be safe transmission of electricity even under the worst operating conditions. For these reasons, the management of such capacity is not used [10].




Fig. 4 Static characteristics ampacity for a period of time [10]

A. Probabilistic methods

Their principle consists in applying probabilistic models weather conditions in different periods and locations in determining the load limit. The criterion is not the temperature but the maximum allowable sag [11].

We know these probabilities methods:

- The method of crossing the projected temperature
- Determining the absolute probability of failure
- Simulation Methods estimated of security

B. Real-time monitoring

Measurement of various quantities related to the current state of the conductors is carried out due to time optimization of Ampacity under given ambient conditions, especially temperature measurements or sag. With knowledge of the current state of the line, operators can improve planning and management during accidents and emergency situations [11].

That the measurement data used effectively must be immediately after measuring analyze, safely and in time to send to the control center and moreover operators interpret as meaningful information for them, such as e.g. instantaneous reserve.

C. The temperature measurement of conductors

Use direct measurement using the measurement systems directly mounted on wire lines at selected locations (local) Fig. 5., or laying the optical fiber directly to the conductors (global) Fig. 6., which allows you to monitor the temperature profile of about every meter up to a distance of several dozen kilometers [13].



Fig. 5 RIBE-Ritherm system [13]




Fig. 6 VALCAP system [13]

D. Measurement of mechanical tension

The size of mechanical tension derives from the tension of conductors between the poles and indirectly determines the sag in that section. Sensors are placed between the grounded end of the insulator and an anchor point on the pole [12].

V. METHODS OF INCREASING VOLTAGE

If the design of poles permits, it is very advantageous to increase the line voltage, and thereby at the same transmit power quadratically reduce losses [12].

With the transition to a higher voltage is beyond an exchange of insulating elements and switching devices are often connected also total replacement of conductors due to the emergence of the corona [12].

A further disadvantages may constitute line redundancy in the voltage level and need long time for reconstruction. Also, problems may arise with height above the ground, which demands with a higher level of voltage is also rising [12].

VI. POWERLINE AMPACITY SYSTEM

Conductor ampacity is defined as the maximum permissible load current, which can transmit the conductor without compromising its function. This distortion is mainly caused by exceeding the maximum permissible temperature.

The maximum current that can be transferred over the line, is not a constant value as yet, but is determined for the unsurpassable temperature conductors depending on ambient conditions - particularly ambient temperature and wind flow.

The ampacity depends on:

- Electrical and mechanical properties of the conductor material
- Thermal insulation properties (the cables)
- Ability to dissipate within the conductor generated and received from nearby heat
- Ambient weather conditions

It is therefore apparent that the ampacity is mainly influenced by the thermal condition of the conductors, because it determines the extension conductors and therefore sag power line over the terrain.

In determining the maximum transmission capacity we use a method that is based from thermal equilibrium between the conductors and the environment.

At steady state, this equation can be expressed as equality heat gain = heat loss [4].

The full form of the equation is:

$$P_J + P_M + P_S + P_i = P_C + P_r + P_W \quad (2)$$

Where:

- P_J (W) - heat losses in the conductor,
- P_M (W) - magnetic heating of magnetic field variations AC,
- P_S (W) - solar radiation,
- P_i (W) - heating from the corona,
- P_C (W) - cooling by heat convection – by radiation,
- P_r (W) - radiant cooling,
- P_W (W) - cooling from water evaporation.

Heating corona P_i , cooling by evaporation of water P_W and heating by changing the magnetic field of alternating current P_M in the equation is usually neglected, from which we get the final equation [4].

$$P_J + P_S = P_C + P_r \quad (3)$$

In determining the maximum transmission capacity using methods that based conductor of heat balance and its surroundings. By entering the ambient temperature, the

geographic position line (to determine the solar radiation), wind direction and velocity. The parameters for calculating the predicted properties of the cables - ability to absorb sunlight and heat transfer coefficient on the surface of the conductor [4].

At steady state must balance energy increases the temperature of the conductor and the amount of energy to dissipate heat from the conductor:

$$q_s + R.I^2 = q_c + q_r \quad (4)$$

Where:

- q_s (W.m⁻¹) – energy from solar radiation,
- q_c (W.m⁻¹) – energy heat transfer from the conductor to the surroundings,
- q_r (W.m⁻¹) – energy from heat radiation.

From the foregoing equation can be derived a formula for calculating the current:

$$I = \sqrt{\frac{q_c + q_r - q_s}{R_t}} \quad (5)$$

Where R_t is conductor resistance at known temperature.

A. Energy from solar radiation

Heat gain supplied by sunlight depends on the efficient transfer surface conductor and the fact that corroded and dirty conductor can absorb around 90% of radiation compared with a perfectly black body than newly placed conductor on poles whose absorption is between 20-30% [4].

We can determine heat gain supplied by sunlight as follows:

$$q_s = \alpha.Q_s.\sin(\Theta).A' \quad (6)$$

Where:

- α (-) is the thermal coefficient of resistance of the conductor material,
- Q_s (W.m⁻²) is solar heat,
- A' (m) is diameter of the conductor,
- Θ is the angle of incidence of solar radiation.

B. Energy heat transfer from the conductor to the surroundings

Cooling fluid flow is physically intricate plot depending on the nature of hydrodynamic and thermal boundary layer, the shape and the size is determined by the speed and the direction of flow, formed in the close proximity to the heat transfer surface and on mass quantities of fluid, such as density, kinematic viscosity, thermal conductivity and isobaric specific heat in the event that no change of state of the fluid [4].

Mathematical expression is thus very complicated and without major simplification almost impossible. For ease of calculation may be used to simplify the equation, it is not necessary to find the appropriate criterion values in the tables, but substituting direct measurements of wind flow to the appropriate body – conductor [4].

$$q_c = \left[1,01 + 0,0372 \cdot \left(\frac{D \cdot \rho_f \cdot V_w}{\mu_f} \right)^{0,52} \right] \cdot k_f \cdot K_{angle} \cdot (T_c - T_a) \quad (7)$$

Where:

- D (mm) is diameter of conductor
- ρ_f ($\Omega \cdot \text{mm}^{-2}$) is density of air
- V_w ($\text{m} \cdot \text{s}^{-1}$) is wind speed
- μ_f (Pa.s) is dynamic viscosity of air
- k_f ($\text{W} \cdot \text{m}^{-1} \cdot \text{C}^{-1}$) is the thermal conductivity of air
- K_{angle} (-) is factor angle wind conditions
- T_c ($^{\circ}\text{C}$) is conductor temperature
- T_a ($^{\circ}\text{C}$) is ambient temperature

C. Energy from heat radiation

When a bare overhead conductor is heated above the temperature of its surroundings, energy is transmitted by radiation to the surroundings. The rate at which the energy is radiated is dependent primarily on the difference in temperature between the conductor and its surroundings, which are assumed to be at ambient temperature. The surface condition of the conductor, its emissivity, also affects the radiative heat transfer. Radiation is described by the Stefan-Boltzmann law, relating the radiative energy transmission to the difference between the conductor surface temperature and the surrounding temperature, expressed in absolute (Kelvin) degrees to the fourth power. The constants in Equations (8) include the Stefan –Boltzmann constant and conversion factors to produce a result in the desired units [4].

$$q_r = 0,0178 \cdot D \cdot \varepsilon \cdot \left[\left(\frac{T_c + 273}{100} \right)^4 - \left(\frac{T_a - 273}{100} \right)^4 \right] \quad (8)$$

VII. CLIMATIC DONDITION IN SLOVAKIA

Climatic conditions or the climate is understood as a long-term weather conditions with all the peculiarities that may be in that location or area show. In determining the climate and weather conditions must be based on the geographical location of the territory [4].

The Slovak Republic belongs to the northern temperate climatic zone with regular alternation of the seasons with an even distribution of rainfall during the year. The climate is influenced by the prevailing westerly airflow that brings moist oceanic air temperate latitudes. Moderates temperature amplitude of day and year and brings atmospheric precipitation. Continental air of mild latitudes bring warm, sunny and less humid summers and cold winters with low rainfall [4].

A. Solar radiation

Solar radiation consists of direct and diffuse radiation incident on the surface. Most affected by the duration of

sunshine and cloud cover. The annual average values of solar radiation in lowlands are in the range 1200 to 1300 kWh.m⁻². The highest position is the 1100-1200 kWh.m⁻². The middle mountain positions a mean value of the annual solar radiation is 1050-1100 kWh.m-2 [4].

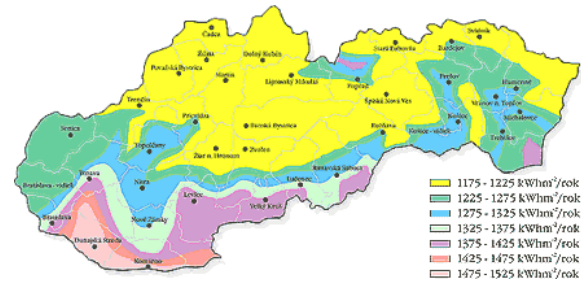


Fig. 7 The amount of incident solar radiation in Slovakia during the year [4]

Table 1 The amount of incident solar radiation in Slovakia

Area	Average amount of solar radiation (W/m ²)
1	134-140
2	140-146
3	146-151
4	151-157
5	157-163
6	163-168
7	168-174

B. Air temperature

The air temperature is on the one hand among the major climatic factors, as well as among the main factors affecting the actual current load of conductor [4].

In a long-term measurement of air temperature in the region of Slovakia is warmest zone Danubian lowland with average air temperature in January -1 to -2 °C, in the month of July 18 to 21 °C. The annual average of this area is in the range of 9-11 °C. The Eastern plains, the average temperature is slightly lower. The basins and valleys of is average annual air temperature 6-8 °C. In the upstream basins below 6°C. For the an altitude of 1000 meters above sea level average value reaches the interval 4-5°C, at a height of 2000 meters above sea level around -1°C [4].

The average temperature during the months of June to August is shown in the following figure.

The average temperature during the months of December to February is shown in the following figure.

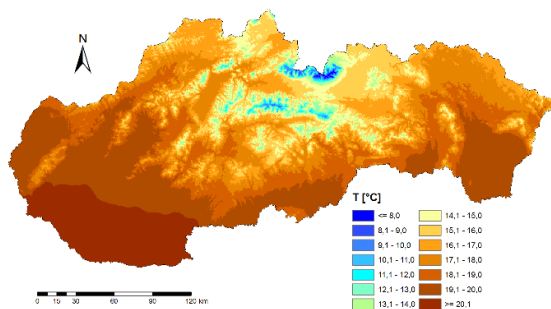


Fig. 8 Average air temperature from June to August [4]

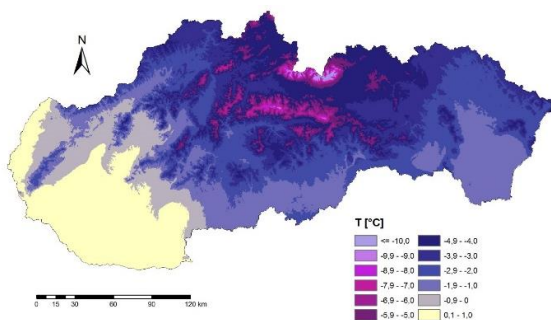


Fig. 9 Average temperature from December to February [4]

C. Wind conditions

Wind conditions on the Slovak are considerable complicated. The main impact has the variability of weather during the year. In the lowland of western Slovakia, the annual average speed is in the range 3-4 m/s. In Eastern Slovakia 2-3 m/s. In the basin is wind speed influenced by openness or closeness to the flow. In the more open basins, the wind speed is in the range 2-3 m/s. In closed basins is the average wind speed of 1-2 m/s. In the mountains, depending on the altitude, the average annual speed is in the interval 4-8 m/s [4].




Fig. 10 Map of wind areas in Slovakia [4]



Fig. 11 Wind speed and direction of wind [4]

VIII. DEFINING RESEARCH PROBLEMS

For the design of power lines is currently applicable standard EN 50341 where are defined ambient conditions for calculation of maximum allowable current value. This standard recommended maximum operating temperature 70°C of conductor [7].

Ambient conditions for calculation of maximum allowable current value of conductor according to the standard are:

- The ambient temperature is 35 ° C,
- Wind speed is 0.5 m / s at 45 ° angle of impact,
- Global temperature of sunlight is 1000 W/m²,
- Absorption coefficient is 0.5,
- Emissivity coefficient of 0.5 [7].

It is necessary to say that conditions given by a standard are the worst case of ambient conditions, which is rarely found. Based on this hypothesis, we compare current value given by a ambient conditions in Slovakia and current value determined by a calculation given by a ambient conditions accordance a standard EN 50341.

1) Construction of ultra high voltage power lines

In practical terms, for the line of 400 kV voltage level are used trunked conductors where one phase consists of three conductors each and electrically connected at a distance, thereby enhanced radius of the conductor of one phase [8].

As conductors of transmission lines are used aluminum cables with steel core. Their advantage is greater mechanical strength, which allows its use for large distance. Among their other advantages include greater flexibility, more uniform structure. When wires material mistake can degrade the whole wire, but with ACSR ropes, tearing of one wire not damage the whole conductor [8].

Parameters of the examined conductor are in the table below.

Table 2 Parameters of the examined conductor [8]

Parameters	ACSR 680/73
Rope diameter (mm)	35,8
Rope cross-section (mm ²)	761,69
Nominal weight (kg.km-1)	2556,12
Specific gravity (MN.m-3)	0,03291
The maximum	93,072

permissible stresses (MPa)	
Elastic modulus (MPa)	69447
The coefficient of thermal expansion (1/°C)	19,46
Rated DC resistance (Ω/km)	0,0433

A. Impact of solar radiation to the current capacity of conductor

Total solar radiation incident on the general plane is the sum of direct radiation, diffuse radiation and reflected radiation. With sufficient precision, it is possible to neglect diffuse and reflected radiation as they affect 2% - 4% [9] [10] [11].

As is apparent from equation above most influence determines argument *Is*, which is variable in the time. Other arguments are of constant character. Argument *D* is significant for a design of new power lines, where can by choose a type of used conductor [9] [10] [11].

For purpose of this article we examine contribution of the solar radiation to the current capacity in Slovakia ambient conditions. Input data of solar intensity radiation are from the table above (Table 1).

Results from the calculation for ACSR conductor 680/73 with comparing current capacity given by a calculation accordance a standard EN 50341 are on the figure bellow (Fig. 12

As is shown in the Figure 13, current capacity given by a calculation accordance to the ambient conditions intended by a standard is 632,02 A for the one conductor in three beam connection.

Current capacity of ACSR conductor 680/73 for average value of solar radiation in Slovakia in range from 134 to 174 W/m² does not achieve a significant change of current value. Results current capacity for intensity of solar radiation 134 W/m² is 744,28 A, that is in comparing with capacity given by a standard about 17,7% higher. On the other side, for intensity of solar radiation 174 W/m² is current capacity 739,47 A, what is decrease in current capacity for ACSR 680/73 only about 0,7%.

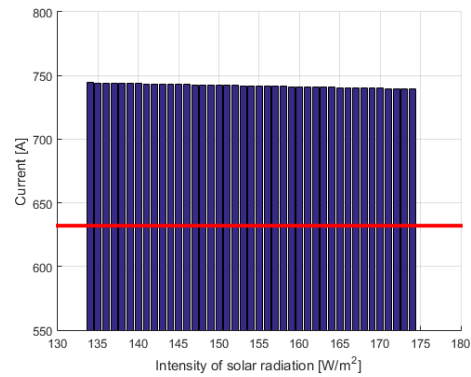


Fig. 12 Comparing resulting current capacity based on the average intensity of solar radiation

B. Impact of air flow to the current capacity of conductor

Airflow cooling is a physically complex process that depends on the nature of the hydrodynamic and boundary temperature layer, the shape and size of which is affected by the velocity and the flow direction, which are formed near the heat of the exchange surface and the material quantities of the fluid [9] [10] [11].

As is clear from the equation most influence on the magnitude of the thermal loss of the conductor has air velocity *w*. A significant parameter is also ambient temperature, which decreases the value of the thermal losses.

For purpose of our research are other parameters constant. A magnitude *K_{uhol}* represent coefficient to respect the influence of wind on the value of thermal loss.

To determine impact of air velocity to the maximum allowable current capacity of conductor we use map of wind areas in Slovakia.

Map of wind areas has defined for Slovakia territory points with specific air velocity and direction of air flow.

To determine current capacity of conductor ACSR 680/73 we create an interval of average values of air velocity from 1,30 to 11,10 m/s.

Results from the calculation for ACSR conductor 680/73 with comparing current capacity given by a calculation accordance a standard EN 50341 are on the figure bellow Fig. 13

As is shown on the figure, change of air velocity has influence on the current value. For air velocity in the range 1,30 m/s to 6,0 m/s we experienced an exponential growth of the current capacity. In the range 6,0 m/s to 11,10 m/s there was an linear growth of the current capacity.

A difference by a current ampacity given by calculation accordance a standard EN 50341 and current capacity of conductor ACSR 680/73 obtained by a calculation for average values of air velocity were as follows:

- For air velocity 1,3 m/s is difference between calculation accordance a standard and average value 31,90%. Current value in this point is equal 833,40 A.
Current value given by a calculation accordance a standard is 632,02 A.
- For an exponential growth of current capacity of conductor for air velocity 6,0 m/s there was an increase towards a value 631,85 A 106,66%.
- For air velocity 11,10 m/s is growth in current capacity equal to 147,39% of the capacity given by a ambient conditions contained in the standard.

Based on these results, we can say that a minimal change of air velocity leads to increase a current capacity of conductor.

The most pronounced increase is in the initial values in the range of average air velocity in the Slovakia weather conditions.




Fig. 13 Comparing resulting current capacity based on the average air velocity

C. Impact of natural radiation to the current capacity of conductor

The radiation represents a mechanism of heat transfer, which consists in the emission and absorption of the electromagnetic radiation. An object with a non-zero temperature emits electromagnetic radiation according to Planck's law [9] [10] [11].

The total amount of energy emitted from the surface of the object increases with surface temperature. Depending on the temperature of the body surface, the emission spectrum changes. By the increase of the temperature there is a change of the spectrum to shorter wavelengths. Each object in addition to its own radiation captures the photons radiated by nearby objects. The resulting energy balance of the process is given by the difference of radiated and received energy. As the amount of radiated energy increases with temperature, resulting radiation is the transfer of energy from warmer units to cooler [9] [10] [11].

To determine impact of natural radiation to the maximum allowable current capacity of conductor we average temperature for summer season and winter season (To

determine the current capacity of conductor we choose a two range for examining. First chooses temperature range is for summer season. It is from 8°C to 20°C. Second studying temperature range for winter season is from -10°C to 0°C.

Results from the calculation are on the following figures Fig. 14 Fig. 15

As can be seen from the attached figures (, when ambient temperature changes occur equally to change current capacity for conductor ACSR 680/73. This change current capacity occurs as a direct result of changes in the coefficient of heat loss by natural radiation (P_r), wherein in increasing the ambient temperature leads to inversely proportional heat rejection to the environment. In terms of size of current capacity in the summer season, there is a decrease current value from 902,30 A to 795,50 A. For the winter season there was a decrease of current capacity from 1038,08 A to 965,50A.

As we see from the Fig. 14, for ambient temperature 8°C is current capacity value higher against the current capacity given by a standard about 42,78%. Due to an increase of ambient temperature to 20°C occur a change in difference between current values in this point of temperature and current value given by a standard to 25,90%.

As shown by the equation (6), magnitude of ambient temperature has most influence on the value of current capacity. This theoretical knowledge has been confirmed by a Fig. 15. At a lower temperature occurred an increase of current capacity. For average ambient temperature in Slovakia conditions -20°C was current value equal to 1038,09 A what is higher compared to the current value given by a calculation with ambient conditions accordance a standard about 64,29%.

In the second point of examining range 0°C is current capacity equal to 965,50 A, what is about 52,80% higher than current value given by a calculation with ambient conditions accordance a standard.




Fig. 14 Comparing resulting current capacity based on the average temperature in summer season




Fig. 15 Comparing resulting current capacity based on the average temperature in winter season

CONCLUSION

Power lines are the most important part of power systems. Their role is not substitutable and their construction determines the size of the current capacity. As every construction of electricity facilities is subject to the standard, also construction of power lines and design is subject of standard. Current capacity of the conductors depends also on ambient conditions, which are in standard EN 50341 described. This ambient conditions are given for the worse case that can occur. As is know this ambient conditions or their combination are very rare in nature.

In this article are described method to determining the current capacity for ACSR conductor 680/73 accordance average ambient conditions in Slovakia, which are described.

As is clear from the results, ambient conditions have most influence on the actual value of current capacity. If we can accurately determine the ambient conditions in real time, we can determine the current capacity under these terms and adapt operation of power system or power lines.

REFERENCES

- [1] M. Kolcun, V. Griger: "Controlling the operation of the power system" (Riadenie prevádzky elektrizačnej sústavy), Mercury - Smékal, Košice, 2003, 288 pages, ISBN 80-89061-57-5.
- [2] Working Group B2.12, "Guide for selection of weather parameters for bare overhead conductor rating," CIGRE, 2006
- [3] A. Bracale, "Probabilistic index for increasing hourly transmission line rating," in Int. Journal of Emerging Electric Power Systems. 2007, pp. 119.
- [4] Slovenský hydrometeorologický ústav, "Klimatické podmienky na Slovensku" < <http://www.shmu.sk/sk/?page=1064>>
- [5] M. Špes: "Powerline ampacity system" Proc. SCYR 2016. - Košice : TU, 2016 pages 202-205. - ISBN 978-80-553-2566-8
- [6] M. Špes, L. Beňa, M. Mikita, M. Márton, H. Wachta: "Possibilities of increasing transmission capacity overhead lines", Acta Electrotechnica et Informatica. Vol. 16, No. 3 (2016), s. 20-25. - ISSN 1335-8243
- [7] EN 50341-1 ED.2 (333300): Elektrická venkovní vedení s napětím nad AC 1 kV - Část 1: Obecné požadavky - Společné specifikace
- [8] Š. Fecko, J. Žiaran, L. Varga: "Power lines – Overhead power lines" (Elektrické siete - Vonkajšie silové vedenia), SVŠT Bratislava, 1990.
- [9] CIGRE Task Force B2.12.3, "Sag-tension Calculation Methods for Overhead Lines." In Technical Brochure 324, June 2007.
- [10] CIGRE Working Group B2.12, "Alternating Current (AC) Resistance of Helically Stranded Conductors." In Technical Brochure 345, April 2008.
- [11] IEEE Power Engineering Society, "IEEE standard for calculating the current temperature of bare overhead conductors," 2007

Hybridný systém na detekciu malvéru

Matúš Uchnár

Katedra počítačov a informatiky
Fakulta elektrotechniky a informatiky
Technická univerzita v Košiciach
Košice, Slovenská republika
Email: matus.uchnar@tuke.sk

Liberios Vokorokos

Katedra počítačov a informatiky
Fakulta elektrotechniky a informatiky
Technická univerzita v Košiciach
Košice, Slovenská republika
Email: liberios.vokorokos@tuke.sk

Abstrakt—Táto práca sa venuje analýze malvéru a spôsobom jeho detekcie. V začiatku práce je definovaný malvér a sú popísané rôzne kategorizácie a druhy malvéru. Ďalej sú v práci popísané jednotlivé metódy detekcie malvéru a ich evolúcia. V práci je ukázané, že moderný malvér sa nedá detegovať jednoduchými mechanizmami a často na jeho detekciu treba využiť kombináciu viacerých techník, ktoré je potrebné neustále vyvíjať. V praktickej časti sú popísané rôzne spôsoby pomocou ktorých sa dá vyhnúť detekcii malvéru antivírusovými systémami. Nasledovne sú v práci urobené praktické pokusy a ukázané metódy a spôsoby, pomocou ktorých je možné detegovať aj takto špecifický malvér, ktorý sa snaží vyhnúť detekcii. Na konci práce je popísané zhrnutie a načrtnutá možná práca do budúcnosti.

