

Žilinská univerzita v Žiline
Fakulta riadenia a informatiky

Ing. Veronika Olešnaníková

Autoreferát dizertačnej práce

**VYUŽITIE KOMPRESNÉHO SNÍMANIA
V BEZDRÔTOVÝCH SIEŤACH SENZOROV**

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

Aplikovaná informatika

v študijnom odbore

9.2.9 aplikovaná informatika

Žilina, apríl, 2017

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

Predkladateľ: Ing. Veronika Olešnaníková
Žilinská univerzita v Žiline
Fakulta riadenia a informatiky
Katedra technickej kybernetiky

Školiteľ: doc. Ing. Ondrej Karpiš, PhD.
Žilinská univerzita v Žiline
Fakulta riadenia a informatiky
Katedra technickej kybernetiky

Oponenti: Ing. Martin Hyben, PhD.,
Senior Researcher
Good AI, Karolínska 654/2, Praha
Česká republika

prof. Ing. Karel Šotek, CSc.
Univerzita Pardubice, Pardubice
Fakulta elektrotechniky a informatiky
Katedra softwarových technológií

Autoreferát bol rozoslaný dňa:

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

prof. Ing. Karol Matiaško, PhD.
predseda odborovej komisie
študijného programu **aplikovaná informatika**
v študijnom odbore **9.2.9 aplikovaná informatika**

Fakulta riadenia a informatiky
Žilinská univerzita
Univerzitná 8215/1
010 26 Žilina

Anotácia

Predmetom skúmania práce bola možnosť aplikácie kompresného snímania v bezdrôtových sieťach senzorov. V kompresnom snímaní nie sú aplikované zaužívané postupy pri vzorkovaní signálov, ale za splnenia určitých podmienok je možné značne znížiť počet meraní signálu. Dôsledkom toho môže byť zvýšenie rýchlosti získavania dát alebo zníženie energetických nárokov na získavanie dát. Práca mala za úlohu overiť vplyv získavania informácií prostredníctvom kompresného snímania na spotrebu danej siete pre definovanú jednoúčelovú úlohu. Na simulačnom príklade akustickej lokalizácie boli navrhnuté vhodné metódy a parametre vysielaného signálu, čo bolo základom pre overenie hypotézy optimalizácie spotreby pre bezdrôtovú sieť a porovnanie s klasickým prístupom.

Kľúčové slová: kompresné snímanie, WSN, bezdrôtové senzorové siete, lokalizácia, akustický signál, spotreba energie.

<i>Počet strán:</i>	81	<i>Počet použitej literatúry:</i>	73
<i>Počet obrázkov:</i>	25	<i>Počet tabuliek:</i>	7

Annotation

The subject of the study was the possibility of application of compressed sensing in wireless sensor networks. Compressed sensing is a fast-forwarding area that provides the basis for data acquisition methods in which it does not apply established signal sampling procedures but, subject to certain conditions, it allows to significantly reduce the number of signal measurements. As a result, it may be faster to obtain data or reduce energy demands on data acquisition. The aim was to verify the impact of data gathering through compression scanning on the consumption of the network for a defined single-purpose task. On the simulation example of acoustic localization, appropriate methods and parameters of the transmitted signal were proposed, which was the basis for verifying the consumption optimization hypothesis for the wireless sensor network and the comparison with the classic approach.

Key words: Compressive sensing, Compressed sensing, WSN, Wireless Sensor Networks, Localization, Acoustic signal, Energy consumption.

<i>Number of pages:</i>	82	<i>Number of used bibliographics:</i>	73
<i>Number of figures:</i>	25	<i>Number of tables:</i>	7

Úvod

Bezdrôtové senzorové siete (WSN) sú pomerne novou technológiou v oblasti inteligentných prostredí. Prostredníctvom nich je možné monitorovať požadované informácie z okolia. Tento systém pozostáva z priestorovo rozložených autonómnych modulov, ktoré sú schopné vzájomnej interakcie. Sú rozmiestnené v pozorovanej oblasti a priebežne vyhodnocujú stav sledovaného objektu. Základom týchto sietí sú moduly (nody) s implementovanými snímačmi vzhľadom na požiadavky aplikácie. Ako príklad je možné uviesť snímanie akustických emisií v doprave, snímanie pohybu osôb v objekte alebo získavanie meteorologických dát, prípadne široké využitie WSN v inteligentných budovách a najnovšie aj v rôznych IoT aplikáciách. Interakcia medzi jednotlivými uzlami je zabezpečená prostredníctvom RF komunikácie. Podľa [9] v súčasnosti komunikuje až 99 % inštalovaných senzorov pomocou vodičov. Z predpokladu na najbližších 10 rokov vyplýva, že WSN technológia by mala pokrývať 10 % všetkých senzorových sietí. V súčasnosti sa rozširujú aplikácie tzv. inteligentných senzorov. Rozdiel medzi klasickým a inteligentným senzorom spočíva v pridaných schopnostiach inteligentného senzora. Kým klasický senzorový uzol získané dáta len odošle do centrály, inteligentný senzorový uzol je schopný tieto dáta ešte pred odoslaním predspracovať do takej podoby, aby sa posielali len nevyhnutné informácie a tým sa znížili nároky na prenosový kanál. Komunikácia v senzorovej sieti je do značnej miery limitovaná. Jednotlivé uzly je často potrebné umiestniť do oblasti bez prítomnosti elektrickej siete, čo má za následok veľké energetické obmedzenie. Tomuto musí byť prispôsobený vysielač aj výpočtový výkon uzlov. Uzly majú definovanú priepustnosť v závislosti od aplikácie a dostupného množstva energie. Používanie WSN technológie vyžaduje minimálne nároky na inštaláciu a údržbu.

V tejto práci sa venujeme možnostiam využitia kompresného snímania vo WSN. Kompresné snímanie je metóda snímania a rekonštrukcie signálu využívajúca riedke vzorkovanie za predpokladu riedkosti signálu, čo vedie k zníženiu počtu meraní, čiže k zjednodušeniu procesu získavania dát z okolia a tým pádom aj k úspore energie prvkov siete. Hlavnými cieľmi práce je:

- preskúmať možnosti využitia KS v bezdrôtových sieťach senzorov,
- aplikovať KS na vybranú úlohu,
- simuláciou overiť navrhnuté riešenie,
- zhodnotiť vplyv KS na spotrebu siete.