Kľúčové slová—Detekcia malvéru, emulácia, malvér, strojové učenie, virtualizácia.

Abstract—This work aims at malware analysis and possible options for its detection. At the beginning of the work, the malware is defined and is categorized and divided. Next, various methods for malware detection and antivirus software evolution are described. It is proven at work that modern malware cannot be detected by simple methods and usually it needs combination of various techniques which needs to be constantly evolved. In practical part of the work, some methods for bypassing malware detection are described. Then, some methods and experiments are described which are aimed towards this specific malware, in order to make their detection possible. At the end of the work, one can find conclusion along with the future work ideas.

Keywords—Malware detection, emulation, machine learning, virtualization.

I. ÚVOD

V dnešnej dobe má skoro každý človek vo svojom PC istý druh osobných dát, ktoré sú pre neho dôležité (či sa už jedná o fotografie, dokumenty, alebo uložené heslá). Tieto dáta môžu byť potenciálne zaujímavé pre tretiu stranu a preto je potrebné sa patrične chrániť pred rôznymi útokmi, ktoré môžu nastať. Jedným z takýchto útokov je infekcia škodlivým softvérom, ktorý je v dnešnej dobe veľmi rozšírený. Každým dňom vznikajú nové a sofistikovanejšie programy, ktoré môžu poškodiť počítače, prípadne zneužiť dáta v nich. Infekcia škodlivým softvérom nastáva väčšinou stiahnutím infikovaného súboru z internetu, keďže v dnešnej dobe sa najväčší transfer dát vykonáva práve pomocou pripojenia na internet. Zriedkavá nie je ani nákaza pomocou prenosných zariadení, ktoré sa stále vo veľkom množstve používajú na prenos dát. Ako prostriedok boja proti týmto škodlivým programom bol vyvinutý antivírusový softvér, ktorý by mal vedieť

tieto programy odhaliť a eliminovať. To naštartovalo vývoj škodlivého softvéru, ktorý sa snaží uniknúť detekcii s využitím rôznych techník, za účelom zotrvania v napadnutom systéme. Veľký zlom v detekcii škodlivého softvéru nastal so začiatkom využívania virtuálnych systémov na analýzu správania týchto programov. Virtuálne systémy však nie sú dokonalé kópie ich hostiteľských systémov a často majú len základné knižnice a podporu, čo mnohé škodlivé programy využívajú ako prostriedok pre detekciu toho, že sú analyzované a tým pádom môžu zmeniť svoje správanie, aby unikli detekcii. Tieto nedokonalosti sa stali inšpiráciou pre túto prácu, ktorá sa venuje vytvoreniu hybridného systému pre detekciu malvéru, ktorý by netrpel týmito nedostatkami a tým pádom by mal vyššiu mieru detekcie škodlivého softvéru.

V tejto práci budú rozobrané jednotlivé druhy malvéru, spôsoby infekcie a ich správanie v osobitých prípadoch, za účelom pochopenia ich správania sa podľa rôznych kritérií. Následne budú rozobrané antivírusové systémy a ich metódy, ktoré používajú. V práci bude vysvetlené na čo jednotlivé metódy slúžia a bude ukázané využitie daných metód pre detekciu konkrétnych druhov malvéru. Ďalej bude v práci vykonaný experiment za účelom dokázať, že antivírusové systémy majú svoje chyby, čo dovoľuje malvéru nepozorovane infikovať systém. Na týchto poznatkoch a zisteniach bude následne založený návrh hybridného systému na detekciu malvéru, z ktorého budú plynúť hypotézy a ciele, ktoré budú základom pre ďalšiu prácu v tejto oblasti.

Ďalej sa práca bude zaoberať tvorbou programu na detekciu malvéru, ktorý deteguje realnosť operačného systému. V práci budú popísané jednotlivé artefakty operačného systému ako aj virtualizácia ako taká. Nasledovne budú v práci vykonané pokusy za účelom porovnať jednotlivé algoritmy strojového učenia aby sa zistilo, že ktorý algoritmus je najvhodnejší na detekciu malvéru a tento algoritmus bude následne implementovaný do navrhovanej aplikácie. Účelom práce bude vyvinúť aplikáciu, ktorá by uľahčila skúmanie a detekciu špecifického malvéru, ktorý je zameraný na detekciu prostredia a teda je ho obtiažne detegovať pomocou bežných metód, ktoré využívajú antivírusové systémy.

II. ŠKODLIVÝ SOFTVÉR

Škodlivý softvér, alebo malvér (skratka z angl. malicious software) je softvér, ktorý môže byť použitý na zneužitie

funkcií PC, krádež dát, obídienie bezpečnostných prvkov, alebo na iné poškodenie počítača [1], [2]. Malvér je široký pojem, ktorý zastrešuje množstvo škodlivých programov. Prvý škodlivý softvér boli jednoduché programy, ktoré boli vyvinuté za účelom srandy, alebo na spôsobenie minimálnych škôd. Tieto programy boli ľahko detegovateľné a odstrániteľné [2], [3]. Dnešný malvér sa veľmi ťažko deteguje, keďže každým dňom sú vydávané nové vírusy, ktoré často využívajú pokročilé metódy zahmlievania kódu, enkrypcie a taktiež polymorfie [3], [4].

A. Trendy v oblasti ukrývania malvéru


V súčasnosti, množstvo tvorcov malvéru sa zaoberá najmä spôsobmi ako uniknúť detekcii malvéru, keďže šírenie malvéru je v dnešnej dobe vcelku primitívnou záležitosťou vďaka internetu a často vďaka neskúseným používateľom. Teda na to aby bol malvér úspešný, potrebuje byť dostatočne dlho skrytý pred odhalením AV softvérom aby dokázal infikovať čo najviac strojov a zároveň vykonať svoju škodlivú činnosť. Keďže v dnešnej dobe sa už používajú sofistikované metódy detekcie malvéru, tvorcovia malvéru často využívajú rôzne techniky ukrývania malvéru aby sa vyhli statickej detekcii, čím značne predlžujú jeho životnosť. Avšak metódou, ktorá dokáže v teórii odhaliť ktorýkoľvek malvér je dynamická detekcia malvéru, čo je v podstate spúšťanie malvéru v bezpečnom prostredí a sledovanie jeho správania. Tento spôsob detekcie malvéru využíva väčšinou virtualizáciu, alebo emuláciu systému, čo so sebou prináša množstvo výhod, ale aj nevýhody a obmedzenia, ktoré sa tvorcovia malvéru snažia využívať. Medzi tieto nevýhody patrí aj fakt, že emulovaný systém nie je dokonalou kópiou reálneho operačného systému a na základe tohto faktu sa často tvorcovia snažia odhaliť tieto nedokonalosti a zabrániť spusteniu škodlivej časti kódu malvéru aby sa predišlo jeho odhaleniu. Iným príkladom môže byť zastavenie vykonávania škodlivej činnosti za určitých podmienok (napríklad pri spustení skenovania AV softvérom). Súčasný trend v ukrývaní malvéru pred odhalením by sa dali zhrnúť do nasledovných bodov:

- Využívanie rôznych bezpečnostných chýb operačného systému a softvéru (napr. zero-day útoky).
- Používanie rôznych techník obfuskácie, enkrypcie a steganografie za účelom skrytia škodlivého kódu aby ho nebolo možné odhaliť statickými metódami.
- Využívanie nedokonalostí emulátorov AV systémov za účelom zabránenia spusteniu škodlivej časti programu.
- Sledovanie prostredia a zastavenie škodlivej činnosti za špecifických podmienok, ktoré by mohli viesť k odhaleniu malvéru.
- Krádež certifikátov aby malvér vyzeral ako legitímny softvér.
- Postupná implementácia umelej inteligencie, ktorá dokáže meniť správanie malvéru na základe podmienok prostredia a jeho okolia a tým pádom predchádzať odhaleniu. Tento spôsob je zatiaľ veľmi zriedkavý, ale predpokladá sa postupné zdokonaľovanie umelej inteligencie malvéru a jeho rozšírenie v budúcnosti.


B. Enkrypcia

Tvorcovia vírusov zistili, že najlepším spôsobom ako spomalit alebo úplne sa vyhnúť antivírusovým skenerom je zistiť aby vírus nemal žiaden konštantný reťazec bajtov, ktorý by sa dal použiť ako podpis vírusu [5], [7]. Enkrypcia pre tieto účely sa dá klasifikovať ako proces, pri ktorom vírus zmení vizuálnu podobu svojho kódu natoľko, že sa na seba vôbec nebude podobáť, za účelom porazenia antivírusových skenerov (viď obrázok 1). Vírus sa spustí, rozšifruje sa, vykoná čo má a následne sa zasa zašifruje pred uložením na disk. Poprední autori vírusov začali skúmať a používať profesionálne šifrovacie algoritmy. Na to aby vírus dokázal využívať enkrypciu, musí byť schopný rozšifrovať svoj zašifrovaný kód v reálnom čase.

Bez enkrypcie:



S enkrypciou:



Obr. 1. Príklad šifrovaného vírusu

Ako teda dokáže antivírusový program získať dobrý podpis vírusu? Riešenie zahŕňa hľadanie dekryptovacieho algoritmu (nazývaného taktiež dekryptor), ktorý sa musí nachádzať na začiatku vírusu [6]. Táto funkcia sa stala dobrým podpisom vírusu. Tieto funkcie nesmú byť zašifrované, keďže na ich spustenie musia byť v ich čistej podobe. Tvorcovia vírusov následne začali vyvíjať kratšie dekryptovacie funkcie, keďže tieto zvyšujú šancu, že antivírusový skener bude produkovať veľa falošných pozitív, kvôli krátkemu podpisu vírusu. Napriek tomu väčšina antivírusových programov dokáže identifikovať zašifrované vírusy celkom spoľahlivo. Aj keď väčšina vírusov používa šifrovanie ako metódu skrývania sa pred antivírusovými programami, niektoré vírusy využívajú šifrovanie kvôli sťaženiu procesu odstránenia pre antivírusové programy. Pri infekcii zašifrujú bootovaciu oblasť, alebo súbor, ktorý prvý infikujú. V prípade potreby dešifrujú boot sektor, alebo infikovaný súbor, ale po použití ich naspäť zašifrujú. Po odstránení vírusu sa môže stať, že súbor alebo bootovacia oblasť zostanú zašifrované a teda nedostupné.

C. Zahmlievanie kódu

Zahmlievanie kódu (alebo taktiež obfuskácia) je technika, ktorá má zmeniť zdrojový kód programu do vizuálne inej, pre človeka nečitateľnej a nezrozumiteľnej formy bez zmeny správania sa obfuskovaného programu [11], [12]. Táto technika sa často používa na bezpečnostné účely, na odvrátenie úpravy kódu druhou osobou, na znemožnenie reverzného inžinierstva alebo taktiež ako metóda ukrývania vírusov. Častými prístupmi obfuskácie, ktoré využívajú najmä metamorfické vírusy sú [12]:

- Obfuskácia toku riadenia – zmena toku riadenia

- Obfuskácia toku dát – substitúcie inštrukcií, permutácie inštrukcií, substitúcie premenných, integrácia kódu a vkladanie takzvaných zbytočných inštrukcií, ktoré neovplyvňujú správanie sa programu
- Obfuskácia rozloženia – zdrojového kódu, alebo aj binárneho kódu (napr. zmena názvu funkcií)
- Preventívna obfuskácia – chráni pred dekompilátormi a debuggermi

Výhody obfuskácie [11]:

- Pomáha chrániť intelektuálne vlastníctvo čiastočným obmedzením alebo znemožnením reverzného inžinierstva a čítania programu.
- Zmenšenie veľkosti programu odstránením bielych miest.
- Pomerne jednoduchá technológia.

Nevýhody obfuskácie [11]:

- Vďaka obfuskácii je možné ukryť v programe škodlivý kód.
- Niektoré antivírusové programy hlásia obfuskované webové stránky ako potenciálne škodlivé, aj keď neobsahujú žiaden škodlivý kód.

D. Polymorfizmus


Polymorfizmus je vlastne vyššia úroveň enkrypcie. Zopár popredných tvorcov vírusov sa rozhodlo, že jediným spôsobom ako úspešne zakryť zašifrovaný vírus pred skenerom je náhodne meniť šifrovaciu/dešifrovaciu funkciu vírusu [8]. Pri každom štarte vírusu môže vírus zmeniť používaný náhodný generátor čísel, dĺžku používaného čísla (volaného kľúč), počet enkryptovaných bajtov a miesto v súbore, na ktorom je uložená šifrovacia funkcia. Celý tento proces je nazývaný polymorfizmus. Po predstavení prvého polymorfického vírusu sa táto metóda začala využívať čoraz častejšie, čo spôsobilo prvé veľké problémy pre antivírusový priemysel, najmä pre nedostatok konštantných bajtov, čo zapríčinilo vysoké riziko falošných pozitív a falošných negatív. Postupom času sa však ukázalo, že aj keď polymorfne vírusy menia svoj výzor v každej svojej iterácii pomerne náhodne, v počítačovom svete úplná náhodnosť neexistuje a spoľahlivý podpis vírusu sa dá vypočítať aj v náhodne vyzerajúcom kóde, len je to omnoho náročnejšie [8], [9]. Spočiatku niektoré antivírusové produkty riešili tento problém tým, že sa snažili do svojej databázy zahrnúť všetky možné signatúry, ktoré sa dali vyprodukovať z rôznych kópií vírusu. Toto riešenie sa veľmi rýchlo stalo nepoužiteľným, keď že jeden vírus dokáže vyprodukovať miliardy rozdielnych kópií seba samého. Výskumné tímy získali lepšie výsledky, keď sa naučili ako funguje jednotlivé šifrovanie vírusov a následne dešifrovali každý skúmaný súbor s použitím reverzného inžinierstva šifrovacieho algoritmu. Toto však zaberalo veľa času a skenery sa tak stávali omnoho pomalšími, keď že každý súbor potrebovali otestovať pomocou veľkého počtu šifrovacích funkcií.

Najúspešnejšie skenery používajú emulátor, ktorý dočasne nahrá skenované súbory do chránenej oblasti v pamäti, ktorá simuluje OS [10]. Vírus si tým pádom myslí, že je spustený a dekryptuje sa, aj keď nemá prístup k žiadnej časti počítača

mimo emulovaného prostredia. Dekódovaný vírus je potom skenovaný antivírusovým programom. Najväčšou výhodou tejto metódy je, že stačí jeden podpis vírusu na detekciu jeho všetkých možných kópií. V dnešnej dobe existuje nespočetné množstvo šifrovacích polymorfických mechanizmov, ale dobrý antivírusový program by ich mal vedieť všetky detegovať.

E. Metamorfizmus

Metamorfické vírusy sa dokážu kompletne meniť tým, že sa šíria ďalej. Rozdiel oproti polymorfickým vírusom je ten, že metamorfické vírusy nie sú nutne závislé na využívaní šifrovania a teda nemajú žiadnu konštantnú časť tela [8]–[10]. Tieto vírusy využívajú najmä metódy obfuskácie na svoju transformáciu a po úprave svojho kódu sa znova skompilujú, čím vytvoria novú generáciu, ktorá bude vyzerat úplne inak ako jej predchodca (viď obrázok 2). Ilustrácia zmeny podoby metamorfického vírusu sa nachádza na obrázku nižšie. Jednotlivé časti metamorfického vírusu sa môžu zväčšovať, prípadne zmenšovať kvôli využívaniu metód obfuskácie kódu. Táto technika je nebezpečnejšia pre platformy ako napríklad Linux, kde je kompilátor pre jazyk C bežne nainštalovaný už v základnom balíku OS, aj keď sa systém nepoužíva na vývoj aplikácií.



Obr. 2. Názorná ukážka zmeny vzhľadu metamorfického vírusu

F. Stealth

Niektoré vírusy obsahujú špeciálne naprogramované inštrukcie, ktoré majú zmiest, prípadne odľakať pozornosť antivírusových expertov, prípadne nástrojov. Jednou z najpoužívanejších metód je odstránenie vírusu zo súboru, keď je súbor skenovaný [10], [11]. Ak je vírus uložený v pamäti, môže pracovať ako medzičlánok medzi používateľom a operačným systémom a teda skryť svoju prítomnosť upravením dotazu, prípadne zmenou odpovedí od systému. Stealth technológia pre systém DOS zažila znovuzrodenie v podobe rootkitov pre operačné systémy Windows.

III. DETEKCIA DYNAMICKÝCH AV METÓD

Medzi moderné metódy ukrývania malvéru pred detekciou AV softvérom patria aj metódy, ktoré sa snažia využívať nedokonalosti, prípadne vlastnosti prostredia a prostriedkov na detekciu malvéru. Tieto metódy sa snažia odhaliť prítomnosť emulátorov, alebo virtualizácie, ktorá je bežne využívaná na dynamickú detekciu malvéru. Tieto metódy, alebo nástroje sa väčšinou snažia zamedziť spusteniu malvéru v prípade, ak je detekované ich spustenie pod virtuálnym systémom. Týmto prístupom sa môže malvér vyhnúť automatickej detekcii, ale aj znemožniť analýzu malvéru výskumníkmi, ktorí sa snažia analyzovať škodlivý kód programu. Avšak množstvo produkčných

systémov v dnešnej dobe využíva virtualizáciu, teda moderný malvér sa nesnaží len odhaliť prítomnosť virtualizácie, ale väčšinou sa snaží zistiť, či ide o reálny systém vo virtuálnom prostredí, alebo ide len o emulátor, prípadne systém určený na analýzu malvéru [13].

A. Spôsoby detekcie virtualizácie

V dnešnej dobe existuje množstvo nástrojov určených na vytvorenie virtuálnych strojov založených na hardvérovej virtualizácii na fyzickom zariadení. Najznámejšie nástroje sú [10]:

- Microsoft Virtual PC,
- Oracle VM VirtualBox,
- Parallels Desktop,
- VMware.

Detekcia virtuálneho stroja často závisí na použitej implementácii, keďže každý z uvedených nástrojov má svoje špecifiká, ktorými sa líši od reálneho hardvérového stroja [10]. Teda detekciu virtuálnych strojov možno rozdeliť podľa ich vlastností, ktorými sa odlišujú od fyzického stroja čo sa týka hardvéru aj softvéru.

Jedným zo spôsobov detekcie virtuálnych strojov, ktorý sa nedá zaradiť medzi vyššie spomenuté oblasti, patrí detekcia na základe porovnávania časov vykonávania rôznych úloh v rôznych prostrediach. Táto detekcia funguje na fakte, že fyzický stroj bude stále vykonávať úlohy o kúsok rýchlejšie ako virtuálny stroj, keďže samotná virtualizácia má svoje náklady. Malvéru teda stačí porovnať čas vykonávania úlohy na konkrétnom stroji oproti vykonávaniu na fyzickom zariadení. Ako referenčné zariadenie sa často využíva externý zdroj aby sa zabránilo možnému podávaniu falošných časov behov programu virtuálnym prostredím, čo je bežnou praxou pri využívaní emulátorov [14]. Ak sú dané časy veľmi odlišné, tak sa s veľkou pravdepodobnosťou jedná o virtuálny stroj a nie reálny stroj.

B. Detekcia na báze hardvéru

Joanna Rutkowska v roku 2004 predstavila nový spôsob detekcie virtualizácie na základe vykonania jedinej inštrukcie, ktorý nazvala Red Pill [15]. Príkladom pre takúto inštrukciu môže byť nasledujúci kód:

```
bool RedPill () {
    unsigned char x[2+4],
    rp[] = "\x0f\x01\x0d\x00\x00\x00\xc3";
    *((unsigned*)&rp[3]) = (unsigned)x;
    ((void(*)())&rp)();
    return (x[5]>0xd0) ? 1 : 0;
}
```

Tento kód deteguje virtuálne prostredie na báze využívania SIDT inštrukcie, ktorej funkciou je ukladanie obsahu IDTR registra. Vykonávanie tejto inštrukcie nie je podmienené privilegovaným módom, no napriek tomu vracia obsah citlivého registra využívaného operačným systémom interne. Fyzický stroj má iba jeden takýto register, na ktorom sú spustené dva operačné systémy. Kvôli tomu je nutné aby virtuálny stroj presmeroval IDTR register host'ovského OS na inú adresu ako je pôvodná adresa tohto registra. Vyššie uvedený fragment

kódu deteguje túto zmenu a preto je možné pomocou neho detegovať spustenie programu vo virtuálnom prostredí.

Na podobnom princípe sú založené aj ostatné metódy detekcie virtuálnych strojov. Ďalšie možné spôsoby detekcie virtuálnych strojov na základe odchýlok oproti fyzickým strojom sú napríklad [15]:

- Kontrola artefaktov OS,
- kontrola ovládačov,
- kontrola artefaktov pamäte,
- kontrola špecifických zariadení.

Jedným zo spôsobov odhal'ovania virtuálnych strojov malvérom je testovanie vykonávania špecifickej inštrukcie pre konkrétne CPU, o ktorej je známe, že jej vykonávanie je v reálnom CPU chybné. Tieto informácie sú väčšinou verejne dostupné, teda implementácia takého testu nie je náročná, keďže stačí len správne identifikovať CPU. V prípade ak sa jedná o virtualizáciu, tak je daná inštrukcia vykonaná správne a teda je jednoduché identifikovať, že sa jedná o virtuálny stroj.

Ďalším spôsobom identifikácie virtuálnych strojov je identifikácia špecifických ovládačov pre konkrétny virtuálny stroj. Ako bolo spomenuté, mnohé virtuálne stroje využívajú špecifické ovládače na adaptáciu virtuálneho stroja hosťiteľ'skému stroju. Tieto ovládače (prípadne ich názvy, sériové čísla, ...) sa nezvyknú meniť v rámci jednej implementácie virtuálneho stroja, teda ich identifikácia je pomerne jednoduchou záležitosťou.

Využívanie artefaktov pamäte na odhalenie virtuálnych strojov spočíva najmä v zistení rozdielov v adresovaní pamäťových buniek pre špecifické štruktúry pamäte. Väčšinou ide o testovanie, či sa špecifická pamäťová štruktúra fyzicky nachádza na rovnakom mieste ako by sa mala nachádzať na fyzickom stroji. Príkladom na takúto zistenie virtualizácie môže byť už spomínaná inštrukcia Red Pill. Existuje veľa takýchto nástrojov pre rôzne implementácie virtuálnych strojov, pomocou ktorých sa dá odhaliť virtualizácia.

Rôzne implementácie virtuálnych strojov väčšinou obsahujú špecifické hardvérové zariadenia, ktoré zanechávajú v operačnom systéme stopy. Môže ísť o špecifické názvy zariadení (napr. ovládače pre sieťové alebo grafický adaptér), špecifické sériové čísla, alebo adresy, ktoré sú typické pre konkrétnu implementáciu virtuálneho stroja. Malvér môže následne vyhľadať tieto špecifické hodnoty kľúčov v registroch a na základe toho dokáže identifikovať prítomnosť konkrétnej virtualizácie. Rôzne verzie a typy virtuálnych strojov môžu obsahovať rôzne takéto špecifické hodnoty. Samozrejme, existuje veľa voľne dostupných metód a nástrojov na detekciu a identifikáciu týchto špecifických hodnôt pre rôzne virtuálne stroje.