Prvá kapitola je venovaná popisu činnosti WSN technológie a jej využitiu v praktických aplikáciách. Tiež sú tu popísané štandardné metódy číslicového spracovania signálov, ich výhody a nevýhody. Druhá kapitola sa zaoberá teoretickými princípmi kompresného snímania s využitím riedkeho vzorkovania a pojednáva o možnostiach využitiu kompresného snímania vo WSN aplikáciách. V tretej kapitole je popísané riešenie konkrétnej úlohy lokalizácie objektu a sú tu zhrnuté poznatky získané vďaka experimentom.

1 WSN technológia

Hlavnou myšlienkou pri tvorbe WSN bolo vytvoriť sieť senzorov rozložených v priestore. Tieto senzory mali byť nízko nákladové a schopné pracovať autonómne a zároveň spolupracovať s ostatnými uzlami v sieti, obsahovali senzory, komunikačnú jednotku a modul pre spracovanie dát [71], [27].

1.1 Hardvérová platforma

WSN pozostáva z priestorovo rozložených senzorových uzlov. Vo WSN je každý senzor schopný nezávisle vykonávať úlohy snímania, predspracovania a spracovania dát. Navyše nody komunikujú spolu navzájom alebo s centrálnym uzlom v závislosti od topológie siete. Aby malo použitie uzlu význam, zvyčajne je v ňom implementovaný jeden alebo viac snímačov, procesor, pamäť a zdroj energie.

1.2 Komunikácia

Bezdrôtová senzorová sieť pozostáva z množstva uzlov, ktoré majú bezdrôtové komunikačné moduly. Nody môžu byť umiestnené na veľkej rozlohe v ťažko prístupnom teréne, preto je potrebné, aby boli snímané dáta zhromažďované niekoľkými centrálnymi (sink) nodmi, ktoré majú prístup k infraštruktúre, napr. k internetu, alebo je k nim zabezpečený jednoduchý prístup aby bolo možné stiahnuť dáta aj osobne.

1.3 Aplikácie

1.3.1 Monitorovanie životného prostredia

Do oblasti monitorovania životného prostredia patrí napr. stopovanie zvierat, vyhodnocovanie stavu lesných ekosystémov, detekcia záplav alebo predpoveď počasia [32]. Sú to ideálne aplikácie pre WSN, pretože merané parametre majú byť prenášané na veľkú vzdialenosť.

1.3.2 Medicínske účely

WSN môžu byť použité v nemocniciach na sledovanie zdravotného stavu pacientov. Tieto zariadenia tvoria špeciálnu skupinu WSN nodov, nazvanú sieť telesných senzorov (Body Sensor Network). BSN je skupina senzorov, ktorá vnáša revolúciu do zdravotnej starostlivosti tým, že poskytuje finančne nenáročné, dlhodobé monitorovanie s neustálym obnovovaním zdravotných záznamov cez internet. Jednou z aplikácií je napr. hrudníkový pás, ktorý slúži na sledovanie pacientov so srdcovou arytmiou [43].

1.3.3 Dopravné systémy

Mnoho križovatiek využíva informácie zo senzorov na ovládanie semaforov s dôrazom na dosiahnutie minimálneho čakania alebo maximálnej priepustnosti [26]. Sensory bývajú zväčša umiestnené nad križovatkou alebo vo vozovke [66], [56].

1.4 Spotreba WSN siete

Jedným z dôvodov vzniku bezdrôtových sensorických sietí je potreba umiestnenia senzorov (statických alebo prenosných) do nedostupného alebo vzdialeného terénu bez zavedenej infraštruktúry. V takomto prostredí nie sú dostupné trvale zdroje elektrickej energie z ktorých by mohli byť nody napájané. Preto je vo WSN aplikáciách stále aktuálna snaha o minimalizáciu spotreby. Elektrická energia sa spotrebúva v podsysteme snímania signálu, podsysteme spracovania signálu a v procese komunikácie.


1.4.1 Snímanie signálu

Pre získanie informácií z okolia je potrebné dané spojité veličiny snímať pomocou senzorov, ktorými je nod vybavený. Značné množstvo energie sa spotrebúva práve pri analógovo číslicovej konverzii vzoriek signálu. Konvenčným prístupom ku vzorkovaniu signálov je dodržanie Shannonovho teóremu, ktorý hovorí o tom, že frekvencia vzorkovania AČ prevodníka musí byť rovná alebo väčšia ako je dvojnásobok maximálnej frekvencie meraného signálu. Vo všeobecnosti uvažujeme s deterministickým a periodickým (ekvidištančným) vzorkovaním. Tento model vzorkovania, podľa ktorého sú vzorky signálu odoberané v časových intervaloch s konštantným trvaním, je najpoužívanejší. Je zrejmé, že takýto postup pri získavaní vzoriek sa zdá byť najprirodzenejší a má viacero výhod. Bol však zavedený dávnejšie a pre niektoré aplikácie nie je vhodný.


Model periodického vzorkovania nie je vždy výhodné aplikovať. Napríklad, keď z rôznych dôvodov majú byť vzorky odobrané v nepravidelných intervaloch alebo dokonca v náhodných časových okamžikoch. Štúdie ukazujú, že náhodnosť pri odbere vzoriek nemusí byť vždy negatívna. Nepravidelnosti prinášajú aj isté výhody, napríklad potlačenie aliasingu. I v prípade šetrenia energie môže náhodnosť prinášať dobré výsledky.

Alias efekt vedie k neurčitej reprezentácii signálu, ako je možné vidieť na Obr.1 [10]. Tieto vzorky signálu môžu byť pri rekonštrukcii použité na vytvorenie originálnej sínusoidy. Sínusoida vykreslená čiernou farbou, vyhovuje dátam. Avšak ak sledujeme možnosti rekonštrukčného procesu, vidíme, že aj ostatné sínusoidy rôznych frekvencií vyhovujú odobratým vzorkám. Sú známe metódy ako sa takýmto komplikáciám vyhnúť, napr. použitím antialias filtra.

Obr. 2 [10] ukazuje ako sa dá vyhnúť alias efektu použitím nerovnomerného vzorkovania. Znovu bola vzorkovaná sínusoida rovnakej frekvencie, ako v predšlom prípade. V tomto prípade nie sú vzdialenosti na časovej osi medzi vzorkami



Obr. 1: Periodické vzorkovanie - alias efekt



Obr. 2: Nepravidelné vzorkovanie - potlačenie alias efektu

rovnaké. Z obrázku je vidieť že len jedna sínusoida vyhovuje všetkým vzorkám.