C. Detekcia na báze softvéru

Detekcia na báze softvéru spočíva vo vyhľadávaní špecifických softvérových odtlačkov, ktoré zanechávajú konkrétne virtuálne stroje. Príkladom takejto detekcie je prehľadávanie diskového priestoru alebo registrov za účelom nájdania známej lokality, ktorá je využívaná virtualizačným softvérom. Tieto

lokality môžu obsahovať známe hodnoty, vďaka ktorým je možné s istotou identifikovať virtuálny stroj.

Ďalším spôsobom ako možno identifikovať virtualizáciu je prechádzanie spustených služieb a procesov v operačnom systéme. Virtuálne systémy väčšinou využívajú pomocné služby a procesy, ktoré zabezpečujú bezproblémový chod v rámci hosťovského operačného systému, prípadne komunikáciu s hosťovským operačným systémom. Tieto služby a procesy sa dajú pomerne jednoducho nájsť a identifikovať. Účinným spôsobom ochrany voči tomuto spôsobu je zmena názvov týchto služieb a procesov.

D. Detekcia emulátorov

V prípade detekcie emulátorov sa často využívajú rozdiely oproti reálnemu operačnému systému. Pre malvér stačí detegovať tieto rozdiely v správaní, prípadne detegovať absenciu niektorých komponentov reálneho operačného systému (napríklad špecifické knižnice, ktoré často nie sú implementované v emulovaných systémoch). Pre úplné systémové emulátory by však malo platiť, že ich správanie by malo presne emulovať správanie reálneho operačného systému (včítane všetkých knižníc, procesov, služieb, ...). Teda toto by malo znamenať, že vykonanie jedného súboru inštrukcií by malo vrátiť rovnaké výsledky ako vykonanie toho istého súboru inštrukcií na reálnom systéme. V princípe sú však emulátory nedokonalé a teda sa dajú nájsť rozdiely medzi vykonávaním programu pod emulátorom a pod reálnym systémom a na základe toho sa dá detegovať prítomnosť emulátora [?].

Detekcia úplného systémového emulátora je veľmi podobná detekcii virtuálneho systému. Jedným zo spôsobov detekcie je využívanie chýb CPU a teda posielanie modelovo-špecifických inštrukcií za účelom odhalenia, či je inštrukcia spracovaná správne, alebo chybné ako by to malo byť na reálnom CPU daného typu. Väčšina emulátorov neimplementuje špecifické emulácie CPU aj s ich chybami, teda preto je možné pomerne ľahko týmto spôsobom odhaliť emuláciu, keďže zoznam týchto chýb je verejne prístupný. Tak isto sa dajú využiť aj metódy pre detekciu registrov, prípadne špecifických hardvérových komponentov.

Špecifickou metódou na detekciu emulátorov je detekcia behu programu. Táto metóda je, na rozdiel od podobnej metódy pri virtuálnych strojoch, založená na fakte, že emulácia inštrukcie často nevykonáva, ale len simuluje ich vykonávanie, teda napríklad inštrukcia *Sleep* reálne nespomalí vykonávanie programu, emulátor ju preskočí. Moderné emulátory tieto inštrukcie síce emulujú, no reálne ich nevykonávajú (z dôvodu šetrenia času a prostriedkov). V prípade tejto inštrukcie vracajú len čas behu programu inkrementovaný o čas, ktorý sa mala táto inštrukcia vykonávať. Toto sa dá detegovať pomerne jednoducho, keďže stačí porovnať čas behu programu z emulátora oproti reálnemu času, ktorý uplynul.

IV. EXPERIMENTY S RÔZNYMI METÓDAMI PRE SKRYTIE MALVÉRU

Hlavnou úlohou antivírusových systémov je schopnosť odhaliť malvér. S evolúciou antivírusových systémov sa začal

vyvíjať aj škodlivý softvér, ktorý sa okrem infekcie a škodlivej činnosti snaží taktiež uniknúť odhaleniu. S vývojom statických analyzátorov prišli vývojári vírusov na to, že ideálnym spôsobom ako sa skryť pred odhalením antivírusovým skenerom je znemožniť tvorbu identifikačných reťazcov z kódu vírusu. To dosahujú s použitím rôznych metód. Niektoré metódy boli prelomené a bezpečnostní analytici dokázali z malvéru vyprodukovať identifikačné reťazce, ale malvér skrytý inými metódami sa nepodarilo identifikovať s použitím statickej analýzy.

Vtedy začali poprední tvorcovia antivírusových systémov využívať na identifikáciu aj dynamickú analýzu správania sa malvéru. Táto analýza sa ukázala byť veľmi úspešná, keďže dokáže odhaliť všetky škodlivé programy. S implementáciou tejto metódy do komerčných antivírusových softvérov sa začala nová éra tvorby vírusov. Tie využívajú metódy na skrytie pred statickými skenermi, ale zároveň sa snažia odhaliť prebiehajúcu dynamickú analýzu správania a zmeniť svoje správanie, keď sú analyzované. Identifikácia toho, či je malvér analyzovaný je pomerne jednoduchá záležitosť, keďže analýza je spúšťaná v bezpečnom, virtuálnom prostredí. To so sebou nesie množstvo obmedzení oproti reálnemu operačnému systému, ktoré sa dajú využiť na identifikáciu analýzy. Samozrejme, nejde len o detekciu obyčajného virtuálneho systému, keďže veľa serverov v dnešnej dobe funguje na báze virtuálnych systémov. Virtuálne systémy využívané antivírusovým softvérom sú často riadne orezané verzie operačných systémov, ktoré majú len základnú podporu, ktorá je nevyhnutná pre detekciu malvéru.

Keďže táto práca sa venuje hybridnej analýze, bol vykonaný praktický experiment na overenie týchto informácií. Experiment má dokázať zraniteľnosť antivírusových systémov, ktorá spočíva vo vyhnutí sa analýze správania sa malvéru. V rámci experimentu sa testovali rôzne metódy, pri ktorých bola vyhodnotená ich úspešnosť.

Ako referenčný prostriedok na skenovanie antivírusmi bol zvolený portál VirusTotal (<https://www.virustotal.com>), ktorý poskytuje možnosť overiť podozrivý súbor s pomocou viacerých antivírusových programov, včítane všetkých dominantných programov na trhu. Tento portál je taktiež zaujímavou možnosťou ako si overiť jednotlivé spôsoby obchádzania antivírusového softvéru. Jednotlivé pokusy budú hodnotené formou skóre, ktoré znamená počet jednotlivých antivírusových programov, ktoré detegovali škodlivú zložku programu z celkového počtu antivírusových programov, ktoré daný program overovali.

Pre testovacie účely bol potrebný kód, ktorý by bol považovaný za malvér. Jednoduchou cestou bolo použiť nálož z Meterpreteru z frameworku Metasploit. Tento kód je považovaný za škodlivý, keďže ide o kód, ktorý má testovať zabezpečenie systému [17].

Ako prvý test bol kód jednoducho zašifrovaný a odoslaný na testovanie za účelom zistiť, že koľko antivírusových programov využíva dynamickú analýzu. Hlavná časť programu vyzerala nasledovne:

```
|| int main(void)
```

```

{
    decryptCode(); // Dekryptovanie kódu
    startShellCode(); // Zavolanie kódu
    Meterpreteru v dekryptovanom kóde
    return 0;
}

```

Táto verzia kódu je detegovaná antivírusovými skenermi a má VirusTotal skóre 12/55. Toto dokazuje, že novodobé antivírusové programy sa stále viac spoliehajú na dynamickú analýzu, aj keď to ešte nie je väčšina z nich.

Ďalším cieľom bolo skúsiť jednotlivé metódy, ktorými by sa dalo vyhnúť detekcii škodlivého kódu so 100% úspešnosťou. Jednotlivé metódy a ich úspešnosť možno vidieť v Tabuľke I.

Metóda	Úspešnosť detekcie
Alokovanie 100MB pamäte	0/55
100 miliónov inkrementácií	0/55
Pokus o otvorenie systémového procesu	11/55
Otvorenie neexistujúcej URL	2/55
Využitie informácií o používateľovi	0/55
Pokus o použitie knižnice NUMA	0/55
Skontrovanie pamäte procesov	1/55
Skontrovanie názvu súboru	0/55

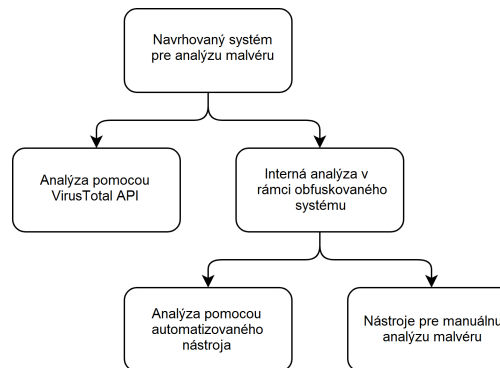
Tabuľka I

POKUSY S RÔZNYMI METÓDAMI O SKRÝVANIE ŠKODLIVÉHO KÓDU

V. NÁVRH RIEŠENIA

Ako bolo dokázané praktickými pokusmi, stále existujú metódy, pomocou ktorých sa dá obfuskovať malvér aby nebol odhaliteľný statickými metódami analýzy malvéru a taktiež metódy, ktoré zabraňujú úspešnej analýze správania malvéru v rámci sandboxov. Tieto nedostatky sa vyskytujú v rámci AV systémov na základe ich vstavaných obmedzení aby nečerpali príliš veľa systémových prostriedkov používateľa a teda boli čo najmenej rušivé. Avšak pre analýzu takto špecifického malvéru je nutné využívať iné metódy, prípadne alokovať viacero systémových prostriedkov aby bola dosiahnutá vyššia miera detekcie.

Základom pre navrhované riešenie je využívanie virtuálneho systému, keďže množstvo malvéru v dnešnej dobe nekontroluje prítomnosť virtualizačných nástrojov z dôvodu, že mnoho serverov funguje na virtuálnych strojoch a môžu byť pre útočníka perspektívnym cieľom (či už kvôli dátam, ktoré sa v ňom vyskytujú, alebo využívaním ako prostriedkov na šírenie malvéru, spamu, alebo na vykonávanie inej škodlivej činnosti). Samozrejme, virtuálny stroj musí byť dostatočne obfuskovaný aby sa tváril ako reálne používaný systém a teda nebol ľahko detegovateľný malvérom (napr. kontrolou histórie prehliadania, registrov, atď.). Pre známy malvér je implementované rozhranie kontroly cez službu VirusTotal.com, ktorá poskytuje API pre rýchlu kontrolu súborov pomocou väčšiny dostupných AV systémov. Ak malvér nie je detegovaný cez API, je možné použiť pokročilé metódy, pomocou ktorých sa dá potencionálne škodlivý súbor preskúmať do detailu a zistiť akékoľvek nežiadúce správanie. Náčrt rozdelenia navrhovaného riešenia je možné vidieť nižšie na obrázku 3.



Obr. 3. Náčrt rozdelenia navrhovaného riešenia

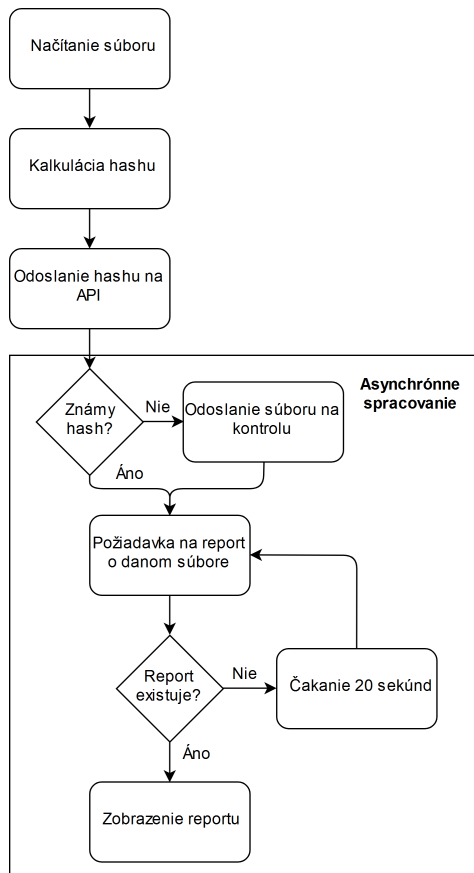
A. VirusTotal API

Služba VirusTotal poskytuje API pre kontrolu súborov a generovanie reportov pre využívanie v aplikáciách. Komunikácia prebieha pomocou HTTP protokolu a dáta sú posielané v JSON formáte. Pre používanie API je potrebné získať API kľúč, ktorý je zaslaný používateľovi po úspešnej registrácii. Na testovanie je možné odoslať súbor, alebo len hash súboru (md5/sha1/sha256). Ak sa odošle len hash súboru, tak sa zisťuje, či už daný súbor bol v minulosti kontrolovaný a ak sa nájde zhoda, tak server odošle report ako odpoveď. Ak však daný súbor nebol kontrolovaný, tak v tom prípade príde negatívna odpoveď zo servera a je nutné odoslať súbor na skenovanie. Pri odosielaní súboru na skenovanie je súbor zaradený do fronty na skenovanie, pričom má nízku prioritu (keďže sa nejedná o volanie z portálu VirusTotal.com). Je možné získať vyššiu prioritu aj kvótu na počet skenovaných súborov (základná kvóta sú 4 súbory za 1 minútu) pomocou zaslania odôvodnenej žiadosti na portál VirusTotal. Výhodou posielania hashu súboru je rýchlosť odpovede, keďže spracovanie požiadavky nečaká vo fronte, ale zároveň nevýhodou je negatívna odpoveď pre neznáme súbory. Navrhované riešenie je využiť kontrolu cez hash súboru a v prípade neznámeho súboru je súbor zaslaný na kontrolu. Toto riešenie znižuje zaťaženie siete a zároveň urýchľuje zobrazenie výsledkov kontroly v prípade známeho súboru. Náčrt využitia VirusTotal API možno vidieť na obrázku 4.

B. Interná analýza

Ako už bolo spomenuté, tvorcovia malvéru sa v súčasnosti zameriavajú najmä na detekciu reálnosti prostredia a nie na detekciu virtualizácie, keďže tá sa veľmi často využíva v produkčnej sfére. Väčšinou sa takto špecifický malvér snaží odhaliť, či je spúšťaný v reálnom systéme, alebo je spúšťaný v sandboxe, prípadne pod neúplnou, alebo čerstvou inštaláciou systému. Medzi bežné metódy zamerané na odhalenie reálnosti prostredia patria:

- Testovanie, či kurzor myši nezostáva po celý čas v strede obrazovky - bežný jav pri sandboxoch.
- Testovanie pripojenia na internet - na základe odpovedí pre existujúce/neexistujúce portály.



Obr. 4. Náčrt využitia VirusTotal API

- Kontrola nízkeho počtu bežiacich procesov, histórie, registrov, ...

Množstvo sadoxov sa však vďaka týmto testom snaží simulovať správanie reálneho používateľa. Kvôli tomu moderný malvér využíva oveľa efektívnejší spôsob detekcie reálnosti prostredia a to metódu využívania artefaktov opotrebovania systému. Tieto artefakty operačný systém nadobúda z hľadiska dlhodobého používania systému. Miera úspešnej detekcie reálneho prostredia dosahuje až 92,86%. Artefakty opotrebovania systému sa dajú rozdeliť do nasledujúcich skupín:

- Artefakty disku,
- artefakty siete,
- artefakty systémových registrov,
- systémové artefakty.

Tieto artefakty sa nachádzajú v systéme Windows, ktorý bol vybraný na základe skutočnosti, že sa jedná o najčastejšie infikovaný systém. Zoznam väčšiny artefaktov, podľa ktorých sa dá detegovať reálnosť systému je možné vidieť v tabuľke II.

Pri hĺbkovej analýze malvéru sa v systémoch na to určených najviac dbá na nasledujúce aspekty:

- Efektívnosť,
- podporu nástrojov,
- prispôbitelnosť,
- transparentnosť.

Katégoria	Názov
Artefakty disku	desktopFileCount miniDumpCount miniDumpSize recycleBinCount recycleBinSize tempFilesCoimt tempFilesSize thumbsFolderSize
Artefakty siete	ARPCacheEntries certUtilEntries dnsCacheEntries tcpConnections wirelessnetCount
Artefakty sys. registrov	autoRunCount deviceClsCount fireruleCount MUICacheEntries orphanedCount regSize shimCacheCount totalActiveSetup totalAppPaths totalMissingDlls totalSharedDlls USBStorCount uninstallCount usrassistCount
Systémové artefakty	appdiffdays appevt appsrc sysdiffdays sysevt syssrc totalProcesses winupdt

Tabuľka II: Prehľad artefaktov opotrebovania systému

Efektívnosť je spojená s alokáciou zdrojov pre požiadavky analýzy malvéru, teda napríklad požiadavky na efektívnu bisekciu a binárny preklad kódu malvéru v prostredí.

Podpora nástrojov znamená jednoduchosť pridania ďalších nástrojov pre analýzu malvéru do existujúceho prostredia. Toto môže byť obzvlášť problémom pri sandboxoch a uzavretých systémoch, kedy sa používateľ musí spoliehať len na existujúce nástroje a reporty.

Prispôbitelnosť sa dá vysvetliť ako schopnosť systému zmeniť svoje správanie a prispôbiť analýzu konkrétnemu druhu skúmaného malvéru, keďže malvér sa môže prezentovať rôzne a často je potrebné sa zamerať na úzku časť systému pri analýze.

Transparentnosť je vlastnosť prostredia na analýzu malvéru, vďaka ktorej by mal systém zostať pred malvárom

skrytý a nedetegovateľný, aby sa malvér nesnažil zmarit' úspešnosť analýzy pri detekcii prostredia.

Na základe týchto skutočností bude riešenie založené na hardvérovej virtualizácii s reálnym operačným systémom. Toto riešenie je najviac transparentné (okrem riešenia bare-metal, ktoré má však množstvo iných nevýhod) a zároveň je rýchlejšie oproti emulovanému hardvéru. Zároveň toto riešenie poskytuje dobrú obnoviteľnosť do pôvodného stavu a možnosť použitia operačného systému bez limitovania ich funkcií. Tieto skutočnosti výrazne uľahčujú analýzu malvéru zameraného na detekciu reálnosti operačného systému. Hardvérová virtualizácia je detegovateľná malvérom, ale počet malvéru, ktorý je zameraný na jej detekciu výrazne klesá a je predpoklad, že bude klesať aj naďalej z dôvodu, že stále väčšie množstvo IT riešení obsahuje istú formu tejto virtualizácie (cloudy, servery, vzdialené desktopy, atď.).

Virtualizácia ako taká prináša množstvo výhod pri analýze malvéru a značne uľahčuje a urýchľuje tento proces. Súčasný trend v oblasti tvorby malvéru je detekcia reálnosti prostredia, teda navrhované riešenie je zamerané na obfuskáciu prostredia a jeho detekcie na základe opotrebenia systému. Ako bolo spomenuté, riešenie je založené na hardvérovej virtualizácii, s reálnym operačným systémom s čo najmenšími úpravami, keďže hardvérová virtualizácia je značne rýchlejšia oproti emulovanému hardvéru a prináša množstvo výhod. Hardvérová virtualizácia taktiež umožňuje používať reálne operačné systémy a umožňuje vytváranie snímok OS pre jednoduché obnovenie systému do pôvodného stavu pred spustením malvéru. Tieto skutočnosti výrazne uľahčujú analýzu malvéru.

Vďaka využívaniu reálneho operačného systému nie je potrebné maskovať niektoré artefakty opotrebenia, keďže systém ako taký ich už implementuje. Ďalšou možnosťou je využívať obraz už existujúceho systému, ktorý eliminuje nutnosť obfuskácie ďalších artefaktov oproti čistej inštalácii systému. Príkladom týchto artefaktov sú:

- Artefakty disku:
 - miniDumpCount
 - miniDumpSize
- Systémové artefakty:
 - appevt
 - appsrc
 - syssrc
 - totalProcesses
 - winupdt

Keďže systém Windows je robustný a veľmi komplexný, táto práca je zameraná na najdôležitejšie artefakty opotrebenia systému, ktoré najviac vplyvávajú na celkové hodnotenie reálnosti systému z hľadiska využívania reálnym používateľom. Konkrétne je aplikácia zameraná na tieto artefakty:

- Artefakty disku:
 - desktopFileCount
 - recycleBinCount
 - recycleBinSize
 - tempFilesCount
 - tempFilesSize

- tempFolderSize
- thumbsFolderSize
- Artefakty internetového prehliadača:
 - browserNum
 - cookieDiffDays
 - totalCookies
 - totalTypedURLs
 - uniqueCookieDomains
 - uniqueURLs
 - urlDiffDays
- Artefakty systémových registrov:
 - autoRunCount
 - MUICacheEntries
 - orphanedCount
 - regSize
 - totalAppPaths
 - totalMissingDlls
 - totalSharedDlls
 - uninstallCount
 - USBStorCount

Nástroj taktiež obsahuje funkciu na zisťovanie a zmenu času a dátumu inštalácie systému Windows, keďže daný dátum je úzko spätý s niektorými artefaktmi a ak je dlhodobý konštantný, môže to viesť k narušeniu reálnosti systému.

Tento nástroj je vyvinutý v objektovo orientovanom programovacom jazyku C#, ktorý je priamo určený na vývoj aplikácií pre prostredie Windows a obsahuje množstvo knižníc, ktoré uľahčujú prístup k registrom a iným častiam operačného systému za účelom jeho zahmlievania. Aplikácia bude rozdelená do troch modulov, pričom každý z týchto modulov bude reprezentovať jednu oblasť artefaktov. Každý modul bude reprezentovaný statickou triedou, keďže nie je nutné vytvárať objekty, ktoré by museli existovať v pamäti dlhodobo, pri zmenách, ktoré sa budú vykonávať v systéme. Taktiež sa budú využívať prevažne statické metódy na zahmlievanie jednotlivých artefaktov opotrebenia systému. Popri tom bude aplikácia obsahovať aj pomocné triedy na zabezpečenie jednotlivých funkcionalít.

C. Zahmlievanie artefaktov disku

Prvý implementovaný modul slúži na zahmlievanie artefaktov opotrebenia disku. Tento modul je zodpovedný za zahmlievanie súborov koša, pracovnej plochy, systému a systémových náhl'adov.

Dočasné súbory sú perfektným indikátorom opotrebenia systému, keďže vznikajú pri bežnej práci používateľa so systémom. Implementácia zahmlievania týchto artefaktov spočíva v generovaní rôznych dočasných súborov s variabilnou veľkosťou a obsahom. Tieto vygenerované súbory budú rôzneho typu (textové súbory, obrázky, dokumenty MS Office, ...). Takto by sa mali zahmlieť artefakty *tempFilesCount*, *tempFilesSize* a *tempFolderSize*. Tieto dočasné súbory budú vygenerované v priečinku:

```
|| %USERPROFILE%\AppData\Local\Temp
```


Samozrejme, tieto vygenerované súbory budú mať variabilnú veľkosť, čas vytvorenia, čas poslednej úpravy a prístupu, aby sa čo najviac približovali reálnemu používaniu systému. Tieto časy sa generujú s dôrazom na čas inštalácie systému, aby sa nestalo, že tento dočasný súbor bol vytvorený pred dátumom inštalácie systému. Taktiež je nutné dodržanie logickej nadväznosti dátumov vytvorenia, poslednej úpravy a čítania zo súboru pri generovaní týchto súborov. Tieto súbory budú mať globálne univerzálne jedinečné identifikátory, v tvare 128 bitových čísel, keďže mnoho aplikácií využíva pri generovaní dočasných súborov práve tieto názvy. Ďalším možným spôsobom na generovanie názvov, ale aj obsahu týchto dočasných súborov je využitie online slovníka anglických slov, z ktorého sa budú čerpať náhodné slová na tvorbu viet. Týmto prístupom sa zvýši reálnosť vygenerovaných súborov. V prípade neúspešného pripojenia nástroja na internet bude využitý interný generátor náhodných slov, ktorý však na rozdiel od online slovníka nebude generovať zmysluplné slová (hlavne kvôli nutnosti implementácie databázy slov, ktorá je veľmi rozsiahla).

Ďalším bežným javom, z dlhodobého hľadiska, pri práci s počítačom je pribúdanie súborov na pracovnej ploche. Tieto súbory sa budú zahmlievat' podobne ako artefakty dočasných súborov, avšak budú pozostávať z obrázkov, dokumentov kancelárskych balíkov a textových súborov. Taktiež ich názvy budú odlišné od dočasných súborov, keďže používateľ väčšinou dáva týmto súborom zmysluplné názvy a nie náhodne vygenerované 128 bitové reťazce pozostávajúce z písmen a čísel. Na generovanie názvov súborov sa teda využije online slovník, ktorý zabezpečí ich reálnosť. Rovnako ako pri generovaní dočasných súborov, budú mať tieto súbory rôzne veľkosti a dátumy vytvorenia, úprav a prístupu. Tieto dátumy budú taktiež podliehať rovnakým logickým obmedzeniam ako dočasné súbory. Takto by sa mal zahmlieť artefakt *desktopFileCount*.

Pre zahmlievanie súborov, ktoré boli vymazané (súbory v koši) sa bude využívať implementácia generovania súborov pracovnej plochy, keďže tieto súbory by mali v reálnom prostredí byť vytvorené používateľom a následne odstránené a reálny používateľ často neodstraňuje systémové, alebo dočasné súbory. Teda v tomto prípade sa súbory po ich vygenerovaní hneď presunú do koša, čo je jediným rozdielom oproti implementácii popísanej vyššie. Týmto spôsobom sa výrazne skrátí implementačný čas tejto časti. Počet vygenerovaných súborov by mal korešpondovať s priemerným počtom a veľkosťou súborov v koši bežného používateľa. Týmto prístupom by sa mali zahmlieť artefakty *recycleBinCount* a *recycleBinSize*.

Ďalším artefaktom opotrebenia systému sú súbory systémových náhľadov. Jedná sa prakticky o cache súbory, ktoré urýchľujú načítanie priečinkov po ich otvorení používateľom. Tieto súbory sa vytvárajú pri prvom otvorení konkrétneho priečinka, teda práve preto sa jedná o jeden z dôležitých artefaktov opotrebenia systému. Zahmlievanie týchto súborov sa bude vykonávať generovaním súborov v priečinku náhľadov, ktorý sa nachádza v:

```
||%LOCALAPPDATA%\Microsoft\Windows\Explorer\
```

Tieto súbory majú len dve možnosti pre ich názov a to buď *thumbcache_zzz.db*, alebo *iconcache_zzz.db*, pričom zzz je reťazec čísel určený na identifikáciu rôznych cache súborov. Názvy týchto vygenerovaných súborov teda budú zložené z náhodne vybranej možnosti s náhodne vygenerovaným číslom. Takto sa teda bude zahmlievat' artefakt *thumbsFolderSize*.

D. Zahmlievanie artefaktov internetového prehliadača

Tento modul je zodpovedný za zahmlievanie artefaktov internetového prehliadača. Vybraný prehliadač na zahmlievanie je Mozilla Firefox, na základe osobných preferencií, keďže výber prehliadača nemá žiaden vplyv na vyhodnotenie reálnosti používaného systému. Taktiež je postačujúce zahmlievat' len jeden internetový prehliadač a nie je nutné túto funkciu implementovať pre všetky dostupné prehliadače, keďže bežný používateľ v reálnom prostredí používa väčšinou len jeden internetový prehliadač. Pre budúcnosť však je možné túto funkciu rozšíriť na viacero iných prehliadačov, pre možnosť variability zahmlievania systému. Pre toto využitie je úplne postačujúce zahmlievat' cookies a históriu prehliadača. Konkrétne prehliadač Mozilla Firefox má uložené súbory cookies a históriu prehliadača v databázových SQLite súboroch. Tieto súbory sa nachádzajú v priečinku:

```
||%APPDATA%\Mozilla\Firefox\Profiles\
```

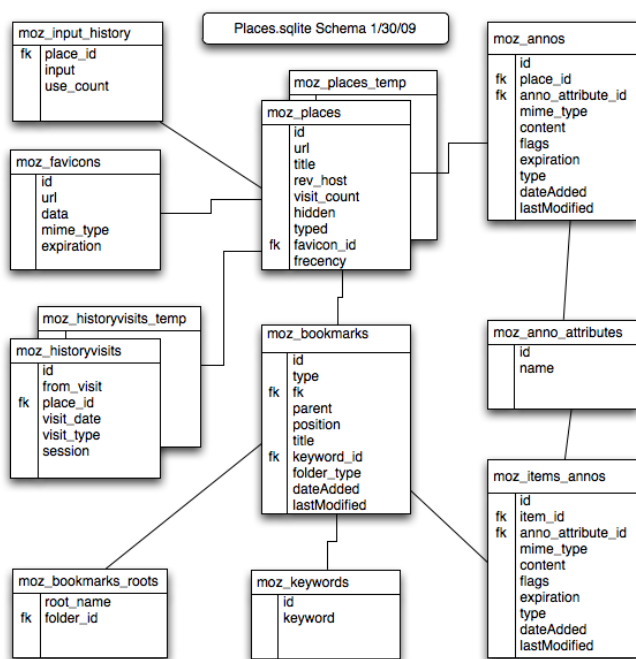
V tomto priečinku sa nachádzajú súbory s názvami *cookies.sqlite* a *places.sqlite*, ktoré obsahujú záznamy cookies a históriu prehliadača.

V tabuľke cookies sa nachádzajú informácie o doméne, na ktorú sú cookies viazané, ich hodnotu, cestu k nim, dátum posledného prístupu, vzniku a expirácie, informácie o pôvode jednotlivých cookies a iné bezpečnostné atribúty cookies. Ich zahmlievanie bude prebiehať vkladaním falošných záznamov do databázového súboru. Názvy jednotlivých cookies a domén pôvodu cookies budú generované pomocou online slovníka a ich hodnota bude náhodný reťazec znakov a čísel. Dátumy vzniku, posledného prístupu a expirácie cookies budú tiež náhodne generované s hľadiskom na dátum inštalácie systému aby sa dodržala logická nadväznosť. Takýmto spôsobom sa budú zahmlievat' artefakty *cookieDiffDays*, *totalCookies* a *uniqueCookieDomains*.

V databázovom súbore *places.sqlite* sa nachádzajú rôzne tabuľky, z ktorých sa bude pracovať s tabuľkami *moz_historyvisits*, *moz_hosts* a *moz_places*. V tabuľke *moz_hosts* sa nachádzajú informácie o jedinečných adresách, ktoré daný používateľ navštívil. Vkladaním záznamov do tejto tabuľky sa budú zahmlievat' artefakty *totalTypedURLs* a *uniqueURLs*. Táto tabuľka obsahuje informácie o daných navštívených adresách, frekvencii návštev, prefixe adries a taktiež informáciu, či adresa bola zadaná používateľom. Zahmlievanie tejto časti bude vykonávané podobne ako zahmlievanie cookies a to generovaním falošných adries pomocou online slovníka. Prefixy adries budú náhodne zvolené zo zoznamu dostupných prefixov a ostatné parametre budú náhodne zvolené.

V tabuľke *moz_places* sa nachádzajú informácie o všetkých navštívených URL adresách, názvoch domén, počte a frekvencii návštev a podobne. Generovanie falošných záznamov v tejto tabuľke bude prebiehať podobne ako v predošlej tabuľke s prihliadnutím na to, že každý záznam v tejto tabuľke musí mať rodiča v predošlej tabuľke. Ostatné údaje budú generované náhodne, prípadne názvy budú generované s využitím online slovníka. Dátumy budú generované s prihliadnutím na dátum inštalácie operačného systému a súčasný dátum a čas.

Záznamy v tabuľke *moz_historyvisits* obsahujú referenciu na záznamy v tabuľke *moz_places*, ako je zobrazené na obrázku 5. Konkrétne záznamy obsahujú informácie o tom, z ktorej URL adresy bola stránka navštívená, dátum a čas návštevy a iné informácie o navštívenej stránke. Tieto záznamy sú ukladané vždy, keď používateľ navštevuje nejaké stránky, s výnimkou návštevy stránok v inkognito móde. Zahmlievanie tejto tabuľky bude prebiehať súčasne so zahmlievaním tabuľky *moz_places*, keďže medzi záznamami existujú väzby pomocou cudzích kľúčov. Toto zahmlievanie bude prebiehať podobne ako zahmlievanie predošlej tabuľky a pomocou neho sa dá pokryť artefakty *totalTypedURLs* a *urlDiffDays*.



Obr. 5. Schéma databázového súboru places.sqlite

E. Zahmlievanie registrov operačného systému

Posledným implementovaným modulom je modul určený na zahmlievanie systémových registrov pre operačný systém Windows. Esenciálnou časťou tohto modulu bude možnosť zistenia a zmeny dátumu inštalácie operačného systému Windows, keďže ako bolo spomenuté v predošlých moduloch, viaceré časti obfuskácie systému sú viazané na tento dátum a zároveň je to jeden z najpodstatnejších artefaktov pri určení opotrebenia systému. Preto je nutné aby bol tento dátum

vhodne zvolený aby operačný systém nepôsobil príliš mlado, ale ani príliš staro. Údaje o dátume a čase inštalácie operačného systému sú uložené v systémovom registri. Cesta ku kľúču tohto registra je:

```
|| HKEY_LOCAL_MACHINE\SOFTWARE\Microsoft\Windows NT\
   CurrentVersion\InstallDate
```

Tento kľúč registra obsahuje číselnú hodnotu vo formáte unix timestamp, teda počet sekúnd, ktoré ubehli od 1.1.1970 00:00:00. Zahmlievanie tejto hodnoty bude prebiehať zadaním dátumu a času v normálnom formáte a následnej konverzii na unixovú časovú stopu, ktorá sa zapíše do daného registra.

Ďalším artefaktom opotrebenia určeným na zahmlievanie sú kľúče registrov programov určených na odinštalovanie softvéru. Väčšina softvéru si ukladá cestu k týmto programom do registrov operačného systému, z dôvodu jednoduchšej správy nainštalovaných programov. Tieto kľúče sa nachádzajú v:

```
|| HKEY_LOCAL_MACHINE\SOFTWARE\Microsoft\Windows\
   CurrentVersion\Uninstall
```

Týmto spôsobom sa budú zahmlievať artefakty *regSize* a *uninstallCount*. Zahmlievanie bude prebiehať vygenerovaním a následným vložením záznamov do daného registra. Konkrétne záznamy budú obsahovať informácie o názve aplikácie, vydavateľovi, verzii, kontakte, dátume inštalácie, ceste k programu určenému na odinštalovanie aplikácie a veľkosti aplikácie. Slovné názvy aplikácie a vydavateľa sa budú generovať pomocou online slovníka, dátum inštalácie bude generovaný z prihliadnutím na dátum inštalácie operačného systému a zvyšné atribúty budú generované náhodne.

Artefakt opotrebenia systému *autoRunCount* je ďalším artefaktom opotrebenia, ktorý bude potrebné zahmlievať. Tento artefakt určuje počet aplikácií, ktoré sa spúšťajú pri štarte systému a je zapísaný v systémovom registri. Cesta k tomuto registru je:

```
|| HKEY_LOCAL_MACHINE\SOFTWARE\Microsoft\Windows\
   CurrentVersion\Run
```

Tento register sa skladá zo záznamov, ktoré obsahujú len informácie o názve aplikácie a ceste k spustiteľnému binárnemu súboru aplikácie, prípadne aj s parametrami pre spustenie aplikácie. Zahmlievanie tohto registra bude prebiehať generovaním záznamov s falošným názvom aplikácie a cestou ku aplikácii pomocou online slovníka. Počet záznamov bude korešpondovať s priemerným počtom záznamov, ktoré sa nachádzajú na priemerne opotrebovanom operačnom systéme.

Podobným spôsobom sa bude zahmlievať aj artefakt *titalAppPaths*, ktorý reprezentuje celkový počet aplikácií a ciest k nim. Obsahom tohto registra sú záznamy o zaregistrovaných aplikáciách v operačnom systéme, ktoré sa skladajú z názvov týchto aplikácií, ciest k nim a nepovinných informácií ako napríklad URL adresy. Cesta k tomuto registru je:

```
|| HKEY_LOCAL_MACHINE\SOFTWARE\Microsoft\Windows\
   CurrentVersion\App Paths
```

Do tohto registra sa budú generovať záznamy s falošnými názvami a cestami k aplikáciám, ktoré budú náhodne zvolené s využitím online slovníka. Ich počet bude, tak isto ako v

predošlom prípade, zvolený aby bol približne totožný s priemerným počtom záznamov, ktoré sa nachádzajú na priemerne opotrebovanom operačnom systéme.

Ďalším dôležitým artefaktom opotrebenia systému je *totalSharedSlls*, ktorý je reprezentovaný registrom zdieľaných DLL knižníc. Obsahom tohto registra sú záznamy s cestami k jednotlivým zdieľaným DLL knižniciam. Tento register sa nachádza v:

```
|| HKEY_LOCAL_MACHINE\SOFTWARE\Microsoft\Windows\
   CurrentVersion\SharedDLLs
```

Zahmlievanie tohto registra bude prebiehať vytvorením falošných DLL knižníc a následným ukladaním ciest k týmto knižniciam do daného registra. Názvy knižníc budú generované s využitím online slovníka a samotné knižnice budú uložené do priečinka v systéme Windows, ktorý je na to určený. Tento priečinok sa nachádza na adrese:

```
|| C:\Windows\SysWOW64\
```

Ďalšími artefaktmi, ktoré sa budú zahmlievať sú *orphanedCount* a *totalMissingDlls*. Artefakt *orphanedCount* reprezentuje počet záznamov, ktoré sa nachádzajú v registroch aj napriek tomu, že aplikácia ku ktorej sa vzťahujú bola odinštalovaná. Artefakt *totalMissingDlls* reprezentuje počet záznamov v systéme ktoré odkazujú na DLL knižnice, ktoré však v systéme neexistujú. Oba tieto artefakty stačí zahmlievať vytvorením falošných záznamov v registroch operačného systému.

Nasledujúcim artefaktom určeným na zahmlievanie je *MU-ICacheEntries*. Tento artefakt reprezentuje údaje, ktoré sa vytvárajú v čase keď používateľ po prvý krát použije nejakú aplikáciu. Cesta k registru s týmito údajmi je:

```
|| HKEY_CURRENT_USER\SOFTWARE\Classes\Local Settings\
   Software\Microsoft\Windows\Shell\MuiCache
```

Tento register sa bude zahmlievať generovaním falošných záznamov, ktoré budú obsahovať falošnú cestu k aplikácii, ktorá bude generovaná s využitím online slovníka.

Posledným artefaktom opotrebenia systému, ktorý je určený na zahmlievanie je *USBStorCount*. Tento artefakt reprezentuje počet záznamov v registroch OS, ktoré obsahujú informácie o pripojených USB diskových úložiskách k počítaču. Register *USBSTOR*, ktorý sa bude zahmlievať, sa nachádza v:

```
|| HKEY_LOCAL_MACHINE\SYSTEM\CurrentControlSet\Enum\
   USBSTOR\
```

Zahmlievanie tohto artefaktu bude prebiehať vytvorením falošných záznamov, ktoré budú obsahovať dáta o pripojených USB kľúčoch. Tieto dáta sa skladajú z názvu zariadenia, ovládača, hardvérového identifikátora, názvu výrobcu, popisu zariadenia, pamäťovej adresy a rôznych iných parametrov. Pre generovanie názvov zariadenia, výrobcu a popisu sa využije znova online slovník. Ostatné atribúty sa budú generovať ako náhodné reťazce, keďže pri zahmlievaní tohto artefaktu nie je podstatná reálnosť jednotlivých záznamov o USB zariadeniach, ale podstatný je počet týchto záznamov, ktoré majú vyplnené všetky povinné údaje.

F. Zahmlievanie virtualizácie

Aj keď množstvo malvéru v dnešnej dobe nedeteguje prítomnosť virtualizácie, ale skôr sa zameriava na reálnosť operačného systému, stále je dostatok malvéru v obehu, ktorý testuje aj prítomnosť virtualizácie. Na základe tejto skutočnosti je potrebné ošetriť aj odhalenie samotnej virtualizácie. Na zníženie pravdepodobnosti detekcie virtuálneho stroja, ktorý beží pod hypervízorom VMware sa dá využiť špeciálna konfigurácia a zahmlievanie istých vlastností a atribútov, ktoré sú pre túto virtualizáciu špecifické.

Konfiguračný súbor, v ktorom sa budú vykonávať zmeny sa nachádza v súbore:

```
|| %PROGRAMDATA%\VMware\VMware Workstation\config.ini
```

Na ochranu voči odhaleniu virtualizácie pomocou rôzneho škodlivého softvéru (napr. Jerry.c) sa do konfiguračného súboru pridali nasledujúce reťazce:

```
|| isolation.tools.getPtrLocation.disable = "TRUE"
   isolation.tools.getVersion.disable = "TRUE"
   isolation.tools.setPtrLocation.disable = "TRUE"
   isolation.tools.setVersion.disable = "TRUE"
```

Ďalšou možnosťou detekcie virtuálneho systému je metóda, ktorú využíva napríklad technika Red Pill. Detekcia touto technikou, prípadne škodlivým softvérom s názvom Scoopy sa dá zamedziť pomocou pridania nasledujúcich reťazcov do konfiguračného súboru:

```
|| monitor_control.disable_btinout = "TRUE"
   monitor_control.disable_btmemspace = "TRUE"
   monitor_control.disable_btpriv = "TRUE"
   monitor_control.disable_brseg = "TRUE"
   monitor_control.disable_chksimd = "TRUE"
   monitor_control.disable_directexec = "TRUE"
   monitor_control.disable_ntreloc = "TRUE"
   monitor_control.disable_reloc = "TRUE"
   monitor_control.disable_selfmod = "TRUE"
```

Pridaním týchto reťazcov do konfigurácie sa zmení nastavenie binárneho prekladu virtualizačného nástroja VMware a taktiež sa zamedzí detekcii virtuálneho stroja na báze rozdielov v adresovaní pamäťových buniek, ktorý bol popísaný v druhej kapitole.

Ďalším opatrením voči odhaleniu virtualizácie je zakázanie využívania VMware Tools. Jedná sa o súbor nástrojov tohto virtualizačného softvéru, ktorý slúži na uľahčenie práce s virtuálnym strojom. Tento súbor nástrojov však zanecháva v systéme veľké množstvo artefaktov (napr. procesy, prípadne záznamy v registroch OS), ktoré prispievajú k uľahčeniu detekcie virtuálneho stroja malvérom.

G. Testovanie prostredia

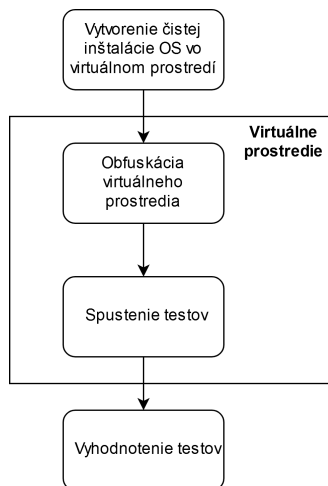
Ďalším logickým ktorom po implementácii zahmlievania systému je testovanie tohto prostredia. Toto testovanie bude prebiehať v dvoch krokoch:

- Testovanie pomocou automatizovaného nástroja,
- testovanie pomocou spustenia špecifického malvéru a sledovania jeho správania.

Testovanie pomocou automatizovaného nástroja prebiehalo v dvoch etapách. V prvej fáze sa testovalo zníženie detekcie virtualizácie samotnej, ktorá bežala na hypervízore

WMware. Toto testovanie prebiehalo pomocou nástroja WM-Detection.exe, ktorý bol vytvorený na konferencii BlackHat v roku 2012. Tento nástroj je implementovaný vo forme konzolovej aplikácie a je napísaný v programovacom jazyku C++. Obsahom tohto nástroja je 6 možných techník, ktoré dokážu detegovať hypervízor WMware. Konkrétne sa jedná o metódy využívanie inštrukcie SIDT, SLDT, SMSW, STR, techniku testovanie verzie a techniku testovania pamäte. Každý z týchto testov bol spúšťaný osobitne a zo všetkých testov sa podarilo detegovať virtualizáciu jedine testu s pamäťou. Teda aj napriek faktu, že trendy malvéru smerujú k detekcii reálnosti prostredia a nie k detekcii virtualizácie, osobitnou konfiguráciou sa dá dosiahnuť rapídne zníženie detekcie virtualizácie a teda prispieť k úspešnému odhaleniu malvéru.

Ďalšou fázou testovania pomocou automatizovaného nástroja bolo testovanie reálnosti systému s využitím nástroja na testovanie opotrebenia systému. Tento nástroj bol implementovaný tímom ľudí, ktorí publikovali štúdiu o artefaktoch opotrebenia OS. Testovanie prebiehalo v 30 rôznych inštanciách a každé spustenie nástroja prebiehalo v čerstvej verzii prostredia v ktorom bol predtým spustený nástroj na zahmlievanie artefaktov opotrebenia operačného systému. Proces testovania možno vidno na obrázku 6.

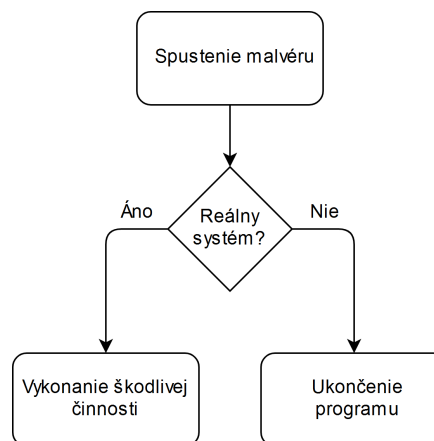


Obr. 6. Náčrt procesu testovania opotrebenia systému

Pri každom spustení nástroja na zahmlievanie artefaktov opotrebenia systému boli zadané rôzne vstupné parametre, teda boli generované rôzne počty súborov, histórie prehliadania, cookies a registrov. Z týchto pokusov bolo úspešných 24. Pri týchto pokusoch bolo podmienkou vygenerovať dostatočné množstvo falošných záznamov aby systém vyzeral opotrebovaný. Pri neúspešných pokusoch, ktorých bolo 6, sa jednalo o nedostatočne obfuskovaný systém. To znamená, že systém obsahoval málo potrebných záznamov na to aby vyzeral opotrebovaný, prípadne mal zahmlených len časť artefaktov opotrebenia systému. Účelom týchto neúspešných pokusov bolo ukázať, že ak sú v systéme niektoré artefakty nedostatočne zahmlené, prípadne vôbec nie sú zahmlené, je možné detegovať, že sa nejedná o reálny systém aj napriek tomu, že


sú ostatné artefakty opotrebenia systému dostatočne zahmlené. Pri úspešných pokusoch sa jednalo o dostatočné množstvo vygenerovaných artefaktov opotrebenia systému aj napriek tomu, že oproti skutočnému využívaniu systému používateľom mohli byť v nepomernom množstve. Testy v ktorých sa pomer jednotlivých vygenerovaných artefaktov nezhodoval so štatistickými údajmi o artefaktoch opotrebenia systému mohli byť úspešné práve kvôli tomu, že aj v reálnych systémoch sa tieto dáta nemusia zhodovať so štatistickými z dôvodu, že každý používateľ môže využívať systém primárne na iné účely a teda väčšinou sa teda malvér zameriava práve na počet jednotlivých záznamov, než na ich pomery. Teda výsledkom týchto testov sa dá predpokladať, že pri správnom používaní nástroja je možné systém dostatočne zahmlieť aby vyzeral ako reálny operačný systém a teda bol vhodným pre analýzu špecifického malvéru zameraného na detekciu prostredia.