1.4.2 Komunikácia

Najviac zaťažujúcim faktorom z pohľadu spotreby WSN siete je práve komunikácia, najmä odosielanie nameraných dát. Preto sa snažíme o zníženie objemu prenášaných dát. Existujú tri prístupy. Prvý prístup využíva metódy spracovania signálu na vyhodnotenie dát a následne je odosielaná už len užitočná informácia (výsledné riešenie), ktorá vďaka nízkemu objemu dát minimálne zaťažuje zdroj energie. V druhom prístupe sú posielané charakteristiky (parametre) signálu. Niekedy je však potrebné odosielať celý zachytený signál, čo je tretí prípad. Pri periodickom vzorkovaní je objem prenášaných dát veľmi veľký. Riedkym vzorkovaním sa dá tento objem rapídne znížiť a posielajú sa len vzorky, ktoré sú naozaj užitočné.

2 Princípy kompresného snímania

Pôvodná myšlienka kompresie dát bola zozbierať všetky dáta, previesť nad nimi vhodnú transformáciu, vyhodnotiť základné koeficienty a väčšinu z nich zahodiť, pretože z nejakého dôvodu nesú málo užitočnej informácie. Kompresné snímanie prichádza s inou stratégiou: za predpokladu riedkosti signálu vo vhodnej oblasti rovno snímať signál nepravidelne a to len toľkokrát, koľko je skutočne potrebné. Následná rekonštrukcia signálu vedie na riešenie systému lineárnych rovníc s nekonečne veľkým počtom riešení. Medzi nekonečne veľa riešeniami, ktoré by bolo

možné nájsť, sú požadované práve tie, ktoré majú čo najviac neznámych súčasne nulových (ide o tzv. riedke riešenia), z dôvodu že tieto riešenia sú zvyčajne s veľkou pravdepodobnosťou správne. Táto tematická oblasť siaha historicky až k prvému použitiu algoritmu Matching pursuit [57] a riedkej dekompozícii signálu na atómy pomocou Basis pursuit [25]. Kompresné snímanie bolo ako oblasť výskumu pomenované v roku 2004 na Stanfordovej univerzite. Ako prvý sa mu venoval profesor D. Donoho [35] a jeho bývalý študent, dnes už profesor E. J. Candès [19], ktorí sa venujú oblastiam riedkej reprezentácie signálov, waveletom, rekonštrukčným metódam, spracovaniu signálov a širokému spektru matematických optimalizácií. KS sa venuje ďalej literatúra [6], [46],[45].

2.1 Riedka reprezentácia signálov

Signál \mathbf{y} (napr. zvuk, obraz alebo video) môžeme reprezentovať ako lineárnu kombináciu bázových vektorov \mathbf{a}_i .

$$\mathbf{y} = \sum_i x_i \mathbf{a}_i,$$

kde x_i sú váhy alebo súradnice \mathbf{y} v systéme \mathbf{a}_i . Jednotlivým \mathbf{a}_i hovoríme atómy a celý systém sa nazýva slovník.

Tento model môžeme tiež zapísať ako sústavu lineárnych rovníc v maticovom tvare

$$\mathbf{A}\mathbf{x} = \mathbf{y},$$

kde \mathbf{x} je vektor neznámych a \mathbf{y} známy vektor. Matica \mathbf{A} sa okrem pomenovania slovník nazýva aj reprezentačný systém, často sa však nazýva aj meracia matica - čo nie je celkom správne a tento pojem bude vysvetlený v podkapitole 2.5 o kompresnom snímaní.

Čiže k -riedky vektor je taký, ktorý má najviac k nenulových zložiek. Relatívnou riedkosťou vektora \mathbf{x} dĺžky N sa bude teda rozumieť pomer k/N . Ďalej označme \mathbb{C}^N množinu všetkých k -riedkych vektorov dĺžky N .


Reálne signály však nebyvajú riedke, tak ako je definované vyššie. Namiesto nulových zložiek obsahujú malé nenulové hodnoty. Preto je vhodné definovať chybu aproximácie.

2.2 Riedke riešenia systémov lineárnych rovníc

Je potrebné riešiť klasickú sústavu lineárnych rovníc $\mathbf{A}\mathbf{x} = \mathbf{y}$, avšak s tým, že neznámy a hľadaný vektor \mathbf{x} má byť čo najredší, to znamená, že má obsahovať čo možno najväčší počet nulových zložiek. Ide o túto úlohu:

$$\min_x \|\mathbf{x}\|_0 \text{ vzhľadom na } \mathbf{A}\mathbf{x} = \mathbf{y}, \quad (1)$$

kde poznáme vektor $\mathbf{y} \in \mathbb{C}^m$ (pozorovanie, meranie, signál) a maticu $\mathbf{A} \in \mathbb{C}^{m \times N}$. Predpokladáme len prípady kedy $m < N$, resp. $m \ll N$, a \mathbf{A} je matica s



Obr. 3: Systém lineárných rovníc.

úplnou riadkovou hodnotou. Schéma úlohy je ilustrovaná na obrázku 3. Vektor \mathbf{x} obsahuje len niekoľko nenulových prvkov (súradníc), čiže pozorovaný vektor \mathbf{y} je lineárnou kombináciou len niekoľkých stĺpcov matice \mathbf{A} . Je tu použitá pseudofarebná schéma, modrá farba reprezentuje nulu, teplejšia farba predstavuje vyššiu hodnotu.

Všetky \mathbf{x} , ktoré spĺňajú podmienku $\mathbf{Ax} = \mathbf{y}$, nazývame prípustné riešenia. Z lineárnej algebry je známe, že vzhľadom na vyššie uvedené podmienky je na matici \mathbf{A} prípustných nekonečne veľa riešení a tvorí afinitný priestor. Matica \mathbf{A} zaručuje možnosť rekonštrukcie pôvodného \mathbf{x} z \mathbf{y} .

2.3 Bázy

Bázou vektorového priestoru sa rozumie množina lineárne nezávislých vektorov, ktorých lineárnou kombináciou je možné dostať sa k ľubovoľnému vektoru z daného vektorového priestoru. V konečnom priestore dimenzie N je bázou každá množina obsahujúca N lineárne nezávislých vektorov. Ak je $\mathbf{B} = \{\mathbf{b}_1, \dots, \mathbf{b}_n\}$ bázou, každý prvok $\mathbf{x} \in \mathbb{V}$ sa dá vyjadriť pomocou jednoznačných súradníc c_i v danej báze ako

$$\mathbf{x} = \sum_{i=1}^N c_i \mathbf{b}_i = \mathbf{B}c. \quad (2)$$

Ak má vektorový priestor viacero báz, potom majú všetky rovnaký počet generujúcich vektorov (generátorov).