Na testovanie pomocou spustenia špecifického malvéru bolo potrebné najprv zaobstarať takýto malvér. Väčšina vzoriek bola získaná z internetu z rôznych diskusných fór zaoberajúcimi sa detekciou, prípadne tvorbou malvéru. Pre tieto potreby bol taktiež vytvorený malvér, ktorý by sa mal snažiť posúdiť reálnosť systému. Celkovo bolo na analýzu použitých 23 vzoriek rôzneho malvéru. Náčrt správania sa tohto druhu malvéru možno vidieť na obrázku 7.



Obr. 7. Náčrt správania sa malvéru detekujúceho prostredie

Na analýzu tohto malvéru bol použitý súbor nástrojov Flare VM, ktorý obsahuje najčastejšie využívané nástroje na detekciu, debugging a skúmanie malvéru. Pred jednotlivým spúšťaním vzoriek bolo potrebné pripraviť prostredie na analýzu. Táto príprava spočívala v obfuskácii prostredia čerstvej inštalácie a následné spustenie potrebných nástrojov na sledovanie systému za účelom odhalenia malvéru. Odhalovanie malvéru v tomto prípade prebiehalo manuálne pomocou daných nástrojov. Pri každom spustení malvéru sa sledovalo jeho správanie a najmä to, či malvér spustí škodlivú časť svojho kódu, alebo nie. Pri každej vzorke bolo vopred známe jej správanie, čo uľahčilo sledovanie tohto malvéru pri spustení. Výsledky jednotlivých testov a porovnanie s výsledkami z VirusTotal možno vidieť na obrázku 8.



Obr. 8. Porovnanie úspešnosti testov s VirusTotal

Pri manuálnej detekcii malvéru sa podarilo detegovať 21 z 23 vzoriek, keďže dve vzorky detegovali, že sú spúšťané v privilegovanom móde. Zvyšné vzorky vyhodnotili, že prostredie je dostatočne reálne a teda spustili škodlivú časť svojho kódu. Je nutné podotknúť, že tieto testy boli vykonávané s reálnym prístupom na internet. V prípade využívania emulovaného pripojenia na internet klesla miera detekcie na 20 z 23, keďže jedna vzorka využívala aj metódu detekcie reálneho pripojenia na internet z dôvodu, že sa jednalo o downloader.

Čo sa týka detekcie pomocou služby VirusTotal.com, priemerná miera detekcie pri detegovaných vzorkách bola 29,34%. Celková miera detekcie bola 7 z 23 vzoriek. Vzorky boli väčšinou odhalené pomocou heuristickej analýzy.

VI. ZHRNUTIE

Ako bolo dokázané rôznymi pokusmi a testovaním, je možné dostatočne zahmlieť virtuálny operačný systém aby bol detegovaný malvérom ako reálny, s využitím vyvinutého nástroja. Pre vyššiu mieru detekcie je možné použiť aj virtualizovaný reálne opotrebovaný systém namiesto čerstvej inštalácie operačného systému, avšak tento systém je potrebné predtým očistiť od všetkých osobných údajov. Z dlhodobého hľadiska je to však neefektívne riešenie, teda oveľa viac efektívnejším riešením je rozšíriť nástroj na zahmlievanie artefaktov opotrebenia systému o ďalšie artefakty. Oproti emulovaným systémom má toto riešenie množstvo výhod, najmä zvýšenie jeho reálnosti za účelom detekcie malvéru. Nevýhodou sú však oveľa vyššie nároky na zdroje a taktiež beh jednotlivé detekcie je značne zdĺhavý oproti emulátorom, ktoré bežne využívajú rôzne antivírusové skenery.

POĎAKOVANIE

Táto práca vznikla vďaka podpore projektu Technickej Univerzity v Košiciach pod grantom číslo FEI-2018-59 s názvom „Sémantický stroj zdrojovo-orientovanej transparentnej intenzionálnej logiky“.

LITERATÚRA

- [1] Y. Ye et. al. *Automatic malware categorization using cluster ensemble*. Proceedings of the 16th ACM SIGKDD international conference on Knowledge discovery and data mining. Washington, DC, USA : ACM, 2010. ISBN 978-1-4503-0055-1. pp. 95-104.
- [2] E. Skoudis. *Infection mechanisms and targets*. Malware: Fighting Malicious Code. Prentice Hall Professional. 2004. ISBN 9780131014053. pp. 31–48
- [3] J. Aycok. *Computer Viruses and Malware*. Springer. 2006. ISBN 978-0-387-30236-2. p27
- [4] F. Cohen. *Computer viruses: Theory and experiments*. Computers & Security, 1987. Vol. 6, no. 1. pp. 22–35
- [5] R. Perdisci, A. Lanzi, W. Lee. *Classification of packed executables for accurate computer virus detection*. Pattern Recognition Letters, Volume 29, Issue 14, 15 October 2008, Pages 1941-1946, ISSN 0167-8655.
- [6] J. Kinable, O. Kostakis. *Malware Classification Based on Call Graph Clustering*. J. Comput. Virol., 7 (4), pp. 233–245. 2011. Dostupné na internete: <http://dx.doi.org/10.1007/s11416-011-0151-y> [Accessed: 22 Jan 2016].
- [7] L. Vokorokos et. al. *Security issues of email marketing service*. Acta Electrotechnica et Informatica. Roč. 15, č. 2 (2015), s. 9-14. - ISSN 1335-8243
- [8] *Metamorphic and polymorphic malware [online]*. [Cited 22.1.2016]. Dostupné na internete: <http://searchsecurity.techtarget.com/definition/metamorphic-andpolymorphic-malware>
- [9] H. Flake. *Structural comparison of executable objects*. Proceedings of the IEEE Conference on Detection of Intrusions, Malware and Vulnerability Assessment (DIMVA), 2004, pp.161-173.
- [10] R. Tian et. al. *Differentiating malware from cleanware using behavioral analysis*. Malicious and Unwanted Software (MALWARE), 2010 5th International Conference on (pp. 23-30). IEEE.
- [11] C. Collberg, K. Heffner. *The obfuscation executive*. Proc. Information Security Conference (ISC'04), volume 3225 of LNCS, pages 428–440, 2004.
- [12] T. Ogiso et. al. *Software obfuscation on a theoretical basis and its implementation*. IEEE Trans. Fundamentals, E86-A(1), 2003.
- [13] L. Vokorokos et. al. *Analysis of the Software Behaviour Using Forensic Methods for Computer Security Purposes*. Acta Electrotechnica et Informatica. Roč. 14, č. 2 (2014), s. 36-40. - ISSN 1335-8243
- [14] B. B. Rad et. al. *Evolution of Computer Virus Concealment and Antivirus Techniques: A Short Survey*. International Journal of Computer Science Issues, Vol. 8, Issue 1, January 2011. ISSN 1694-0814. pp. 113-121
- [15] E. Filiol. *Malware pattern scanning schemes secure against black-box analysis*. Journal of Computer Virol. 2006
- [16] C. Ko, G. Fink, K. Levitt. *Automated detection of vulnerabilities in privileged programs by execution monitoring*. Proceedings of the 10th Annual Computer Security Applications Conference. 1994. pp. 134–144
- [17] Emeric Nasi. 2014. *Bypass Antivirus Dynamic Analysis: Limitations of the AV model and how to exploit them*. Sevagas, 2014. p21

Metódy analýzy vybraných typov medicínskych dát

Michal Vadovský

Katedra kybernetiky a umelej inteligencie
Technická univerzita v Košiciach
Košice, Slovensko
michal.vadovsky@tuke.sk

Ján Paralič

Katedra kybernetiky a umelej inteligencie
Technická univerzita v Košiciach
Košice, Slovensko
jan.paralic@tuke.sk

Abstrakt—Tento článok je zameraný na vybrané aspekty analýzy dát v medicínskej doméne s cieľom identifikovať kľúčové symptómy a biomarkery pre včasnú a úspešnú medicínsku diagnostiku Parkinsonovej choroby, čo predstavuje zložitý proces, ktorý navyše často čelí značnému množstvu vstupných atribútov. V jeho prvej časti sa venujeme teoretickému popisu rôznych techník, ktoré používame vo fáze predspracovania dát na výber vhodnej podmnožiny atribútov pre samotné modelovanie. Hlavná časť článku je zameraná na analýzu viacerých dátových vzoriek od pacientov s Parkinsonovou chorobou, kde sa zameriavame na ich reč, chôdzu a pamäť a experimentujeme aj s výberom podmnožín atribútov pomocou rôznych metód. Nevenujeme sa len diagnostikovaníu toho, či pacient má alebo nemá toto ochorenie, ale aj posúdeniu závažnosti pomocou určenia správneho štádia. Dosiahnuté výsledky sú vyhodnotené ukazovateľmi, ako presnosť, senzitivita a špecifita.

Kľúčové slová—dolovanie v dátach; výber atribútov; Parkinsonova choroba; reč; chôdza; pamäť

Abstract—This article focuses on selected aspects of data analysis in the medical domain in order to identify key symptoms and biomarkers for early and successful medical diagnosis of Parkinson's disease. This complex process often faces a significant amount of input attributes. In the first part, we devote a theoretical description of the various techniques which we use in the pre-processing phase to select a suitable subset of attributes for modeling itself. The main part of the article is focused on the analysis of multiple data samples from patients with Parkinson's disease, where we focus on speech, walking and memory, and we also experiment with selecting subset of attributes using different methods. We do not only want to diagnose whether the patient has a disease but also to assess the severity by determining the correct stage. The obtained results are evaluated by indicators such as accuracy, sensitivity and specificity.

Keywords—data mining, attribute selection, Parkinson's disease, speech, walking, memory

I. ÚVOD

Medicínska diagnostika vážnych ochorení predstavuje niekedy zdĺhavý a komplexný proces vychádzajúci často z heterogénnych zdrojov dát a na prvý pohľad ťažko rozpoznateľných súvislostí, ktoré môžu vo veľkej miere pôsobiť na konečný výsledok a následné stanovenie vhodnej liečby. Dostupnosť dátovej vzorky v elektronickom formáte nám zjednoduší problém spracovania a následnej analýzy

pomocou vhodných metód dolovania v dátach, ktoré dokážu celý proces urýchliť a v konečnom dôsledku poslúžiť lekárom ako efektívna podpora pri rozhodovaní v zložitých situáciách. Práve preto sa za účelom zberu medicínskych dát začali mnohé nemocnice vybavovať rôznymi monitorovacími zariadeniami, ktoré predstavujú pomerne jednoduchý a lacný spôsob pre prvotný zber a následne zhromažďovanie získaných údajov. Tento trend spôsobuje neustály nárast objemu medicínskych dát, čo robí samotný proces získavania nových užitočných znalostí zložitejším. Okrem toho sa medicínske dáta vyznačujú vyššou početnosťou vstupných atribútov, faktorov alebo biomarkerov, ktoré dátový analytik musí pochopiť a správne využiť pri generovaní analytických modelov. V tomto prípade je dôležitá spolupráca s expertom v danej doméne – lekárom, ktorý môže pomôcť aj so samotným výberom najdôležitejších atribútov. To si vyžaduje spoločný slovník a správnu formu výsledkov, ktoré budú jednoducho interpretovateľné a pochopiteľné aj zo strany experta. Po vhodnom predspracovaní je možné pomocou rôznych metód dolovania v dátach vygenerovať prediktívne modely, napríklad vo forme pravidiel, ktoré ako vstup umožňujú zadať jednotlivé údaje daného pacienta. Na základe týchto získaných pravidiel je možné diagnostikovať dané ochorenie, jeho závažnosť alebo stanoviť vhodnú liečbu, čo v konečnom dôsledku uľahčí prácu hlavne lekárom. To nám umožní postupne budovať bázu znalostí, ktorú budeme kontinuálne vyhodnocovať, verifikovať, aktualizovať, dopĺňať alebo modifikovať.

V tejto práci sa chceme zamerať na podporu procesu medicínskej diagnostiky prostredníctvom vhodných metód a modelov, ktoré umožnia identifikáciu a verifikáciu nových faktorov, závislostí alebo súvislostí aj pomocou znalostí experta. Okrem toho sa taktiež zameriame na spomínaný problém výberu atribútov, či už pomocou experta alebo metódami, ktoré nie sú typické pre fázu predspracovania dát.

II. VÝBER ATRIBÚTOV

Keďže každým dňom rastie rozsah vyprodukovaných dát aj v oblasti medicíny, pred samotným modelovaním je potrebné sa zamerať aj na výber atribútov (dimenzií). Túto fázu môžeme podľa metodológie CRISP-DM zaradiť do fázy prípravy dát [1]. Pri použití všetkých dostupných atribútov často nastáva veľký problém s irelevantnými, nadbytočnými alebo redundantnými informáciami, ktoré nakoniec spôsobujú zníženie výkonnosti niektorých metód dolovania v dátach [2]. Výber vhodných atribútov je proces výberu minimálneho počtu dimenzií v dátach, ktoré v konečnom dôsledku najviac

vplývajú na výslednú klasifikáciu, resp. sú skutočne nevyhnutné pre tvorbu modelov. Okrem toho, ďalšou veľkou výhodou je to, že na výpočet a vytvorenie nových modelov potrebujeme oveľa menej času a sú taktiež pochopiteľnejšie a ľahšie interpretovateľné [3]. Niektoré algoritmy dolovania v dátach by mali obsahovať aj krok pre výber atribútov, ktoré dokážu predikovať cieľové triedy s čo najväčšou presnosťou. Aktuálne výskumy v tejto oblasti však preukázali, že irelevantné, nadbytočné a nepotrebné atribúty vyskytujúce sa v trénovacej množine, nepriaznivo vplývajú na bežné algoritmy strojového učenia [4]. Preto je potrebné tento krok nepodceňovať a pri samotnej analýze vybranej dátovej vzorky uskutočniť aj výber pre danú úlohu najrelevantnejších atribútov pre danú úlohu aj pomocou prístupov, ktoré sme popísali v našich publikáciách [5][6].

Ak pri analýze vybranej dátovej vzorky spolupracujeme s expertmi v danej oblasti (lekármi), môžeme ponechať výber alebo odstránenie atribútov aj na nich. Z medicínskeho hľadiska vedú najlepšie vyhodnotiť, ktoré atribúty sú od seba navzájom odvodené, podávajú duplicitné informácie (redundantné) alebo nie sú potrebné a zaujímavé do ďalších analýz. Niekedy sa lekári zamerajú aj na výber viacerých podmnožín atribútov z dát, na ktorých následne dátoví analytici vytvoria klasifikačné alebo predikčné modely použitím rôznych metód a nakoniec ich vyhodnotia vhodnými ukazovateľmi. Tieto výsledky sú potom vyhodnotené z pohľadu toho, aké skupiny atribútov z medicínskeho hľadiska dokážu najviac prispieť k vytvoreniu najlepších modelov, ktoré môžu slúžiť ako podpora diagnostiky danej choroby. Ak pri analýze dát nespôsobujeme s expertmi v danej doméne, vo fáze predspracovania dát môžeme pre výber alebo odstránenie atribútov využiť existujúce prístupy, ako napríklad odstránenie kolinearit v dátach, výber na základe štatistických testov atď. Odstrániť nepotrebné atribúty je možné aj pomocou metód, ako **Backward/Forward Stepwise Selection** alebo **LASSO** [7], avšak tieto metódy sú typické už pre fázu modelovania, pretože vygenerujú regresné modely len s podstatnými atribútmi, poprípade hodnoty niektorých regresných koeficientov zmenšia na nulu a tým pádom sa daný atribút vo finálnom modeli už nenachádza. My sme sa však rozhodli tieto metódy aplikovať už v samotnom predspracovaní dát a podmnožinu vybraných atribútov sme následne použili ešte na vytvorenie modelov pomocou rozhodovacích stromov.

A. Multikolarita

Ak nastane v dátach situácia, že 2 alebo viaceré premenné sú medzi sebou úzko prepojené (závislé), hovoríme o kolinearite [7]. Jej prítomnosť v dátach môže spôsobiť skreslenie dosiahnutých výsledkov, pretože mení vplyv jednotlivých kolineárnych premenných na cieľový atribút, ktorý sledujeme. Pri regresii sa to prejavuje napríklad zníženou presnosťou odhadovaných regresných koeficientov v modeli, čo spôsobuje aj zvýšenie štandardných chýb hodnôt b_i . Medzi najjednoduchšie spôsoby ako zistiť problém s kolinearitou v dátach je vytvoriť korelačnú maticu zo všetkých numerických atribútov a zamerať sa v nej na vysoké absolútne hodnoty medzi jednotlivými dvojicami. Avšak niekedy vytvorenie korelačnej matice nestačí, pretože aj keď medzi vybranými dvojicami atribútov neexistuje vysoká závislosť, kolinearita

môže existovať medzi tromi a viacerými premennými. Vtedy hovoríme o multikolarite. Na jej posúdenie sa nestačí pozrieť iba na korelačnú maticu, ale lepší spôsob je vypočítať **Inflačný faktor rozptylu (VIF)** pre každý numerický atribút. O úplnej neprítomnosti kolinearit hovoríme vtedy, ak je VIF na hodnote 1. V praxi však aj malé množstvo kolinearit v dátach nespôsobuje žiadne problémy, pretože menšie vzťahy medzi dvoma a viacerými atribútmi sa stále vyskytnú [8]. Preto ako pravidlo platí, že ak hodnota VIF presiahne hodnotu 5 alebo 10, vtedy už začíname hovoriť o problematickom množstve kolinearit.

B. Štatistické testy

Štatistické testy [9] poznáme rôzne, pričom ich výber závisí v prvom rade od cieľovej úlohy a povahe štúdie. Poskytujú metódu na tvorbu kvantitatívnych rozhodnutí na vybranej dátovej vzorke, kde testujú hypotézy o významnosti sledovaných parametrov vzorky. Štatistické testy priamo súvisia so štatistickým záverom získaným na základe dôkazov a odôvodnenia. Kľúčovú úlohu pri týchto záveroch zohráva testovanie hypotéz. V oblasti medicíny a zdravotnej starostlivosti je potrebné dávať veľký pozor pri používaní týchto testov. Klinické štúdie veľmi často porovnávajú napríklad účinok nového lieku s účinnosťou už existujúceho lieku, poprípade placebo. Ak sa výskumník dopustí chyby pri výpočtoch, tak záverom testu môže byť napríklad nesprávne označenie účinnej vzorky liekov a naopak. Keďže aj na základe štatistických testov je možné ovplyvňovať výber liekov alebo dávok pre jednotlivých pacientov, pri dopustení sa chyby môžu nastať obrovské komplikácie pri nastavení vhodnej liečby a ďalšom živote ľudí.

Ak máme položenú otázku zameranú na porovnanie dvoch alebo viacerých sledovaných skupín, vtedy môžeme vykonať štatistický test. Musíme si teda najprv stanoviť nulovú hypotézu a určiť vhodný testovací atribút. Napríklad, ak chceme sledovať vplyv daného lieku na hladinu krvného tlaku (testovací atribút), tak vypočítame rozdiel medzi priemerom krvného tlaku liečených pacientov sledovaným liekom a pacientov, ktorí brali iba placebo. Stanovíme si teda nasledujúce **hypotézy** [10]:

- **H₀**: Medzi sledovaným liekom a placebom nie je žiadny rozdiel v súvislosti s hodnotami krvného tlaku (účinnosť lieku je nulová) – závislosť medzi výškou krvného tlaku a sledovaným liekom neexistuje.
- **H₁**: Medzi sledovaným liekom a placebom je rozdiel v hodnotách krvného tlaku (účinnosť liekov má vplyv) – závislosť medzi výškou krvného tlaku a sledovaným liekom existuje.

Štatistický test potom počíta pravdepodobnosť získania pozorovaných údajov. Ak je **p-hodnota** veľmi nízka, tak vypočítaná pravdepodobnosť je zanedbateľná. Na základe nami stanovenej hladiny významnosti α buď zamietame, alebo nezamietame nulovú hypotézu. Ak je p -hodnota $< \alpha$, tak zamietame H_0 a tým pádom prijímame H_1 a naopak, ak je p -hodnota $> \alpha$, tak nezamietame H_0 , čiže stanovená hypotéza H_0

platí. Keby v našom vzorovom príklade vyšla p -hodnota pod úroveň hladiny významnosti α , zamietli by sme H_0 , prijali H_1 a mohli by sme tvrdiť, že medzi vzorkou pacientov liečených sledovaným liekom a vzorkou pacientov, ktorí brali iba placebo, existuje signifikantný rozdiel v hodnotách krvného tlaku. Týmto tvrdením by sme následne mohli povedať, že daný liek má vplyv na výšku krvného tlaku.

Keďže v skutočnom živote nie všetci pacienti reagujú na podávaný liek rovnako, môže dôjsť k chybe pri prijatí alebo odmietnutí nulovej hypotézy. Jej nesprávne zamietnutie nazývame chybou I. typu, pričom maximálna pravdepodobnosť výskytu tejto chyby je na úrovni hladiny významnosti α , ktorý sa najčastejšie volí na hodnote 5% ($\alpha = 0,05$) [11]. Tento typ chyby teda vedie k záveru, že predpokladaný vzťah alebo účinok sledovaného lieku existuje, aj keď v skutočnosti to nie je pravda. Ďalší príklad pre výskyt chyby typu I. môže byť, ak test ukáže že pacient má dané ochorenie, ale v skutočnosti je zdravý. Chyba II. typu nastáva v situácii, ak neodmietneme nepravdivú nulovú hypotézu. Príkladom tejto chyby môže byť nepotvrdenie použiteľnosti danej liečby, ak liečba naozaj funguje alebo keď krvný test určený na zistenie choroby ju v skutočnosti nepotvrdí, pričom pacient dané ochorenie naozaj má [12].