Najčastejšie sa stretávame s ortogonálnymi a ortonormálnymi bázami. Ortogonálna báza je taká, kde pre ľubovoľné dva vektory z bázy $\mathbf{B} = \{\mathbf{b}_1, \dots, \mathbf{b}_n\}$ platí

$$\langle \mathbf{b}_i, \mathbf{b}_j \rangle = 0, \text{ pre } i \neq j, \langle \mathbf{b}_i, \mathbf{b}_i \rangle \neq 0. \quad (3)$$

2.4 Rekonštrukčné algoritmy

2.4.1 Výpočtová zložitosť problému

Predpokladajme, že platí $\text{spark}(\mathbf{A}) > 2k_0$ a existuje nejaké k_0 –riedke riešenie sústavy. Ak trváme na nájdení presného riešenia, je potrebné prejsť všetkých $\binom{N}{k_0}$ kombinácií podmnožín atómov matice. To zodpovedná NP-zložitosť (nedeterministicky polynomiálny problém), čo v praxi, kde N je veľké číslo, nie je prijateľné[18]. Preto bolo vyvinutých viacero aproximačných metód riešenia tohto problému, ktoré nie sú deterministicky presné, ale podstatne rýchlejšie. Tieto metódy sa delia zhruba do dvoch hlavných kategórií - greedy algoritmy (pažravé, hladné) a relaxácie, aj keď stále pribúdajú nové typy algoritmov.

2.4.2 Greedy algoritmy

Skupinu „greedy“ algoritmov tvoria tie metódy, ktorých hlavný princíp spočíva v tom, že v každej iterácii nájdú jeden alebo viac „najvýznamnejších“ atómov. Dôležité je, že v ďalšom priebehu algoritmu, vybraný atóm už bude súčasťou konečného riešenia. Výhodou týchto metód je nízka zložitosť, nevýhoda je, že nie je zaručené dosiahnutie globálneho optima. Známe algoritmy z tejto kategórie sú Matching Pursuit [57] a v súčasnosti najviac využívaná variácia Orthogonal Matching Pursuit – OMP [69], ďalšie odvodené algoritmy sú Regularized OMP, Stagewise OMP, OMP with Replacement a sub-lineárny algoritmus OMPR-Hash. Do tejto kategórie tiež patria Subspace Pursuit [33] a Least Angle Regression - LARS [37]. Niektoré algoritmy sú schopné garantovať stabilitu ako BPDN (relaxačný algoritmus) pričom sú rýchlejšie a lepšie pochopiteľné.

2.4.3 Relaxačné algoritmy

Táto skupina metód vychádza z konvexnej optimalizácie a sú založené na l_1 –relaxácií, čo znamená, že sú výpočtovo náročnejšie. Tieto algoritmy sa spoliehajú na to, že sa za určitých podmienok dostaneme k riešeniu presnému, alebo aspoň relatívne blízke. Z týchto metód je to napr. Basis Pursuit – BP[25], Basis Pursuit Denoising – BPDN, modifikovaný Least Angle Regression – LARS [37], [40], Interior Point Methods - IPM [51], Projected Gradient Methods, Iterative Reweighted Least Squares – IRLS, FOCal Underdetermined System Solver – FOCUS[41], [40] alebo Dantzing Selector [20].

L1 - minimalizácia (L1-relaxácia)

Za účelom vystihnúť podstaty relaxačných princípov L-minimalizácií, je potrebné definovať niekoľko pojmov.

Definícia 2.1. l_p -norma vektora $x \in \mathbb{C}^N$ je definovaná ako:

$$\begin{aligned} \|x\|_p &:= \left(\sum_{i=1}^N |x_i|^p \right)^{\frac{1}{p}} \quad \text{pre } 1 \leq p < \infty, \\ \|x\|_p &:= \sum_{i=1}^N |x_i|^p \quad \text{pre } 0 < p < 1, \\ \|x\|_\infty &:= \max_i |x_i|, \\ \|x\|_0 &:= |\text{sup}(x)|. \end{aligned} \tag{4}$$

O normu sa v skutočnosti jedná len v prípade, že $1 \leq p \leq \infty$. Pre zjednotenie však bude pre všetky p použité jednotné označenie l_p -norma. Pre lepšiu predstavu fungovania noriem je na Obr.4 vykreslená guľa v jednotlivých normách.

Definícia 2.2. Jednotková guľa B_p^N v norme l_p je definovaná ako

$$B_p^N := \{x \in \mathbb{C}^N \mid \|x\|_p \leq 1\}. \tag{5}$$

Definícia 2.3. Vektor $x \in \mathbb{C}^N$ sa nazýva k -riedky (k -sparse) pokiaľ platí

$$\|x\|_0 \leq k. \tag{6}$$


(Pseudo)norma l_0 nie je konvexná funkcia, čiže nie je možné pre výpočet úlohy 1 použiť žiadnu z metód a algoritmov konvexnej optimalizácie (konvexného programovania) [15]. Pretože normy l_p sú konvexné pre $p \geq 1$, uvažujeme využitie „najbližšej“ konvexnej normy, tzn. l_1 , aspoň k približnému riešeniu NP-zložitého problému. Je teda potrebné riešiť úlohu:

$$\min_x \|x\|_0 \quad \text{vzhľadom na } \mathbf{Ax} = \mathbf{y}. \tag{7}$$

Za splnenia podmienok NSP A RIP je možné použiť l_1 normu namiesto normy l_0 . Dokonca vo väčšine prípadov sa riešenia oboch úloh zhodujú. Na Obr. 4 je znázornené riešenie úlohy $\min_x \|x\|_p$ vzhľadom na $\mathbf{Ax} = \mathbf{y}$ v \mathbb{R}^2 , postupne pre $p = 0; 0,5; 1; 2$. Priestor všetkých prípustných riešení reprezentuje červená priamka. Z obrázku je zrejmé, že riešenie problémov 1 a 7 je zhodné. Riešenie v prípade, kedy použijeme euklidovskú normu, $p=2$, je však odlišné (riešenie s minimálnou energiou, čo znamená úzku spojitost s metódou najmenších štvorcov).

2.4.4 Ostatné algoritmy

Ďalšími algoritmami, ktoré nie sú zaradené do týchto kategórií sú algoritmy založené na prahovaní (thresholding) [37] a ďalšie hybridné algoritmy, ktoré využívajú jednotlivé prednosti z oboch skupín algoritmov. Jedným z nich je aj



Obr. 4: Vrstevnice noriem $l_0, l_{0,5}, l_1$ a l_2 a ich dotyk s nadrovinou určenou sústavou $\mathbf{Ax} = \mathbf{y}$.


A*OMP algoritmus, ktorý využíva A*-algoritmus prehľadávania informačných stromov. Tento algoritmus dosahuje lepšie výsledky v rekonštrukcii signálov než relaxačné algoritmy a navyše má oproti relaxačným metódam nižšiu zložitosť. Existujú aj kombinatorické algoritmy - HHS Pursuit, ktoré sú veľmi rýchle, ale potrebujú pomerne veľa meraní. Špeciálnym typom sú Total Variation - TV algoritmy. Tieto sa využívajú hlavne pri rekonštrukcii obrázkov, kedy je možné vyžadovať riedkosť gradientu. Vhodné sú najmä pre obrázky zložené z hladkých plôch oddelených krivkami (obrázky bez zložitých textúr). Takéto obrázky je často možné nájsť v medicínskom prostredí (MRI, angiogram).

2.5 Kompresné snímanie


Kompresné snímanie je asi jedna z najatraktívnejších aplikácií v oblasti riedkej reprezentácie signálov. Hlavná myšlienka tohto prístupu spočíva v neadaptívnom snímaní signálov len takým počtom vzoriek, ktorý je skutočne potrebný. Jedná sa o rovnaký problém - hľadanie (aproximácia) riedkeho riešenia úlohy 1 pomocou l_1 -minimalizácie, ale konštrukcia meracej matice \mathbf{A} je špeciálna (ako bolo spomenuté v kap. 2.1).

Predpokladaná je riedkosť signálu v nejakom slovníku (v našom prípade ortogonálne bázy). Nech je báza označená Ψ a teda signál sa dá vyjadriť ako $\mathbf{z} = \Psi\mathbf{x}$, kde \mathbf{x} je k -riedky. Cieľom je previesť malý počet neadaptívnych meraní, ktoré budú mať charakter skalárnych súčinov so signálom, čo sa dá vyjadriť ako $\mathbf{y} = \mathbf{Pz} = \mathbf{P\Psi}\mathbf{x}$. Kde \mathbf{P} je tzv. meracia (snímacia) matica rozmeru $m \times N$ a jednotlivé zložky vektora \mathbf{y} sú výsledky merania, ktoré vznikajú ako lineárna kombinácia vzoriek signálov. Pod pojmom vzorka sa v kompresnom snímaní rozumie skalár, ktorý vznikne lineárnou kombináciou pôvodných hodnôt signálu. Počet meraní je $m \ll N$. Z Obr. 5 môžeme vidieť že meracia matica \mathbf{A} , uvádzaná v predošlých kapitolách, má v tomto prípade tvar $\mathbf{A} = \mathbf{P\Psi}$ a celkovo je potrebné l_1 -minimalizáciou riešiť úlohu:

$$\min_x \|x\|_0 \text{ vzhľadom na } \mathbf{y} = \mathbf{P\Psi}\mathbf{x}. \quad (8)$$



Obr. 5: Tvar meracej matice \mathbf{A}




Obr. 6: Ilustrácia situácie pri kompresnom snímaní (bez prítomnosti šumu): nameraný vektor \mathbf{y} je rovný súčinu meracej matice $\mathbf{P} = \mathbf{R}\Phi$, jednotkovej matice Ψ a riedkeho vektoru \mathbf{x} . Do procesu snímania vstupuje vektor $\mathbf{z} = \Psi\mathbf{x}$, ktorý sám o sebe nie je riedky, ale je riedky v nejakej báze Ψ , na obrázku v ortonormálnej báze inverznej DCT. Matica Φ je v tomto prípade Gaussovská. Matica \mathbf{R} vznikla z jednotkovej matice $N \times N$ rovnomerne-náhodným zachovaním m riadkov.

Základnou úlohou je nájsť takú meraciu maticu \mathbf{P} , aby bolo možné z „malého“ počtu meraní zrekonštruovať signál. Vhodné meracie matice sa uvažujú v tvare $\mathbf{P} = \mathbf{R}\Phi$. Kde Φ je matica $N \times N$ a \mathbf{R} je matica, ktorá vznikne z jednotkovej matice $N \times N$ ponechaním len m náhodne vybraných riadkov, čiže funguje ako náhodný výber riadkov z matice Φ . Náhodný výber \mathbf{R} sa pritom riadi rovnomerným rozdelením pravdepodobnosti. Celkový tvar meracej matice \mathbf{A} je teda zložený z matíc $\mathbf{A} = \mathbf{R}\Phi\Psi$. Kompletná schéma kompresného snímania je zobrazená na Obr. 6.

Aby bolo možné zrekonštruovať signál pomocou l_1 -relaxácie, je nutné definovať, koľko meraní je potrebné zrealizovať (počet riadkov m matice \mathbf{P}). V prípade náhodných meracích matíc \mathbf{R} závisí tento počet od vzájomnej koherencie (μ). V prípadoch, keď je matica zložená z dvoch ortonormálnych báz Φ a Ψ , čiže $[\Psi, \Phi]$ je

$$\mu([\Psi, \Phi]) = \max_{1 \leq i, j \leq N} |\psi_i^\top \phi_j| \quad (9)$$

a hodnota koherencie (9) sa pohybuje medzi $\frac{1}{\sqrt{N}}$ a 1. Nasledujúce tvrdenie podmieňuje, kedy je zaručená presná rekonštrukcia z merania.



Obr. 7: Proces merania - násobenie signálu \mathbf{z} maticou \mathbf{P} predstavuje m lineárnych meraní signálu \mathbf{z} .

Tvrdenie 2.4. [23] *Nech je daný signál \mathbf{z} , ktorý má v báze Ψ k -riedku reprezentáciu \mathbf{x} . Potom riešenie l_1 -minimalizácie*

$$\min_x \|\mathbf{x}\|_1 \quad \text{vzhľadom na } \mathbf{y} = \mathbf{R}\Phi\Psi\mathbf{x}, \quad (10)$$

kde \mathbf{y} sú merania, je súčasne s vysokou pravdepodobnosťou najrýchlejšie možné, pokiaľ je zvolený počet matice riadkov takto:

$$m \geq C \cdot \mu^2 \left([\Psi, \Phi] \right) \cdot k \cdot N \cdot \ln N, \quad (11)$$

pre špecifickú konštantu C .