Pri našich analýzach sme väčšinou tieto štatistické testy používali vo fáze pochopenia dát pre nájdenie vzťahov medzi atribútmi, poprípade medzi vstupnými parametrami a cieľovou diagnózou vyjadrenou v binárnom tvare (1 – pacient trpí ochorením, 0 – pacient je zdravý). Avšak stanovením hladiny významnosti (napr. $\alpha = 0,05$) je možné na základe výslednej p -hodnoty štatistického testu vybrať pre ďalšie analýzy len tú podmnožinu atribútov, ktorá štatisticky najviac vplyva na sledovaný atribút (diagnostiku). Výber štatistického testu [13] závisí hlavne od dátového typu vstupného a cieľového atribútu. Pri práci s numerickými hodnotami musíme najprv pomocou **Shapiro-Wilkovho testu** sledovať to, či daný atribút má alebo nemá normálne rozdelenie. Ak je cieľový atribút v binárnej forme (pacient má/nemá ochorenie) a vstupný numerický atribút má normálne rozdelenie, tak použijeme **Welchov test**. V rovnakom prípade, ak numerický atribút nemá normálne rozdelenie, aplikujeme **Wilcoxonov test**. Pri sledovaní závislosti medzi vstupnými a cieľovými atribútmi v binárnom, poprípade nominálnom tvare sa používa **Chi-kvadrát test** alebo **Fisherov test**. Medzi hlavné výhody Fisherovho testu patrí to, že je presný bez ohľadu na veľkosť dátovej vzorky, avšak je oveľa zložitejší a zdĺhavejší na výpočet. Pri analýze menšej dátovej vzorky v prostredí RStudio a zvolení Chi-kvadrát testu Váš program môže upozorniť, že výsledok nemusí byť správny. V takomto prípade je lepšie použiť Fisherov test. V medicínskej doméne môžeme mať cieľový atribút vyjadrený aj v nominálnom tvare, napríklad ak vyjadruje štádium určitého ochorenia. V takomto prípade pri sledovaní jeho závislosti ku vstupnému numerickému atribútu používame **ANOVA testy**, ktoré sa zameriavajú na porovnávanie troch a viac skupín.

C. Forward a Backward Stepwise Selection

Forward a Backward Stepwise Selection patria medzi regresné metódy, pomocou ktorých vytvoríme model len s podmnožinou dôležitých prediktorov [7]. **Forward Stepwise Selection (FSS)** sa často používa aj v situáciách, ak sa v analyzovaných dátach predpokladá problémový výskyt multikolinearity [14]. Metóda FSS [15] je veľmi jednoduchá, na úvod začíname s modelom, ktorý obsahuje 0 prediktorov (atribútov). Následne vytvoríme p jednoduchých modelov (pre každý jeden prediktor) obsahujúcich len jednu premennú a hľadáme medzi všetkými modelmi ten, ktorý je najlepší z hľadiska najnižšej hodnoty RSS – reziduálny súčet štvorcov. Vybraný prediktor potom ponecháme v modeli a znova pokračujeme v hľadaní ďalšieho prediktora, avšak už iba z $p-1$ premenných. Opäť sa zameriavame na to, ktorá premenná by mala byť pridaná do modelu, aby sa čo najviac zlepšila hodnota RSS. Tento postup opakujeme dovtedy, kým zvyšné premenné dosahujú vyššiu p -hodnotu ako je nami zvolená hranica. Napriek tomu že metóda FSS je často využiteľná v praxi, nie je vždy zaručené, že vybraná podmnožina atribútov bude najlepšia pre tvorbu finálneho modelu [7]. Vezmime si napríklad dátovú množinu s 3 atribútmi, kde najlepší model s 1 prediktorom pozostáva z premennej X_1 a najlepší možný model s 2 prediktormi obsahuje premenné X_2 a X_3 . Na základe postupu metódy BSS by nebolo možné vybrať najlepší model s dvoma atribútmi, pretože po prvom kroku by už model musel obsahovať premennú X_1 . V ďalšom kroku by ku premennej X_1 bol zvolený jeden z dvojice X_2 alebo X_3 .

Metóda **Backward Stepwise Selection (BSS)** [14] začína s modelom, ktorý obsahuje všetky dostupné premenné, a preto je často označovaná za menej populárnu ako FSS. Keďže metóda funguje spôsobom postupného odoberania atribútov, tak ukazovateľ RSS sa stále pohybuje na vyšších hodnotách. Rovnako ako pri FSS pripadá do úvahy, že výsledná podmnožina atribútov bude obsahovať aj premenné, ktoré nie sú potrebné [7]. Ako sme už spomínali, celý postup metódy BSS začína so všetkými atribútmi, pričom odstránime ten, ktorý nadobúda najvyššiu p -hodnotu. Jedná sa teda o štatisticky najmenej významný atribút. Nová podmnožina tak po prvom kroku obsahuje už iba $p-1$ prediktorov. Ako pri FSS opakujeme tento postup dovtedy, pokiaľ v podmnožine atribútov nezostanú už iba atribúty s p -hodnotou pod nami zvolenou hranicou.


Výsledky získané metódami FSS a BSS vedú k vytvoreniu viacerých modelov s rôznymi množinami atribútov, pričom každý jeden model obsahuje určitý počet prediktorov. Aby sme mohli tieto výsledky vhodným spôsobom vyhodnotiť, potrebujeme určiť, ktorý z týchto modelov je najlepší a ktoré atribúty v sebe zahŕňa. Model obsahujúci všetky prediktory bude mať samozrejme najväčšiu hodnotu R^2 , poprípade najnižšiu RSS, pretože sa odvíjajú od chyby dosiahnutej pri trénovaní. Je potrebné sa zamerať na model, ktorý nadobudne najmenšiu chybu na testovacej množine. Pre nájdenie toho najlepšieho modelu s určitým počtom atribútov musíme chybu dosiahnutú pri testovaní odhadnúť. Existujú na to 2 spôsoby [7]:

- Priamy odhad testovacej chyby tradičným rozdelením dát na tréningovú a testovaciu množinu, prípadne pomocou napr. 10-násobnej krížovej validácie,
- Nepriamy odhad testovacej chyby vykonaním úpravy tréningovej chyby tak, že zohľadníme pri tom aj sklon k preučeniu.

Techniky pre úpravu tréningovej chyby s ohľadom na preučenie, pričom sa berie do úvahy aj veľkosť modelu, poznáme tieto:

- **Mallow's Cp** – používa sa na určenie vhodnosti modelu, ktorý bol vytvorený pomocou metódy najmenších štvorcov. Aplikuje sa pri výbere modelu, keď máme dostupných niekoľko vstupných premenných na predikovanie určitého výsledku (sledovaný atribút) a naším cieľom je nájsť model, ktorý obsahuje len podmnožinu atribútov [16]. Čím menšia hodnota Cp, tým je zvolený model presnejší.
- **BIC (Bayesovské informačné kritérium)** – zameriava sa na výber jedného modelu z celej množiny modelov, pričom sleduje sa čo najnižšia hodnota BIC [17]. Súvisí taktiež s informačným kritériom Akaike (AIC) [18] a podstata tohto kritéria sčasti vychádza z funkcie pravdepodobnosti. Pridávaním atribútov do modelu dokážeme zvýšiť jeho presnosť a úspešnosť, avšak musíme prihliadať aj na možný problém preučenia (ak sa model pokúša správne klasifikovať aj šum, pretože sa učí priveľa detailov). Práve BIC a AIC sa snažia riešiť tento problém pomocou sankcií, ktoré sa udeľujú na základe počtu atribútov v modeli. Pre porovnanie, vyššie sankcie sú v kritériu BIC ako pri kritériu AIC.
- **Korigovaný R² (Adjusted R²)** – oproti tradičnému R² sa odlišuje tým, že berie do úvahy pri výpočte jeho hodnoty aj počet odhadovaných parametrov modelu a tiež počet záznamov n na každú premennú [19]. Rovnako ako predchádzajúce kritériá, používa sa na výber vhodného modelu, ak ich máme k dispozícii viacero.

Pre lepšie znázornenie sme si zobrazili na Obr. 1 výstup v podobe grafov získaných v prostredí RStudio, kde sme z celkového počtu 61 atribútov chceli vybrať len tie najdôležitejšie.




Obr. 1 Výber atribútov metódou Forward Stepwise Selection

Cieľový atribút bol v binárnom tvare a podával informáciu o tom, či pacient má alebo nemá dané ochorenie. Na Obr. 1 sú zobrazené dosiahnuté výsledky pomocou metódy Forward Stepwise Selection. Na x-ovej osi je počet atribútov (0 až 61) a y-ová popisuje hodnoty jednotlivých kritérií a ukazovateľov (Cp – Mallow's Cp, BIC – Bayesovské informačné kritérium). Optimálne hodnoty jednotlivých ukazovateľov sú v grafoch vyznačené červenou bodkou.

D. LASSO

Pre prispôsobenie modelu zostrojeného z podmnožiny prediktorov používajú prístupy FSS a BSS metódu najmenších štvorcov. Ďalším spôsobom ako zredukovať počet atribútov je vytvoriť model zo všetkých p prediktorov a zmenšiť odhad ich koeficientov na hodnotu blízku nule alebo presne na nulu, čo môže v konečnom dôsledku znížiť ich rozptyl. Medzi najznámejšiu metódu znižovania regresných koeficientov patrí **LASSO (Least Absolute Shrinkage and Selection Operator)** [7]. Táto metóda využíva penalizáciu, ktorej vplyv a miera je vyjadrená pomocou penalizačného koeficientu λ . So zvyšovaním jej hodnoty sa rovnako zvyšuje aj počet regresných koeficientov približujúcich sa k alebo rovných nule. Nastavenie najlepšej hodnoty λ je možné na základe určenia najmenšej chybovosti modelu, ktorú zistíme napríklad použitím 10-násobnej krížovej validácie. Metóda LASSO znižuje odhady regresných koeficientov k nule, pričom ak je penalizačný koeficient λ dostatočne veľký, tak niektoré odhady sa aj rovnajú nule. Vo všeobecnosti je LASSO [20] vhodné používať v prípadoch, kedy očakávame väčší počet prediktorov s nízkou popripade nulovou hodnotou regresného koeficientu a zároveň menšie množstvo podstatných prediktorov s väčšími koeficientami.

Na Obr. 2 si môžeme všimnúť, ako sa jednotlivé hodnoty regresných koeficientov zmenšovali so stúpajúcou logaritmicou hodnotou penalizačného koeficientu λ . Na y-ovej osi sú vyjadrené hodnoty regresných koeficientov a na osi x v spodnej časti vidíme logaritmické hodnoty λ . Na vrchnej časti si zas môžeme všimnúť zastávajúci počet prediktorov. Každý jeden atribút je v grafe zobrazený pomocou vlastnej krivky a farby, pričom pri väčšom počte atribútov je to samozrejme už ťažšie čitateľné.




Obr. 2 Výber atribútov pomocou LASSO

III. ANALÝZA REČI

Pri tejto úlohe sme pracovali s dátami zaznamenávajúcimi reč pacientov Parkinsonovej choroby, ktorá bola transformovaná do jednotlivých atribútov. V publikácii [21] sme sa zamerali na určenie jedného zo 7 rôznych štádií tohto ochorenia podľa Hoehn & Yahr škály. Dátová množina je voľne dostupná na internete v databáza UCI Machine Learning Repository, pričom jednotlivé atribúty popisujú viacero biomedicínskych hlasových meraní. Tieto dáta vytvoril a zozbieral Max Little z Univerzity v Oxforde, ktorý spolupracoval s Národným centrom pre hlas a reč sídliacim v Denvery v Colorade. Kompletná dátová množina pozostávala zo záznamov od 32 pacientov, kde 24 z nich trpelo Parkinsonovou chorobou. Od väčšiny subjektov sme mali k dispozícii 6 záznamov a od 3 subjektov 7 záznamov bežného hovoreného slova, čo spolu predstavovalo 195 riadkov. Viaceré záznamy od jedného pacienta boli v dátach brané nezávisle od seba. Okrem mena subjektu, pohlavia, veku, rokov od diagnostikovania Parkinsonovej choroby a jeho štádia sa vo vzorke nachádzalo ďalších 22 atribútov, ktoré boli transformované z reči. Keďže sme sa chceli v prvom zamerať na reč pacientov, pred samotnou analýzou sme nebrali do úvahy počet rokov od diagnostikovania tohto ochorenia, ale taktiež meno subjektu, na základe ktorého bolo možné presne určiť štádium. Po všetkých úpravách sme nakoniec pracovali so 189 záznamami a 25 atribútmi.

A. Závislosť

Pre lepšie pochopenie dát sme sa v prvom rade zamerali na sledovanie závislosti vstupných numerických atribútov ku cieľovému v nominálnom tvare, ktorý vyjadruje štádium ochorenia. Pre tento typ úlohy je vhodné použiť ANOVA test (Analysis of Variance) [22], kde je opäť potrebné sledovať p-hodnotu, ktorá ak je menšia ako hladina významnosti (napr. $\alpha = 0,05$), tak zamietame H_0 (prijímame H_1) a tvrdíme, že existujú rozdiely v priemerných hodnotách sledovaného numerického atribútu rozdeleného podľa nominálneho atribútu (Stage). Najnižšia p-hodnota, čo znamená prijímanie H_1 s väčšou dôverou, bola dosiahnutá pri MDVP.APQ (p-hodnota = 2,519407e-29), MDVP.Shimmer.db (p-hodnota = 4,454684e-23) a MDVP.PPQ (p-hodnota = 5,885382e-23). Podľa získaných p-hodnôt môžeme vidieť, že sa jedná o naozaj silné závislosti medzi danými numerickými atribútmi a cieľovým atribútom Stage. Na Obr. 3 sme si znázornili graf zobrazujúci najsilnejšiu závislosť medzi cieľovým atribútom a numerickým atribútom MDVP.APQ.



Obr. 3 Závislosť medzi štádiom a MDVP.APQ

V tomto obrázku si môžeme všimnúť, že rastom štádia Parkinsonovej choroby väčšinou rastú aj priemerné hodnoty atribútu MDVP.APQ (hrubá čiara v boxplote), jediná výnimka je pri štádiu 1.5, kde nastane výraznejší nárast hodnôt oproti štádiu 1, dokonca vyšší ako pri štádiu 2 a 2.5. Preto môžeme predpokladať, že pri klasifikovaní pacientov do jednotlivých štádií sa môžu vytvorené modely najviac myliť práve pri priradení pacientov do štádií tesne za 1.5 [23].

B. Výber atribútov a modelovanie

Pre samotné generovanie klasifikačných modelov sme si zvolili rôzne algoritmy rozhodovacích stromov – C4.5, C5.0 a CART. Experimentálne sme skúšali použiť aj ďalšie algoritmy, avšak dosahovali nižšie presnosti, preto sme vybrali 3 najlepšie. Na odhad presnosti vytvorených rozhodovacích stromov sme využili 10-násobnú krížovú validáciu (10-CV), ale taktiež aj metódu Leave-one-out (LOO), kde sa model trénuje na $n-1$ záznamoch z celkového počtu n záznamov, na zvyšnom jednom zázname sa testuje a celý proces sa opakuje n -krát. Klasifikačné modely sme vytvárali najprv na celej dátovej množine a potom aj na dátach, v ktorých sme odstránili kolinearitu medzi numerickými atribútmi. Kolinearitu pre každý atribút sme sledovali pomocou ukazovateľa s názvom Inflačný faktor rozptylu (VIF). V našom prípade sme odstránili tie atribúty, ktoré nadobúdali hodnotu $VIF > 5$ [7]. V Tab. 1 si môžeme všimnúť zoznam ponechaných numerických atribútov, ktorý je usporiadaný zostupne od najväčšej hodnoty VIF.

Tab. 1 Usporiadané atribúty s $VIF < 5$

Poradie	Atribút	VIF
1.	MDVP.APQ	3,716
2.	Spread1	3,685
3.	MDVP.Fo. Hz	3,649
4.	RPDE	2,537
5.	NHR	2,426
6.	DFA	2,363
7.	Spread2	2,351
8.	D2	2,248
9.	MDVP.Flo. Hz	2,026
10.	Age	1,811
11.	MDVP.Fhi. Hz	1,372

Keďže pri generovaní rozhodovacích stromov sme opäť nebrali do úvahy meno subjektu, po ponechaní nominálnych atribútov Pohlavie a Štádium (Stage) sa nám celkový počet stĺpcov zmenšil z 25 na 13. V Tab. 2 a Tab. 3 sú porovnané presnosti spolu so smerodajnou odchýlkou jednotlivých klasifikačných modelov použitím algoritmov rozhodovacích stromov, ako C4.5, C5.0 a CART pri použití celej dátovej množiny (24 atribútov) a pri výbere len 13 atribútov (11 s hodnotou $VIF < 5$ spolu s Pohlavím a Štádiom). Presnosti vytvorených modelov sme odhadovali pomocou 10-CV a LOO.

Tab. 2 Výsledky pri 10-CV

Výber atribútov	10 - CV		
	CART	C4.5	C5.0
Všetky atribúty	69,71% ± 13,49%	79,88% ± 8,55%	83,54% ± 7,02%
VIF < 5	67,66% ± 12,56%	85,15% ± 6,95%	86,2% ± 6,34%

Tab. 3 Výsledky pri LOO-CV

Výber atribútov	10 - CV		
	CART	C4.5	C5.0
Všetky atribúty	71,96% ± 45,04%	80,42% ± 39,78%	81,48% ± 38,95%
VIF < 5	72,47% ± 44,78%	80,95% ± 39,37%	82,01% ± 38,51%

Už na prvý pohľad si môžeme všimnúť, že odstránit kolinearitu v dátach je správny krok, pretože skoro vo všetkých prípadoch, až na jednu výnimku, došlo k zvýšeniu dosiahnutých presností. Pokles nastal iba pri algoritme CART (10-CV) o približne 2%, avšak tento algoritmus dosahoval o dosť nižšie presnosti ako lepšie algoritmy C4.5 a C5.0. Pri porovnaní metód na odhad presnosti výsledných modelov použitím 10-CV alebo LOO-CV je viditeľné, že pri najslabšom algoritme CART nastal mierny nárast presnosti a naopak pri najlepšom algoritme C5.0 došlo naopak k zmenšeniu presnosti. Rozdiel medzi najlepším a najslabším algoritmom sa teda zmenšil. Samozrejme smerodajná odchýlka pri presnosti jednotlivých modelov bola o dosť vyššia pri LOO-CV, pretože pri testovaní modelu len na jednom zázname môže nastať len 100% alebo 0% presnosť, preto táto hodnota viac kolísala ako v prípade 10-CV. Celkovo najvyššia presnosť na úrovni 86,2% sme dosiahli použitím algoritmu C5.0 na dátach očistených od kolinearity odhadujúc presnosť podľa metódy 10-CV.

Pre pokus o zlepšenie výsledkov sme použili sofistikovanejšie metódy pre generovanie modelov, ktoré používajú jednotlivé rozhodovacie stromy ako stavebné bloky. Jedná sa o metódy **RandomForest**, **Bagging** a **Boosting** [24], pri ktorých je potrebné ako vstup zadať počet vygenerovaných stromov. V publikácii [25] porovnávali autori na 29 dátových množinách dosiahnutú presnosť pri vytvorení 128, 512, 1024, 2048 a 4096 stromov, kde podľa výsledkov dospeli k záveru, že v ich prípade od hranice 128 vygenerovaných stromov sa presnosť zvýšila už len minimálne, avšak rapídne rastie výpočtová zložitosť. V tomto experimente sme sa pre porovnanie rozhodli vygenerovať 50, 100 a 150 stromov pri použití metód RandomForest, Bagging a Boosting, pričom testovanie prebiehalo pomocou 10-CV.

Podľa výsledkov v Tab. 4 si môžeme všimnúť, že metóda Boosting pri vytvorení 150 stromov dosiahla jednoznačne najlepšiu presnosť na úrovni 95,77%. Pri rastúcom počte vygenerovaných stromov už presnosť pri jednotlivých metódach až tak rapídne nerástla, naopak metóda RandomForest dosiahla nižšiu presnosť. V porovnaní s predchádzajúcimi výsledkami dokonca algoritmus C5.0 (10-CV) pri vygenerovaní jedného rozhodovacieho stromu získal vyššiu presnosť ako metóda Bagging a pomerne porovnateľné s výsledkami pri metóde RandomForest.

Tab. 4 Dosiadnuté presnosti metód RandomForest, Bagging a Boosting

Počet stromov	RandomForest	Bagging	Boosting
m = 50	87,25% ± 8,37%	77,78% ± 9,25%	93,65% ± 6,51%
m = 100	86,73% ± 8,52%	77,78% ± 9,25%	95,24% ± 5,01%
m = 150	86,73% ± 8,52%	78,31% ± 9,12%	95,77% ± 4,95%

Tab. 5 Kontingenčná tabuľka metódy Boosting

Predicted Class	Observed Class						
	0	1	1.5	2	2.5	3	4
0	47	0	0	2	1	0	0
1	0	15	0	0	0	1	0
1.5	0	0	19	0	0	0	0
2	1	1	0	28	0	0	0
2.5	0	2	0	0	42	0	0
3	0	0	0	0	0	23	0
4	0	0	0	0	0	0	7

Pre metódu s najvyššou presnosťou Boosting sme si vykreslili aj kontingenčnú tabuľku, v ktorej stĺpce zobrazujú predikované hodnoty a riadky naopak reálne hodnoty z testovacej množiny. V Tab. 5 je možné vidieť aj to, kde najčastejšie sa model mylil a dochádzalo tak k chybe. Testovanie vytvorených modelov prebiehalo pomocou metódy 10-CV, vďaka čomu sme vlastne získali 10 kontingenčných tabuliek. V tejto finálnej je každý prvok vypočítaný ako súčet prvkov na rovnakom mieste zo zvyšných kontingenčných tabuliek. Najvyššia presnosť je dosiahnutá vtedy, ak dosiahnu maximálne hodnoty prvky na hlavnej diagonále, pretože vtedy model predpovedal pacientovi určité štádium Parkinsonovej choroby, ktoré nakoniec aj mal. Celková presnosť je teda vypočítaná tak, že zo 189 príkladov vedel vygenerovaný model predpovedať správne štádium až v 181 prípadoch (95,77%). Rovnako si vypočítame aj presnosť modelu pre každé jedno štádium, ktoré sme mali dostupné v dátach, pričom v zátvorke je uvedený pomer správne klasifikovaných príkladov ku celej množine príkladov pre vybrané štádium Parkinsonovej choroby: 0 (47/48) = 97,92%, 1 (15/18) = 83,33%, štádium 1.5 (19/19) = 100%, štádium 2 (28/30) = 93,33%, štádium 2.5 (42/43) = 97,67%, štádium 3 (23/24) = 95,83%, štádium 4 (7/7) = 100%.

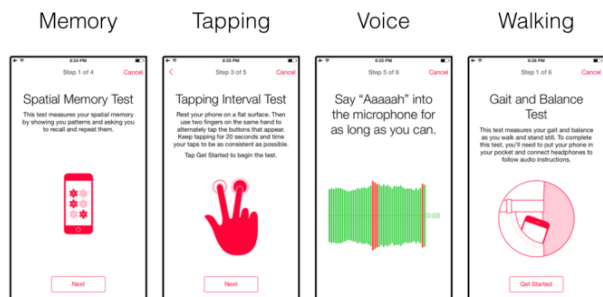
C. Vyhodnotenie

Z týchto výsledkov je viditeľné, že model vytvorený metódou Boosting dokázal 100% klasifikovať pacientov so štádiami 1.5, a 4. Naopak, najhoršie výsledky s presnosťou 83,33% boli dosiahnuté pri štádiu 1, kde nám model pri dvoch príkladoch predpovedal štádium 2,5 a v jednom prípade štádium 2. Pri Obr. 3 sme poznamenali, že vytvorené modely sa môžu najviac myliť pri predikovaní štádií tesne za 1.5, pretože hodnoty atribútu s najsilnejšou závislosťou MDVP.APQ boli pri štádiu 1.5 vyššie ako pri štádiách 2, 2.5 a 3. Tento neočakávaný nárast mohol preto spôsobiť chyby práve pri predikovaní týchto ďalších štádií Parkinsonovej choroby. Pri celkovom pohľade na získané presnosti jednotlivých štádií môžeme povedať, že až na výnimku jedného vedel model predpovedať každé štádium tohto ochorenia s presnosťou nad 93%. Pri binárnej klasifikácii na rovnakých dátach sme v našich predchádzajúcich publikáciách [26][27] dosiahli najlepší výsledok s presnosťou iba 91,43% pri využití algoritmu C4.5. Tentokrát išlo o náročnejšiu klasifikačnú úlohu, pretože náš model musel zaradiť pacientov do jedného zo 7 štádií a napriek tomu sme vhodným očistením dát od kolinearity a využitím sofistikovanejších metód dokázali zvýšiť celkovú presnosť až na úroveň 95,77% (metódou Boosting a vygenerovaní 150 rozhodovacích stromov).

IV. APLIKÁCIA MPOWER

Mobilná aplikácia **mPower** sa zameriava na sledovanie hlavných faktorov pre správne diagnostikovanie Parkinsonovej choroby pomocou dát získaných z mobilných zariadení napríklad prostredníctvom jeho senzorov alebo vykonaním rôznych hier. Celá štúdia a táto aplikácia vznikla so zámerom správne pochopiť rôznorodosť symptómov a ich zdroje u týchto pacientov [28]. mPower sa skladala zo 7 častí [29]:

- **Demografický prieskum** – účastníci odpovedali na základne demografické otázky, napríklad vek, zamestnanie, rasa, rodinný stav, rok diagnostikovania ochorenia a množstvo ďalších,
- **Chôdza** – pre splnenie úlohy bolo potrebné prejsť najprv rovno 20 krokov a po otočení ostat' stáť na mieste 30 sekúnd,
- **Pamäť** – táto kognitívna vlastnosť bola sledovaná na základe hry s kvetmi, ktoré boli vysvecované v ľubovoľnom poradí, ktoré si mal účastník zapamätať,
- **Hlas** – po dobu 10 sekúnd musel účastník vyslovovať „Aaah“ trvalo, ak to teda bolo možné,
- **Klikanie** – aktivita zameraná na opakujúce striedavé klikanie na ľavú a pravú stranu displeja po dobu 20 sekúnd, pričom išlo hlavne o rýchlosť a zručnosť,
- **MDS-UPDRS** – vyplnenie vybraných položiek a otázok z tohto dotazníka zamerané prevažne na hybnosť,
- **PDQ8** – vyplnenie položiek a otázok z tohto dotazníka so zameraním na psychický stav pacienta, jeho každodenné aktivity a taktiež vplyv na osobný a spoločenský život.



Obr. 4 Aktivity pre pamäť, klikanie, hlas a chôdzu

V prípade parkinsonikov, jednotlivé aktivity (pamäť, klikanie, hlas a chôdza) mali vykonať v ľubovoľnom čase počas dňa, ale aj pred a po užití liekov. Pri zdravých ľuďoch bolo možné tieto aktivity vykonať hocikedy počas dňa, avšak testovanie sa odporúčalo vykonať taktiež aspoň 3 krát za deň. Nakoniec až 9520 používateľov dalo súhlas pre zdieľanie údajov pre vedcov po celom svete, kde 6805 vyplnilo všetkých 7 častí a 8320 aspoň jednu z nich. Z pohľadu ochorenia malo Parkinsonovu chorobu diagnostikovanú 1087 účastníkov, 5581 bolo zdravých ľudí a 137 na túto otázku neodpovedalo.

Každá jedna zo 7 častí v aplikácii obsahuje jedinečný identifikátor každého dobrovoľníka v štúdií (*healthCode*) a taktiež každého jedného záznamu pri ľubovoľnej činnosti (*recordId*). Tieto atribúty sa samozrejme nachádzajú vo všetkých aktivitách (tabuľkách), čo nám umožňuje ich spájať a vykonať tak rozsiahlejšie analýzy. Okrem toho, každá tabuľka obsahuje aj informácie o dátume získania záznamu (*createdOn*), verzii aplikácie mPower (*appVersion*) a type mobilného telefónu (*phoneInfo*). Tieto atribúty však pre naše analýzy nebudú potrebné, keďže sa v prvom rade zameriame na vplyv vybraných aktivít (chôdza a pamäť) pre diagnostiku Parkinsonovej choroby, na čo tieto informácie určite vplyv mať nebudú. Pri aktivitách chôdza a pamäť sme pracovali aj s demografickými údajmi, čo zabezpečí väčšiu variabilitu výsledkov aj pre rôzne skupiny obyvateľov. Čisto demografické údaje o veľkosti 26 atribútov teda informovali o veku, rase, vzdelaní, zamestnaní, pohlaví, rodinnom stave, ďalších ochoreniach, priebehu Parkinsonovej choroby, užívaní liekov, používaní smartfónu, fajčení, atď.

V. ANALÝZA CHÔDZE

Aktivita zameraná na chôdzu účastníkov pozostávala z troch úloh, ktoré boli samostatne zaznamenávané v JSON súbore. Prvou úlohou bolo potrebné prejsť po rovnej čiare (20 krokov), následne druhá úloha bola zameraná na státie na mieste (30 sekúnd) a poslednou úlohou bolo potrebné prejsť naspäť na počiatočný bod prvej úlohy (20 krokov). Pri vykonávaní týchto úloh mali jednotliví účastníci svoj smartfón uložený v zadnom vrecku alebo v malej taške pri sebe. Kvôli veľkému množstvu dát získaných už len z jedného typu vykonaných úloh sme sa v publikácii [30] zamerali len na tú prvú, čiže prvotnú chôdzu po rovnej čiare pri 20 krokoch. Až 3101 účastníkov prispelo k získaniu dát z týchto troch pohybových aktivít, pričom celkovo vyprodukovali 35410 záznamov, keďže napríklad v prípade pacientov s Parkinsonovou chorobou bolo potrebné tieto aktivity vykonať 3 krát za deň (v ľubovoľnom čase, pred a po užití liekov). Zdraví účastníci mohli vykonať jednotlivé aktivity tiež viackrát za deň, pričom odporúčanie bolo rovnako tri krát za deň [28].

Spracovanie a extrahovanie jednotlivých atribútov z rozsiahlych JSON súborov trvalo veľmi dlho, pričom chôdza z vybranej úlohy bola zosumarizovaná do jednotlivých štatistických premenných. Pre každú os (*X,Y,Z*), priemerné zrýchlenie a priemerné trhnutie bolo k dispozícii 22 premenných, napríklad: priemer, smerodajná odchýlka, modus, medián, šikmosť, špicatosť, 1. a 3. kvartil, medzi-kvartilový rozsah, rozptyl a mnoho ďalších. Celkový počet exportovaných atribútov len z aktivity chôdza a jednej úlohy bolo 113. Po spojení demografickej tabuľky s údajmi o chôdzi pacientov sme ešte pripojili atribút, ktorý obsahoval dobu vykonania danej aktivity (v ľubovoľnom čase alebo pred/po užití liekov). Bolo to z toho dôvodu, že napríklad po užití liekov sa môže pacientom s Parkinsonovou chorobou mierne zlepšiť chôdza, a preto by nami získané modely nemuseli byť tak presné. Rovnako sme odstránili nepotrebné atribúty pre diagnostiku tohto ochorenia, ktoré informovali napríklad o rôznych technických veciach (údaje o mobilnom telefóne, používaní internetu), ďalej od ktorých bolo možné odvodiť, či pacient má alebo nemá Parkinsonovu chorobu (rok diagnostikovania a

prepuknutia symptómov) a samozrejme jednoznačne identifikátory pacientov a aktivít alebo dátumy nahratia dát do databázy. Celkovo nám však stále ostalo 166 atribútov, čo predstavuje veľkú množinu údajov, ktorú sme sa rozhodli zredukovať pomocou metód zameraných na výber atribútov (štatistické testy, odstránenie multikolinearity), ale aj regresných metód typických už pre fázu modelovania (Backward/Forward Stepwise selection a LASSO).

A. Výber atribútov

Pri použití štatistických testov sme sledovali závislosť jednotlivých vstupných atribútov ku cieľovému atribútu v binárnej forme, ktorý podával informáciu o tom, či pacient má alebo nemá diagnostikovanú Parkinsonovu chorobu. Keďže sme chceli vybrať čo najmenšiu podmnožinu, nastavili sme aj prísnejšiu hladinu významnosti na úrovni $\alpha = 0,01$. Pri vstupných numerických atribútoch sme najprv testovali ich normálne rozdelenie (Shapiro-Wilkov test) a následne na základe výsledkov použili Welchov t-test (normálne rozdelenie) alebo Wilcoxonov test (nemá normálne rozdelenie). V prípade vstupných nominálnych atribútov bol použitý Chi-kvadrát test, popri prípade Fisherov test. Výsledky štatistických testov nám preukázali, že k cieľovému atribútu sa prejavila závislosť u 98 numerických a 17 nominálnych atribútov. Na odstránenie vysokej kolinearity medzi vstupnými numerickými atribútmi sme zvolili pre ukazovateľ VIF (Inflačný faktor rozptylu) hraničný bod na hodnote 5. V našom prípade dosiahlo 44 atribútov hodnotu $VIF > 5$, preto boli odstránené, a tak sa nám po odstránení multikolinearity zredukoval počet zo 166 na 122 atribútov. Pri použití metód ako Backward a Forward Stepwise Selection (BSS a FSS) sme sa zamerali na najnižšie hodnoty ukazovateľa BIC, pretože v oboch prípadoch obsahoval najmenší počet atribútov. Pri FSS naša konečná množina obsahovala 67 a pri BSS 80 atribútov. Poslednou metódou bola LASSO, čo je regularizačná regresná metóda s cieľom zmenšiť niektoré hodnoty regresných koeficientov až na nulu, vďaka čomu tento atribút môžeme následne odstrániť. Pri vypočítaní optimálnej hodnoty regularizačného koeficientu $\lambda = 0,000169$ pomocou 10-násobnej krížovej validácie sa nám zredukoval počet na 119 atribútov. Vo fáze prípravy dát a výberu podmnožiny atribútov nám teda ostalo k dispozícii 5 podmnožín atribútov získaných rôznymi metódami ich výberu. Okrem kolinearity bol výber realizovaný na základe vzťahu ku diagnostikovaní Parkinsonovej choroby, preto ku celkovému počtu vybraných atribútov danou metódou je potrebné pripočítať aj cieľový atribút. Pri spomínanej kolinearite došlo len k odstráneniu vstupných navzájom závislých numerických atribútov, ktoré pravdepodobne boli nositeľmi redundantných informácií, a preto k odstráneniu cieľového atribútu v binárnej forme nedošlo. V konečnom dôsledku sme teda dostali týchto 5 podmnožín:

1. Podmnožina (výber na základe štatistických testov) – 116 atribútov,
2. Podmnožina (odstránenie multikolinearity u numerických atribútov) – 122 atribútov,

3. Podmnožina (výber na základe metódy FSS) – 68 atribútov,
4. Podmnožina (výber na základe metódy BSS) – 81 atribútov,
5. Podmnožina (výber na základe metódy LASSO) – 120 atribútov.

Vo všetkých piatich podmnožinách sa napríklad z demografických údajov vyskytovali atribúty, ako zamestnanie, rodinný stav, vzdelanie, pohlavie a ochorenia (infekcia moču, mŕtvica, infarkt). V prípade údajov z chôdze účastníkov sa prevažne vyskytovali súhrnné ukazovatele získané z osi Z (frekvencia s maximálnym vrcholom periodogramu Lomb-Scargle, šikmosť, autokorelácia, priemer a variačný koeficient).

B. Modelovanie a vyhodnotenie

Na vytvorenie modelov sme použili metódu Naivného Bayesovského klasifikátora a rôzne algoritmy rozhodovacích stromov, ktoré boli vyhodnotené pomocou ukazovateľov, ako presnosť, senzitivita a špecificita pri použití 10-násobnej krížovej validácie. Pri binárnej klasifikácii je presnosť často nepostačujúci ukazovateľ, pretože jeho výsledná hodnota môže byť skreslená hlavne pri nevyváženej početnosti dvoch tried cieľového atribútu. Pri senzitivite vieme presne zistiť, koľko pacientov trpiacich daným ochorením dokázal náš model naozaj identifikovať a naopak špecificita nás informuje o tom, koľko zdravých subjektov vedel náš model rozpoznať. V nasledujúcej časti sú zobrazené výsledky modelov na rôznych podmnožinách, pričom jednotlivé tabuľky sú rozdelené na základe výsledného ukazovateľa – presnosť, senzitivita, špecificita.

Tab. 6 Priemerná presnosť modelov získaných z chôdze účastníkov

Model	Priemerná presnosť na testovacej množine vyjadrená v %					Priemer
	1.	2.	3.	4.	5.	
Ctree	97,111	99,072	98,892	98,883	98,874	98,566
C4.5	93,448	98,272	98,473	98,484	98,225	97,380
C5.0	97,498	99,447	99,107	99,057	99,43	98,908
Random Forest	97,35	99,395	98,709	98,649	99,488	98,718
rPart	92,043	97,556	97,192	97,187	97,556	96,307
Naive Bayes	81,711	91,766	92,124	89,718	90,376	89,139
Priemer	93,194	97,585	97,416	96,996	97,325	

Tab. 7 Priemerná senzitivita modelov získaných z chôdze účastníkov

Model	Priemerná senzitivita na testovacej množine vyjadrená v %					Priemer
	1.	2.	3.	4.	5.	
Ctree	97,792	99,231	99,177	99,169	99,177	98,909
C4.5	95,126	99,036	98,882	98,858	98,971	98,175
C5.0	98,111	99,497	99,194	99,204	99,497	99,101
Random Forest	99,459	99,443	98,486	98,397	99,653	99,088
rPart	94,701	97,300	96,900	96,896	97,300	96,619
Naive Bayes	87,113	93,792	96,968	95,980	95,961	93,963
Priemer	95,384	98,050	98,268	98,084	98,427	

Tab. 8 Priemerná špecificita modelov získaných z chôdze účastníkov

Model	Priemerná špecificita na testovacej množine vyjadrená v %					Priemer
	1.	2.	3.	4.	5.	
Ctree	95,521	98,706	98,231	98,220	98,170	97,770
C4.5	89,558	96,501	97,529	97,620	96,500	95,542
C5.0	96,078	99,331	98,907	98,726	99,274	98,463
Random Forest	87,609	99,161	99,462	99,496	98,703	96,886
rPart	85,870	98,159	97,875	97,865	98,159	95,586
Naive Bayes	69,168	87,063	80,870	75,181	77,407	77,938
Priemer	87,301	96,487	95,479	94,518	94,702	

Na úvod je potrebné poznamenať, že pri vytvorení modelov na celej dátovej množine 166 atribútov boli vo všetkých prípadoch dosiahnuté najnižšie hodnoty presnosti, senzitivity a špecificity. Po aplikovaní rôznych metód a techník pre výber podmnožiny atribútov došlo teda k zlepšeniu dosiahnutých výsledkov, preto si ich detailnejšie popíšeme už iba z pohľadu jednotlivých podmnožín. Tieto výsledky sú zobrazené v Tab. 6, Tab. 7 a Tab. 8. Už na prvý pohľad je viditeľné, že po výbere podmnožín atribútov boli vo všetkých prípadoch dosiahnuté najhoršie výsledky pri použití metódy Naivného Bayesovského klasifikátora, pričom z pohľadu výsledných ukazovateľov dosahoval najvyššie priemerné hodnoty pri senzitivite (93,963%), nasledovala presnosť (89,139%) a na záver špecificita (77,938%). Naopak najlepšie výsledky opäť pri všetkých priemerných hodnotách výsledných ukazovateľov dosiahol algoritmus rozhodovacieho stromu C5.0 v rovnakom poradí a to senzitivita (99,101%), presnosť (98,908%) a špecificita (98,463%). Z pohľadu výberu vhodnej podmnožiny boli dosiahnuté najlepšie výsledky v dvoch prípadoch na množine atribútov očistených od multikolinearity (presnosť – 97,585%, špecificita – 96,487%) a v jednom prípade pri selekcii atribútov použitím metódy LASSO (senzitivita – 98,427%). Vo všetkých prípadoch boli najhoršie výsledky získané pri výbere atribútov na základe výsledkov štatistických testov (senzitivita – 95,384%, presnosť – 93,194%, špecificita – 87,301%). Pri porovnaní najvyšších hodnôt všetkých troch ukazovateľov dosiahol najlepšie výsledky algoritmus RandomForest (senzitivita – 99,653%, špecificita – 99,496%, presnosť – 99,488%), pričom najvyššia presnosť a senzitivita bola získaná na podmnožine dát vybraných metódou LASSO a pri špecificite sa jednalo o podmnožinu dát vybranú pomocou metódy BSS.

Pri zameraní sa na tieto dáta získané z chôdze jednotlivých účastníkov štúdií je vidieť, že získané modely dosahovali vyššie hodnoty senzitivity ako špecificity aj keď počet záznamov pacientov s Parkinsonovou chorobou bol menší ako zdravých jedincov (v pomere 10346:24025). Výsledné hodnoty ukazovateľov sa pohybovali na veľmi vysokých hodnotách, často až na úrovni 98-99%, napríklad pri algoritme RandomForest pri použití podmnožiny dát získanej z LASSO sme vedeli identifikovať až 99,653% pacientov s Parkinsonovou chorobou. Tieto výsledky môžu teda odzrkadľovať to, že chôdza ľudí s týmto ochorením je značne rozdielna od zdravých jedincov, a preto je potrebné sa tejto problematike venovať aj v budúcnosti, čo by v konečnom dôsledku mohlo pomôcť a urýchliť prvotnú diagnostiku Parkinsonovej choroby. Pri získaní veľkého množstva atribútov

zo senzorov, ako sme mali v tomto prípade, je potrebné použiť aj vhodný spôsob na výber podmnožiny atribútov z dôvodu jednoduchšej interpretácie výsledkov a taktiež dobou potrebnou na výpočet jednotlivých modelov. V tomto prípade sme vďaka tomu dosiahli aj lepšie výsledky z pohľadu vyšších hodnôt presnosti, senzitivity a špecificity. Z pohľadu metód pre výber najlepšej podmnožiny atribútov pre tvorbu modelov sa jednoznačne najhoršie javia štatistické testy, kedy vo všetkých prípadoch dosiahli najnižšie priemerné hodnoty presnosti, senzitivity a špecificity. Naopak v dvoch prípadoch sme dosiahli najvyššie priemerné hodnoty presnosti a špecificity na množine dát s odstránenou multikolaritou a v jednom prípade, najvyššiu senzitivitu, pri využití podmnožiny dát získanej metódou LASSO. Pri porovnaní metód FSS a BSS sa dosiahnuté výsledky medzi sebou veľmi neodlišovali a často bol rozdiel v rozmedzí 1%. Na základe týchto výsledkov preto neodporúčame selektovať atribúty na základe závislosti ku cieľovému atribútu pomocou štatistických testov. Naopak, výber najlepšej podmnožiny atribútov je vhodné urobiť pomocou metódy LASSO alebo na množine dát očistených od multikolinearity. Po implementovaní vhodného predspracovania dát a následne najlepších modelov by bolo možné v rámci podobnej aplikácie upozorniť zdravých účastníkov pri vykonávaní jednotlivých aktivít na to, že s určitou pravdepodobnosťou sa môže jednať v ich prípade o Parkinsonovu chorobu s odporúčaním navštíviť odborníka. Samotný výber podmnožiny atribútov spolu s vytvorením modelov boli implementované aj do webovej aplikácie RShiny [31], ktorej ukážka je podrobnejšie popísaná v našej publikácii [30].

VI. ANALÝZA PAMÄTE

V ďalšej publikácii [32] sme sa zamerali na pamäťovú aktivitu jednotlivých účastníkov, ktorá je monitorovaná na základe hry zameranej na zapamätanie si postupnosti rozsvietených kvetov na obrazovke [33]. Rovnako ako pri chôdzi musel účastník v prípade pozitívnej diagnostiky Parkinsonovej choroby zadať informáciu, či danú aktivitu vykonáva v ľubovoľnom čase alebo pred/po užití liekov. Meranie pamäťovej aktivity [29] pozostávalo z 5 úrovní náročnosti, pričom pri prvej úrovni sa rozsvietili postupne 3 kvety na ploche o veľkosti 3x3 a pri najťažšej úrovni až 7 kvetov na ploche 4x4. Účastník si musel zapamätať poradie, v akom sa kvety zaradom na displeji mobilného telefónu rozsvetcovali. Atribúty získané z vykonania tejto hry zameranej na pamäť popisovali informácie o počte odohraných úrovní, celkovom skóre, počte chýb, čase spustenia/ukončenia hry a taktiež o čase vykonania aktivity z pohľadu parkinsonikov (v ľubovoľnom čase, pred/po užití liekov). Okrem toho bol pre každý záznam tejto aktivity k dispozícii ešte jeden súbor v JSON formáte, kde boli zaznamenané detailnejšie informácie o každom dotyku na obrazovku, napríklad X a Y súradnice displeja, poradové čísla kvetov, čas a správnosť každej voľby kvetu a množstvo ďalších. Z týchto detailnejších informácií bolo potom možné exportovať ďalšie atribúty pomocou skriptu, ktorý tieto dáta v JSON súboroch zosumarizoval a získali sme tak dodatočné atribúty, ktoré vyjadrovali: celkovú vzdialenosť, celkový čas, počet správne vybraných kvetov, priemerné poradové číslo chybné vybraného kvetu, celkový počet opätovne vybraných kvetov a štatistické ukazovatele

priemer/odchýlka/medián časov prvého vybraného kvetu, vzdialenosti prvého vybraného kvetu, časov vybraných kvetov okrem prvého, vzdialenosti vybraných kvetov okrem prvého.

Prvá skupina atribútov vyjadrujúca určitú vzdialenosť zachytáva vzdialenosť medzi kliknutým miestom na obrazovke a stredom kvetu, ktorý mal byť vybraný. Tým pádom atribút informujúci o celkovej vzdialenosti vyjadruje súčet všetkých týchto vzdialeností pri všetkých úrovniach hry zameranej na pamäťovú aktivitu. Druhá skupina atribútov sa zameriava na čas, ktorý uplynie medzi určitými výbermi kvetov, kde súčtom týchto všetkých časov vieme získať informáciu o dĺžke vykonávania jednotlivých úrovní, resp. celej hry. Samozrejme, ak účastník neprejde všetkými úrovňami, má menší celkový čas, avšak to je ošetrené atribútom, ktorý informuje o počte odohraných úrovní. V tejto hre taktiež záleží, ktorý kvet v poradí daný účastník netrafi, preto odlišujeme skupiny atribútov času a vzdialenosti pre prvý kvet a pre všetky ostatné. V prípade, ak účastník klikne na obrazovku, kde sa nenachádza žiaden kvet, tak ich počet sa ukladá do atribútu vyjadrujúceho celkový počet opätovne vybraných kvetov. Počet účastníkov, ktorí túto aktivitu vykonali, bol 968.