Z uvedeného vyplýva, že počet meraní závisí na riedkosti signálu len lineárne. Koherencia kvadraticky ovplyvňuje nutný počet meraní. Preto je snaha hľadať také dvojice, ktorých koherencia je minimálna - pri dvojiciach $[\Psi, \Phi]$ s koherenciou $1/\sqrt{N}$ stačí rádovo $k \cdot \ln N$ meraní. Ak však koherencia vzrastá, meranie podľa tejto podmienky prestáva byť relevantné, lebo počet meraní m prevyší počet vzoriek signálu N (napr. v prípade $\Phi = \Psi$).

2.6 Kompresné snímanie v aplikáciach


Všeobecne sa dá povedať že aplikáciu KS je možné nájsť všade tam, kde je možné signál vyjadriť riedko, či už v štandardnej báze, alebo v systéme ktorý bol signálu prispôbený. V počítačovej tomografii (CT), je potrebné získať obraz tela pacienta z rôznych uhlov s využitím röntgenových lúčov. Odber kompletnej množiny meraní by vystavil pacienta dlhej a nebezpečnej dávke radiácie, takže počet meraní by mal byť čo najmenší a mal by zaručovať dostatočnú kvalitu obrazu pre medicínske účely [22].

3 Kompresné snímanie v aplikácii pre lokalizáciu objektu

Ako vybraný príklad pre aplikáciu metód kompresného snímania sme zvolili úlohu lokalizácie objektu. Určovanie polohy objektov už dlhšie nie je záležitosťou len vonkajšieho prostredia. Čoraz častejšie sa tieto úlohy presúvajú do interiéru, napr. do výrobných hál alebo logistických centier, alebo kombinujú obe prostredia. Rozlišujú sa dva typy lokalizácie. Môže sa jednáť o absolútnu lokalizáciu vzhľadom na geografickú polohu. Druhým typom je lokalizácia relatívna, kde ide o určenie pozície vzhľadom na daný priestor v ktorom sa objekt nachádza.

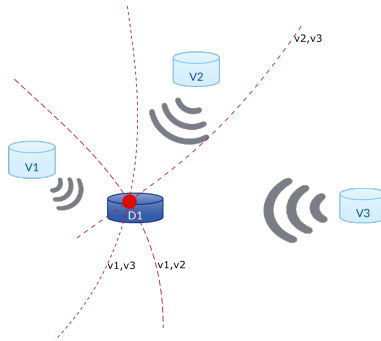
3.1 Princípy lokalizácie

Lokalizačné technológie využívajú rôzne princípy meraní na určenie správnej pozície. Metódy založené na meraní času sa delia na dve hlavné skupiny (prehľad ostatných často využívaných metód je uvedený v [59]):



Obr. 8: Triangulácia

- **TOA (Time of Arrival)** alebo doba príchodu. Táto metóda je založená na meraní absolútneho času za ktorý dorazí signál od vysielača k prijímaču. Euklidova vzdialenosť medzi dvoma zariadeniami môže byť odvodená násobením času za ktorý signál cestoval s rýchlosťou vlny. Pokiaľ však vlna prechádza rôznymi materiálmi je potrebné poznať jej rýchlosť v daných podmienkach. TOA však silne závisí na presnej synchronizácii hodín vysielača a prijímača. Určenie polohy sa v tomto prípade premietne do priesečníkov krúžnic so stredmi určenými vysielačmi modulmi.
- **TDOA (Time Difference of Arrival)** - pri meraní rozdielu časov príchodu nie je nutné, aby vysielač a prijímač mali synchronizovaný hodinový signál. Na rozdiel od prvého prípadu, nie je potrebné aby prijímač zaznamenával absolútny čas, za ktorý bol pulz vyslaný. Je potrebné poznať len rozdiel časov zo synchronizovaných vysielačov. Z dvoch vysielačov modulov sa získava jeden TDOA čas. Na určenie polohy sú potrebné minimálne dve takéto časové konštanty. Z troch vysielačov na známych pozíciách je




Obr. 9: Multilaterácia

možné určiť polohu objektu na hyperbole v 2D priestore, alebo zo štyroch prijímačov na hyperboloide v 3D priestore. Je tu využitá základná vlastnosť hyperboly, ktorá hovorí, že hyperbola je krivka konštantného rozdielu časov príchodu signálu vyslaného vysielačmi modulmi. Ohnisko každej hyperboly je určené týmito modulmi [16].

3.2 Využitie metód KS pri riešení lokalizačných úloh

Ako simulačný príklad využitia kompresného snímania vo WSN aplikáciách sme zvolili úlohu lokalizácie na základe akustických emisií. Základný scenár uvažuje s využitím nodov, ktoré sú vybavené reproduktorom, v úlohe vysielačov V1 až V3 a s jedným nodom D1, ktorý má za úlohu snímať vysielané akustické signály a zároveň je bodom záujmu lokalizácie. Aplikáciou KS na zaznamenaný signál a odosielaním riedkych vzoriek na spracovanie sa bude zaoberať spomenutý detekčný nod D1. Nakoľko uvažujeme s centralizovanou topológiou, vyhodnocovanie získaných dát sa bude uskutočňovať v centrálnom node C1 s dostatočnými výkonovými parametrami, kde na prijaté vzorky budú aplikované rekonštrukčné algoritmy a následne bude vyhodnocovaná pozícia objektu. Princiálna schéma úlohy je na znázornená na Obr. 10.



Obr. 10: Ilustrácia simulačného príkladu.

Aby bolo možné ďalej pracovať s týmto príkladom, je potrebné zaviesť nové pojmy.

Kompresný pomer (KP)

Nech N je počet vzoriek signálu $\mathbf{y}(\mathbf{n})$ získaných pri rovnomernom vzorkovaní so vzorkovacou frekvenciou f_{vz} určenou Shanonovým teorémom na danom intervale a nech m je počet vzoriek signálu $\mathbf{y}(\mathbf{n})$ vybraných na tom istom intervale na základe meracej matice \mathbf{P} (popísanej v kapitole 2.5), potom je kompresný pomer definovaný ako

$$KP = \frac{N}{m}.$$

KP je základným ukazovateľom výhodnosti použitia kompresného snímania. Úlohou je maximalizovať KP pri zachovaní maximálnej prípustnej chyby rekonštrukcie.

Chyba rekonštrukcie

Chyba rekonštrukcie je definovaná ako stredná absolútna odchýlka rozdielu signálov

$$e = \frac{1}{N} \sum_1^N |r(n)|,$$

kde rozdiel signálov $r(n) = y(n) - y'(n)$, pričom $y'(n)$ je rekonštrukcia pôvodného generovaného signálu $y(n)$ zo vzoriek získaných kompresným snímaním a N je počet prvkov vektora $r(n)$. Po vynásobení konštantou $K=100$ uvádzame v ďalšom texte chybu v percentách. Chyba vo frekvenčnej oblasti je určená analogicky, ako stredná absolútna odchýlka rozdielu frekvenčných spektier.

Ďalšie pojmy nachádzajúce sa v texte a tabuľkách:

- **názov** - názov signálu
- f_1, f_2 - nosná frekvencia generovaného signálu, jednotka: Hz
- **pomer** - pomer nosných frekvencií definovaný ako f_2/f_1
- f_{vz} - vzorkovacia frekvencia, jednotka: Hz
- **meracia matica** - počet riadkov (m) meracej matice \mathbf{P}
- **počet periód** - počet užitočných (nenulových) periód generovaného signálu s nosnou frekvenciou f_1, f_2

3.3 Simulačné prostriedky

Matlab

Na simulačné účely bola využitá knižnica L1-magic, ktorá má pôvod priamo v centre zrodu teórie kompresného snímania – na Standfordovej univerzite. Je to zbierka Matlabovských rutín na riešenie lineárneho programovania a konvexnej

optimalizácie, ktorá je zameraná na kompresné snímanie. Simulačný skript má široké možnosti nastavenia parametrov, medzi hlavné patria:

1. Parametre pre generovanie signálu: frekvencia vzorkovania, frekvencia signálu, počet periód, typ signálu, veľkosť šumu.
2. Parametre pre rekonštrukciu signálu: typ meracej matice, kompresný pomer, báza signálu, spôsob rekonštrukcie.
3. Parametre pre vyhodnotenie rekonštrukcie: vyhodnotenie chyby, čas výpočtu, typ vykreslenia, vykreslené položky.

Okrem týchto parametrov je možnosť implementácie vlastných rutín, potrebných pre analýzu zvolenej úlohy.

3.4 Vysielačný signál


V tejto úlohe je uvažované s využitím akustického signálu. Základnou úlohou bolo preskúmať typ vysielačného signálu - signál je možné vysielať nepretržite v čase (continuous) alebo dávkovo (burst).

3.4.1 Continuous

V prípade vysielačného nepretržitého signálu je rekonštrukcia menej náročná, čo znamená, že kompresný pomer môže dosahovať vyššie hodnoty pri požadovanej odchýlke, viď Tab. 1. Výslednú chybu môžeme považovať v praxi za nulovú, ide však o ideálny prípad (bez zavedenia šumu), kedy je vzorkovaný signál maximálne riedky. Ďalej vidno aj z Obr. 11, že signál pred a po rekonštrukcii vykazuje minimálnu chybu. Nevýhodou tohto snímania však je, že lokalizačná úloha nie je triviálne riešiteľná a nie je jednoznačne zrejme v ktorej perióde sa daný signál nachádza, čiže určenie vzdialenosti nie je jednoznačné. Je možné implementovať ďalšie softvérové riešenia, napr. vloženie pomocných signálov do nepretržitého vysielačného aby sa zabezpečila jednoznačnosť časových línií. S týmto riešením však dochádza aj k zvyšovaniu nárokov na výkon jednotlivých nodov siete, čo je nežiadúci efekt.

názov	f [Hz]	f _{vz} [Hz]	SNR [dB]	chyba [%]
cont_1	100	2000	-	6,1E-9
cont_2	200 a 500	2000	-	1,2E-8
cont_1a	100	2000	11	14,8
cont_2a	200 a 500	2000	11	35
cont_1b	100	2000	2,5	10,28
cont_2b	200 a 500	2000	2,5	25

Tabuľka 1: Výsledky rekonštrukcie pri KP= 100.



Obr. 11: Signál `cont_2` z Tab. 1 pred a po rekonštrukcii.

3.4.2 Burst

Úpravou vysielania z nepretržitého na dávkové bolo testami potvrdené, že kompresný pomer bude v takomto prípade nižší. Je možné však presnejšie analyzovať zachytený signál. V ideálnych podmienkach je možné určiť začiatok vysielania pomerne presne. V testoch bolo uvažované s využitím akustického burst signálu v rozsahu od 100Hz do 1kHz. Simuláciami bolo overené, že rekonštrukcia môže byť považovaná za dostatočnú pokiaľ je chyba medzi originálnym a zrekonštruovaným signálom do 5%. Pri rekonštruovaných signáloch, ktoré obsahujú jednu nosnú frekvenciu s chybovosťou do 15% je táto frekvencia stále výrazne zastúpená, pričom signál v časovej doméne nie je použiteľný bez ďalších filtrácií. V Tab. 2 sú uvedené vybrané realizované pokusy – v prvom priblížení obsahovali testované burst signály jednu nosnú frekvenciu. Na každú z uvedených položiek bolo opakovane aplikovaných 100 testov a stĺpec *chyba* uvádza priemernú chybu zo všetkých iterácií. V ďalšej tabuľke Tab. 3 bol signál generovaný s využitím dvoch rôznych nosných frekvencií, pričom pomery frekvencií boli určené náhodne.


názov	f [Hz]	f _{vz} [Hz]	meracia matica	KP	počet periód	chyba [%]
burst1f_01	100	2000	200	10	10	3,73
burst1f_02	200	2000	200	10	10	3,95
burst1f_03	300	2100	250	8,5	10	2,11
burst1f_04	400	2000	200	10	10	3,26
burst1f_05	500	2000	200	10	10	2,05
burst1f_06	800	4000	300	13	10	1,89
burst1f_07	1000	4000	200	20	10	1,6
burst1f_08	2000	8000	300	27	10	1,09

Tabuľka 2: Testy základných burst signálov a ich parametre.