Pri pochopení dát sme sa zamerali aj na vzťahy medzi jednotlivými atribútmi, pričom pre tých numerických sme použili korelačnú maticu. Silné korelácie vyšli v prípadoch, kedy jednotlivé atribúty boli vo väčšine prípadov od seba navzájom odvodené alebo logicky na seba navdžovali. Pri stredných koreláciách sa opäť opakovali podobné výsledky, pričom vzťah medzi skupinami atribútov pamäťovej aktivity a atribútov súvisiacich s diagnostikou Parkinsonovej choroby sa medzi numerickými atribútmi nevyskytol. S vekom nadobudli stredne silné korelácie atribúty informujúce o počte rokov s diagnózou (0,6771254), počte rokov od prejavu pohybových symptómov (0,6769) a počte správne vybraných kvetov (0,5609499). Multikolinearitu sme v dátach opäť sledovali pomocou inflačného faktoru rozptylu (VIF), kde sme rovnako ako v predchádzajúcom prípade zvolili jeho hraničnú hodnotu na 5. Bolo odstránených 6 numerických atribútov (v zátvorke je uvedená VIF hodnota): počet rokov s diagnostikou (154616,6), celkové skóre (61,94148), priemerný čas (12,29768), obdobie od ukončenia fajčenia (8,961529), priemer časov prvého vybraného kvetu (8,495816) a počet správne vybraných kvetov (8,422482). Jednalo sa presne o tie atribúty, ktoré boli silne korelované voči ďalšiemu numerickému atribútu. Vzťahy ku cieľovému atribútu v binárnej forme (má/nemá Parkinsonovu chorobu) sme analyzovali na základe vhodných štatistických testov rovnakým spôsobom ako pri analýze chôdze účastníkov, avšak keďže sa jednalo o menší počet atribútov tak sme stanovili hladinu významnosti α na hodnotu 0,05. Pri sledovaní vplyvu nominálnych atribútov ku cieľovému atribútu bolo zistené, že na konečnú diagnózu nevlývajú napríklad rôzne typy ochorení (napríklad skleróza multiplex, endometrická rakovina, koronárna arteriálna choroba), ale ani informácia o tom, či účastník fajčil alebo podstúpil nejakú operáciu. Naopak, značný vplyv na diagnostiku Parkinsonovej choroby, a teda najmenšie p-hodnoty mali napríklad atribúty, ktoré sú typické len u účastníkov s týmto ochorením (čas užívania liekov, posledná návšteva u odborníka, používanie smartfónu a smartfónu pri hľadaní informácií o chorobe), ale aj ďalšie zaujímavejšie

skupiny atribútov – vzdelanie, zamestnanie, rodinný stav, pohlavie a rôzne typy ochorení (vysoký krvný tlak, určité druhy rakoviny, infekcia močových ciest atď.). Z pohľadu numerickým atribútov neprejavovali k cieľovému atribútu závislosť na danej hladine významnosti informácie o odchýlke/mediáne vzdialenosti prvého vybraného kvetu, počet odohraných úrovní, celkový čas a celková odchýlka vzdialeností. Najvyššiu závislosť a tým pádom aj najnižšie p-hodnoty nadobudli aj atribúty, ktoré logicky vplývajú na cieľový atribút (počet rokov od prejavu pohybových symptómov, počet rokov užívania liekov, počet rokov s diagnostikou), ale aj ďalšie atribúty, ako vek, medián/priemer/odchýlka časov, odchýlka časov prvého vybraného kvetu, počet chýb atď.

A. Výber atribútov

Vo fáze prípravy dát sme sa v prvom rade zamerali na odstránenie nepotrebných alebo nevhodných atribútov, napríklad ak na základe nich bolo možné zistiť, či pacient má alebo nemá Parkinsonovu chorobu. Ako príklad si môžeme uviesť, ak počty rokov od diagnostiky, užívania liekov, prepuknutia symptómov sú väčšie ako 0, tak sa samozrejme jedná o parkinsonika. Nepotrebné atribúty obsahovali napríklad informácie o účasti na podobnom výskume, starostlivosti pacienta s týmto ochorením alebo otázky zamerané na internetové a mobilné údaje. Okrem toho sme taktiež v niektorých prípadoch spracovali chýbajúce hodnoty, ktoré bolo možné logicky doplniť na základe hodnôt skupiny podobných atribútov, čiže napríklad ak pacient nemal uvedený počet rokov koľko fajčí a následne údaje o ňom informovali, že je nefajčiar, nevyfajčí ani jeden balík denne, tak pre tento atribút sme doplnili hodnotu nula. Po ukončení tohto spracovania dát sme ešte vytvorili 4 dátové množiny, kde v prvej boli zahrnuté všetky atribúty ponechané po fáze prípravy dát, druhá vznikla z množiny dát očistených od multikolinearity, tretia obsahovala iba štatisticky významné atribúty a štvrtá bola kombináciou druhej a tretej množiny. Na týchto 4 rôznych dátových množinách sme následne aplikovali ešte metódy Forward a Backward Stepwise Selection, pričom sme vo vybranej dátovej množine ponechali len tie atribúty, ktoré boli zvolené na základe oboch prístupov (Forward aj Backward). Rovnako na všetkých podmnožinách sme použili aj metódu LASSO, ktorá zmenšila niektoré hodnoty regresných koeficientov na nulu. Modely pomocou Naivného Bayesovského klasifikátora a algoritmov rozhodovacích stromov sme vytvorili na 4 podmnožinách bez dodatočného aplikovania metód na výber atribútov, ale aj na dátach získaných na základe kombinácie 4 podmnožín a aplikovaním metód Forward/Backward Stepwise Selection a LASSO. Z celkového počtu 54 atribútov nám pri jednotlivých kombináciách zostali početnosti, ktoré sú zobrazené v Tab. 9.

Tab. 9 Počet vybraných atribútov pri určitých kombináciách

	Pôvodná množina	Multikolinearita	Štatistické testy	Multikolinearita a štatistické testy
BSS a FSS	41	37	35	25
LASSO	22	19	19	17

B. Modelovanie a vyhodnotenie

Pri samotnom modelovaní sme chceli určiť to, či daný účastník štúdie má alebo nemá Parkinsonovu chorobu. Ako sme už spomínali, jednotlivé modely sme vytvorili na rôznych podmnožinách v kombinácii s aplikovaním metód pre výber atribútov Forward/Backward Stepwise Selection a LASSO. Pre tvorbu rozhodovacích stromov boli použité algoritmy *tree*, *ctree*, *rpart*, *RandomForest*, *Bagging* *CART* a *rozšírené prístupy algoritmu C5.0 (C5.0, Rule-based C5.0, Boosted C5.0, Rule-based & Boosted C5.0)*. Testovanie získaných modelov prebiehalo pomocou 10-násobnej krížovej validácie, kde cieľový ukazovateľ vyjadruje priemer medzi výslednou senzitivitou a špecificitou.

Opäť najhoršie výsledky boli dosiahnuté pri použití metódy Naivného Bayesovského klasifikátora, kde sa pri všetkých podmnožinách pohyboval priemer senzitivity a špecificity na úrovni 88-89%, pričom najvyšší priemer (89,8557%) bol dosiahnutý na dátovej podmnožine získanej odstránením multikolinearity a následne aplikovaním metódy LASSO. Naopak najmenší priemer 88,6658% sme dostali pri použití pôvodnej dátovej množiny, kde sme pre výber atribútov nepoužili žiadnu metódu. Z pohľadu rozhodovacích stromov sme už dosiahli oveľa lepšie hodnoty, pričom samostatne najvyššiu priemernú hodnotu senzitivity a špecificity dosiahol model generovaný algoritmom C5.0 (rule-based + boosted) na úrovni 98,0898%, ktorý bol vytvorený na množine dát očistených od multikolinearity. Druhým v poradí (98,04016%) bol model opäť vytvorený rovnakým algoritmom pri použití dát odstránených od multikolinearity a následne aplikovaním oboch prístupov metódy Stepwise Selection. Najhoršiu výslednú hodnotu 88,9391% dosiahol algoritmus *tree* vytvorený na podmnožine vytvorenej kombináciou odstránenia multikolinearity a aplikovaním metódy LASSO. Táto percentuálna hodnota je dokonca nižšia ako bola tá najlepšia pri použití metódy Naivného Bayesovského klasifikátora. Algoritmus rozhodovacieho stromu *tree* z celkového hľadiska dosiahol najmenšie hodnoty priemeru senzitivity a špecificity, pričom priemer všetkých hodnôt tohto ukazovateľa na všetkých podmnožinách sa pohybovala iba na úrovni 90,4459%. Na druhej strane, najlepší algoritmus rozhodovacieho stromu bol Rule-Based & Boosted C5.0, pri ktorom výsledný priemer na všetkých podmnožinách dosiahol hodnotu 97,4296%. Z hľadiska výberu vhodnej podmnožiny atribútov sa najlepšie preukázala kombinácia prvotného odstránenia multikolinearity z dát a následného aplikovania oboch prístupov metódy Stepwise Selection, pričom výsledný priemer zo všetkých algoritmov dosiahol hodnotu 95,763%. Na druhej, za najnevhodnejší spôsob sa javila kombinácia výberu na základe štatistických testov a následného aplikovania metódy LASSO, kedy sa priemer pohyboval na úrovni 94,459%. Pri detailnejšom pohľade na najlepší model (98,0898%) vygenerovaný algoritmom Rule-Based & Boosted C5.0 si môžeme všimnúť, že tento model považoval za najdôležitejšie atribúty vek, používanie smartfónu, zamestnanie, dĺžka fajčenia v rokoch a ochorenia (Alzheimerova choroba, kolorektálna rakovina, mŕtvica, AIDS). Zo skupiny atribútov získaných z pamäťovej aktivity boli najdôležitejšie medián časov, priemer vzdialeností a odchýlku časov.

VII. ZÁVER

Pomocou metód dolovania v dátach je možné z veľkého množstva dát získať potenciálne užitočné znalosti a vzory, ktoré sú na prvý pohľad ťažko rozpoznateľné. V rôznych oblastiach môžu byť takto nájdené znalosti veľmi nápomocné, obzvlášť v medicíne, kde v konečnom dôsledku môžu urýchliť a spresniť celý diagnostický proces alebo slúžiť lekárom ako podpora pri rozhodovaní v komplikovaných situáciách. Rýchlejšou diagnostikou vážnych a ťažko liečiteľných ochorení je možné nastoliť potrebnú liečbu oveľa skôr, vďaka čomu sa môže rapídne zvýšiť pravdepodobnosť uzdravenia daného pacienta alebo aspoň udržať kvalitu jeho života na čo najvyššej úrovni. Príspevok tejto dizertačnej práce k tomuto širšiemu cieľu bol najmä v dvoch sledovaných aspektoch dátovej analytiky v medicínskych aplikáciách, a síce vo fáze predspracovania dát pri výbere najvhodnejšej podmnožiny atribútov a vo fáze modelovania.

V tejto práci sme pracovali s väčším množstvom dátových množín, pričom prvotné analýzy boli zamerané na prácu s voľne dostupnými dátami zaznamenávanými reč pacientov, pri ktorých sme klasifikovali pacientov do dvoch tried (áno/nie). Pre lepšie pochopenie samotnej choroby a jej symptómov sme sa venovali aj určeniu konkrétneho štádia, kde sme poukázali na možné chyby modelov pri klasifikácii pacientov do štádií 2, 2.5 a 3, pretože na základe testov ANOVA a grafického zobrazenia vybraného atribútu bolo možné vidieť neočakávane prudký nárast hodnôt pri štádiu 1.5. Venovali sme sa taktiež aj odstráneniu multikolinearity v dátach, čo v konečnom dôsledku pomohlo k zvýšeniu presnosti až na úroveň 95%. Pri analýze dát z chôdze a pamäte pacientov sme sa zamerali taktiež na spôsob výberu najlepšej podmnožiny atribútov aj pomocou metód, ktoré už vygenerujú samotné regresné modely len s podstatnými atribútmi. Pre porovnanie sme použili aj typické metódy pre fázu predspracovania dát, ako sú štatistické testy a odstránenie multikolinearity. Z výsledkov získaných z chôdze pacientov je nutné poznamenať, že najlepšie hodnoty ukazovateľov presnosť, senzitivita a špecificita dosiahli modely rozhodovacích stromov vytvorené na podmnožine atribútov, kde bol ich výber realizovaný odstránením multikolinearity, poprípade metódou LASSO. Naopak, najhoršie výsledky boli získané na podmnožine atribútov vybraných na základe štatistických testov, kde sa hodnoty sledovaných ukazovateľov pohybovali v priemere o 3-4% nižšie. Pri pamäti pacientov sme už používali podmnožiny atribútov získané pomocou rôznych kombinácií metód podrobne popísaných vyššie. Najlepšie výsledky dosiahla opäť podmnožina očistená od multikolinearity, poprípade ešte následným aplikovaním metód Forward a Backward Stepwise Selection. Na základe analýzy súčasného stavu je však možné poznamenať, že množstvo autorov vo svojich výskumoch používali pre výber podmnožiny atribútov len štatistické testy, čo sa na základe našich výsledkov nejaví ako veľmi vhodný spôsob. Naopak nami navrhnuté metódy, ktoré sú síce používané na generovanie regresných modelov, dosiahli lepšie výsledky v porovnaní so štatistickými testami. Z pohľadu porovnania dosiahnutých výsledkov presnosti klasifikácie na jednotlivých dátových vzorkách pacientov s Parkinsonovou chorobou sa najlepšie javili výsledky dosiahnuté na dátach

zaznamenávajúcich chôdzu pacientov, nasledovala pamäť a nakoniec reč.

A. Výber atribútov

Na základe záverov popísaných v tomto článku, ktoré boli získané analýzou našich výsledkov, je možné formulovať nasledovné prínosy pre vedu a pre prax:

- Návrh a verifikácia ďalších spôsobov pre výber atribútov vo fáze predspracovania dát pomocou metód (popríklad ich kombináciou), ktoré sa tradične používajú až pri samotnom modelovaní,
- Zlepšenie konkrétnych medicínskych procesov (pochopenie vzťahov medzi symptómami, výber najdôležitejších biomarkerov, vygenerovanie ľahko interpretovateľných modelov, zvýšenie presnosti) pomocou vhodného začlenenia a spôsobov využitia metód dátovej analytiky a strojového učenia,
- Identifikácia najlepšej dátovej množiny z aktivít (reč, chôdza, pamäť), pomocou ktorých je možné najpresnejšie diagnostikovať Parkinsonovu chorobu, popríklad určiť presné štádium a poukázať aj na možnosť potencionálneho výskytu chyby pri tejto úlohe na dátach z reči pacientov.

POĎAKOVANIE

Táto publikácia vznikla vďaka podpore Agentúry na podporu výskumu a vývoja na základe Zmluvy č. APVV-17-0550 (Determinanty zvýšeného kardiovaskulárneho rizika a ich prognostický význam analyzovaný pomocou strojového učenia pri diagnostike vysokorizikových jedincov). Poďakovanie patrí taktiež všetkým účastníkom štúdie mPower za venovanie svojho času pri poskytovaní dát, technickým príspevkom od Dwayne Jeng, Erin Mounts, Alx Dar, Eric Wu, Shannon Young pre podporu aplikácie mPower a systému pre zber dát (Bridge). Okrem toho sme vďační za usmernenie od Caroline Tannerovej ohľadom návrhu štúdie a Katherine Possinovej a Joel Kramerovej za návrh a poskytnutie dát z pamäťovej aktivity. Y Media Labs pre skorý vývoj aplikácie, Apple pre počiatočný vývoj aplikácie a open-source ResearchKit framework. Financovanie poskytlá nadácia Robert Wood Johnson.

REFERENCIE

- [1] M. Hany Harb, S. Abeer Desuky, "Feature Selection on Classification of Medical Datasets based on Particle Swarm Optimization," in *International Journal of Computer Applications*, vol. 104, no. 5, pp. 14-14, 2014.
- [2] S. Devaraj, S. Paulraj, "An Efficient Feature Subset Selection Algorithm for Classification of Multidimensional Dataset," in *The Scientific World Journal*, vol. 2015, p. 9, 2015. ISSN 2356-6140.
- [3] V. Sangeetha, J. Preethi, M. Sreeshakthy, "Survey on Medical Data Cluster analysis using Feature Selection and Neural Networks," in *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, vol. 3, no. 11, pp. 3731-3738, 2014. ISSN 2278-1323.
- [4] V. Santos, N. Datia, M. P. M. Pato, "Ensemble Feature Ranking Applied to Medical Data," in *Procedia Technology*, vol. 17, pp. 223-230, 2014. ISSN 2212-0173.

- [5] M. Vadovský, "Selecting attributes for classification models in a medical domain," in *SCYR 2018*, Košice: TU, pp. 226-227, 2018. ISBN 978-80-553-2972-7.
- [6] M. Vadovský, "Výber vhodných atribútov pre tvorbu klasifikačných modelov v oblasti medicíny," in: *Data a Znalosti & WIKT 2018*, Brno: Vysoké učení technické v Brně, pp. 83-88, 2018. ISBN: 978-80-214-5679-2.
- [7] G. James et al., *An Introduction to Statistical Learning: with Applications in R*. New York: Springer-Verlag, 2013. Springer Texts in Statistics. ISBN 978-1-4614-7137-0.
- [8] C. B. Garcia et al., "Collinearity: revisiting the variance inflation factor in ridge regression," in *Journal of Applied Statistics*, vol. 42, no. 3, pp. 648-661, 2015. ISSN 0266-4763.
- [9] *Statistical Tests*. [online]. Dostupné na internete: <<https://www.statisticssolutions.com/statistical-tests>>.
- [10] J. Du Prel et al., "Choosing Statistical Tests," in *Deutsches Ärzteblatt International*, vol. 107, no. 19, pp. 343-348, 2010. ISSN 1866-0452.
- [11] J. Du Prel et al., "Confidence Interval or P-Value?," in *Deutsches Ärzteblatt International*, vol. 106, no. 19, pp. 335-339, 2009. ISSN 1866-0452.
- [12] A. Victor et al., "Judging a Plethora of p-Values," in *Deutsches Ärzteblatt International*, vol. 107, no. 4, pp. 50-56, 2010. ISSN 1866-0452.
- [13] J. D. Lepeér, "Choosing the correct statistical test in SAS, STATA, SPSS and R." [online]. Dostupné na internete: <<https://stats.idre.ucla.edu/other/mult-pkg/whatstat/>>.
- [14] NCSS Statistical Software, "Stepwise Regression," [online]. Dostupné na internete: <https://ncss-wpengine.netdna-ssl.com/wp-content/themes/ncss/pdf/Procedures/NCSS/Stepwise_Regression.pdf>.
- [15] T. Hastie, R. Tibshirani, R. J. Tibshirani, "Extended Comparisons of Best Subset Selection, Forward Stepwise Selection, and the Lasso," in *arXiv:1707.08692 [stat]*. 2017. Dostupné na internete: <<http://arxiv.org/abs/1707.08692>>.
- [16] R. Miyashiro, Y. Takano, "Subset selection by Mallows' Cp: A mixed integer programming approach," in *Expert Systems with Applications*, vol. 42, no. 1, pp. 325-331, 2015. ISSN 0957-4174.
- [17] M. Drton, M. Plummer, "A Bayesian information criterion for singular models," in *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, vol. 79, no. 2, pp. 323-380, 2017. ISSN 1467-9868.
- [18] L. Dirick, G. Claeskens, B. Baesens, "An Akaike information criterion for multiple event mixture cure models," in *European Journal of Operational Research*, vol. 241, no. 2, pp. 449-457, 2015. ISSN 0377-2217.
- [19] A. F. Yehia, M. Saleh, A. N. Ahmed, "An Adjusted Correlation Coefficient for Canonical Correlation Analysis", p. 6, 2016.
- [20] T. Hastie, R. Tibshirani, M. Wainwright, *Statistical Learning with Sparsity: The Lasso and Generalizations*. CRC Press, 2015. ISBN 978-1-4987-1217-0.
- [21] M. Vadovský, J. Paralič, "Predikcia Parkinsonovej choroby pomocou signálov reči použitím metód dolovania v dátach," *WIKT & DaZ 2016: 11th Workshop on Intelligent and Knowledge Oriented Technologies 35th Conference on Data and Knowledge*, Bratislava: STU, pp. 329-333, 2016. ISBN: 978-80-227-4619-9.
- [22] M. Sebera, "Vícerozmerné statistické metódy: Analýza rozptylu." [online]. Dostupné na internete: <http://www.fsps.muni.cz/~sebera/vicerozmerna_statistika/anova.html>.
- [23] M. Vadovský, J. Paralič, "Utilizing processed records of patient's speech in determining the stage of Parkinson's disease," in *Acta Electrotechnica et Informatica*, Košice: Fakulta elektrotechniky a informatiky, vol. 18, no. 3, pp. 35-40, 2018. ISSN 1335-8243.
- [24] Y. Freund, R. E. Schapire, "A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting," in *Journal of Computer and System Sciences*, vol. 55, no. 1, pp. 119-139, 1997. ISSN 0022-0000.
- [25] T. M. Oshiro et al., "How Many Trees in a Random Forest?" in *Machine Learning and Data Mining in Patter Recognition. MLDM 2012. Lecture Notes in Computer Science*, Berlin, Heidelberg: Springer-Verlag, roč. 7376, pp. 154-168, 2012. ISBN 978-3-642-31537-4.

- [26] M. Vadovský, J. Paralič, "Predikcia Parkinsonovej choroby pomocou signálov reči použitím metód dolovania v dátach," WIKT & DaZ 2016: 11th Workshop on Intelligent and Knowledge Oriented Technologies 35th Conference on Data and Knowledge, Bratislava: STU, pp. 329-333, 2016. ISBN: 978-80-227-4619-9.
- [27] M. Vadovský, J. Paralič, "Data Collection Methods for the Diagnosis of Parkinson's Disease," in *International Journal on Biomedicine and Healthcare*, vol. 5, no. 1, pp. 28-32, 2017. ISSN 1805-8698.
- [28] A. D. Trister, E. R. Dorsey, S. H. Friend, "Smartphones as new tools in the management and understanding of Parkinson's disease," in *NPJ Parkinson's disease*, vol. 2, p. 16006, 2016. ISSN 2373-8057.
- [29] B. M. Bot et al., "The mPower study, Parkinson disease mobile data collected using ResearchKit," in *Scientific Data*, vol. 3, p. 160011, 2016. ISSN 2052-4463.
- [30] M. Vadovský, J. Paralič, Z. Tocimáková, "Spracovanie a analýza dát z mobilnej aplikácie na sledovanie pohybových príznakov Parkinsonovej choroby," in *Electrical Engineering and Informatics 9: proceedings of the Faculty of Electrical Engineering and Informatics of the Technical University of Košice*, Košice: FEI TU, pp. 353-358, 2018. ISBN 978-80-553-2713-6.
- [31] Z. Tocimáková, "Spracovanie a analýza dát z mobilnej aplikácie na sledovanie pohybových príznakov Parkinsonovej choroby," *Bakalárska práca*. Košice: FEI TU, p. 67, 2018.
- [32] M. Vadovský, J. Paralič, N. Gross, "Spracovanie a analýza dát z mobilnej aplikácie na sledovanie kognitívnych príznakov Parkinsonovej choroby," in *Electrical Engineering and Informatics 9: proceedings of the Faculty of Electrical Engineering and Informatics of the Technical University of Košice*, Košice: FEI TU, pp. 746-751, 2018. ISBN 978-80-553-2713-6.
- [33] N. Gross, "Spracovanie a analýza dát z mobilnej aplikácie na sledovanie kognitívnych príznakov Parkinsonovej choroby," *Bakalárska práca*. Košice: FEI TU, p. 54, 2018.

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: 2585-9587