Pri testovaní tohto typu vysielania, bolo pozorovaných niekoľko dôležitých faktov. Pri rekonštrukcii burst signálu dochádza k vysokej chybovosti hlavne na

názov	f_1 [Hz]	f_2 [Hz]	pomer	f_{vz} [Hz]	KP	meracia matica	chyba [%]
burst2f_01a	100	300	3	4000	13,33	300	3,78
burst2f_01b	100	400	4	4000	13,33	300	1,5
burst2f_01c	100	130	1,3	4000	20	200	1,27
burst2f_02a	200	130	0,65	4000	20	200	3,02
burst2f_02b	200	350	1,75	4000	13,33	300	1,32
burst2f_03a	500	144	0,288	4000	20	200	2,68
burst2f_03b	500	630	1,26	4000	13,33	300	1,58
burst2f_04a	1000	1300	1,3	4000	13,33	300	1,53
burst2f_04b	1000	840	0,84	4000	13,33	300	1,17

Tabuľka 3: Testy kombinovaných burst signálov a ich parametre.

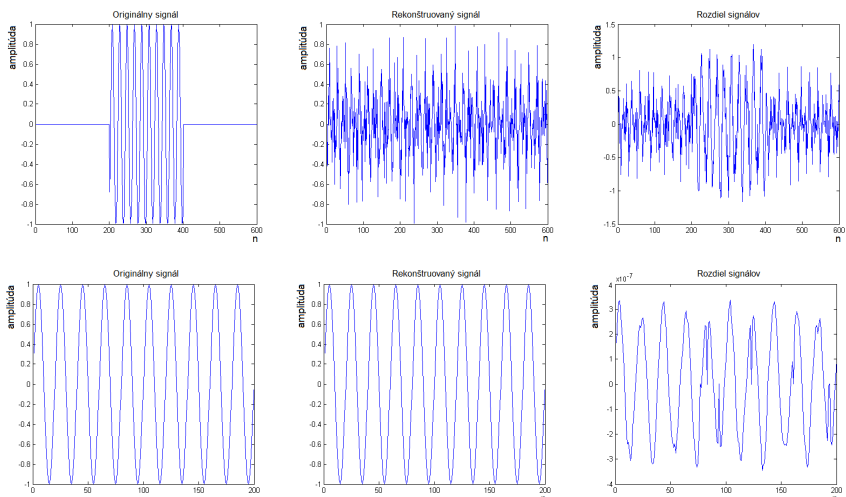


Obr. 12: Signál burst pred a po rekonštrukcii a ukážka chyby na hranách. Kompresný pomer: 10, nosná frekvencia 100Hz.


jeho začiatku a konci Obr. 12. V prípade zachovania rovnakého kompresného pomeru ako pri signáli continuous bola dosiahnutá nepoužiteľná miera rekonštrukcie (Obr. 13), kde horný rad predstavuje signál burst a dolný rad signál continuous. Tieto poznatky viedli k ďalšej fáze úpravy generovaného signálu. Úlohou je generovať taký signál aby bola jeho reprezentácia vo frekvenčnej oblasti čo najredšia. Na vyhladenie spektra slúžia napr. váhovacie okná. Obrázky 14 a 15 ilustrujú použitie okna a vplyv na riedkosť frekvenčného spektra signálu. Reálne signály sú vo väčšine prípadov blízke riedkym. Zobrazený výsledok je test s Hammingovým oknom, ktorý potvrdil zlepšenie reprezentácie vo frekvenčnej oblasti. Ak nie je signál riedky v danej oblasti, tak potom aj rekonštrukcia signálu L1-minimalizáciou nadobúda výraznejšie chyby.

3.4.3 Použitie váhovacieho okna a jeho vplyv na frekvenčné spektrum


Za účelom zvýšenia kompresného pomeru a zachovania kvality rekonštrukcie boli na signál aplikované okná rôznych typov, okrem obdĺžnikového, ktorým je signál burst sám o sebe. Oknové funkcie boli aplikované postupne na signál s rôznou




Obr. 13: Porovnanie signálov continuous a burst pri zachovaní rovnakého $KP=200$. Prvý riadok zodpovedá signálu burst, druhý riadok signálu continuous.



Obr. 14: Frekvenčné spektrum signálu burst bez použitia okna



Obr. 15: Frekvenčné spektrum signálu burst s použitím okna



Obr. 16: Váhovacie okná, ktoré boli použité pri testovaní. Ilustrácia je vykreslená na párnom počte prvkov, $N=64$.

hodnotou odstupe signálu od šumu.

Oknové funkcie sú váhovacie funkcie [63], [4], ktoré sú aplikované na dáta aby bol zredukovaný spektrálny únik, ktorý je spojený s pozorovaním konečného intervalu. Z pohľadu spracovania signálov je okno aplikované na základnú množinu, tak aby signál z ľubovoľnej frekvencie vykazoval významnú amplitúdu iba na tých bázičkových vektoroch, ktoré majú frekvenciu blízko frekvencie signálu.

Z matematického pohľadu sú to funkcie, ktoré majú nulové funkčné hodnoty mimo vybraný interval. Proces váhovania funguje tak, že pôvodný signál je násobený oknovou funkciou. Na výsledný signál môže byť ďalej aplikovaná požadovaná operácia, najčastejšie spektrálna analýza. V ďalšom texte sú stručne popísané oknové funkcie použité v našom prípade, kde N reprezentuje šírku okna a n poradie vzorky.

Vplyv šumu na okná

Vysielaný signál bol váhovaný na celom intervale burst signálu. Z Tab. 4 je viditeľné, že úpravou signálu pomocou okna sa chyba výrazne znížila oproti signálu bez použitia váhovania, tučným písmom sú vyznačené najmenšie chyby po rekonštrukcii oproti pôvodnému signálu. Experiment prebiehal na troch testovacích scenároch s pridaním rôznej úrovne šumu:

- nezašumený signál,
- biely šum so $\text{SNR} = 11\text{dB}$,
- biely šum so $\text{SNR} = 2,5\text{dB}$.

Po aplikácii okna je najvýraznejší rozdiel v chybe viditeľný v prípade nezašumeného signálu.

Na základe experimentov, bola maximálna prípustná miera chybovosti určená pre daný signál tak, ako je uvedené v Tab. 5. Tabuľka udáva pri akej maximálnej chybe rekonštrukcie je možné rozoznať a využiť parametre signálu

aplikované okno	bez šumu chyba [%]	SNR=11dB chyba [%]	SNR = 2,5dB chyba [%]
bez okna	4,4005	6,8020	10,4077
Bartlett	0,2543	3,6553	5,7728
Hamming	0,1975	3,0891	6,2740
Gauss	0,1782	2,6845	6,4022
Blackman-Harris	0,0895	3,8651	4,5833
Bartlett-Hanning	0,0851	3,6039	6,0955
Hanning	0,0602	2,7795	7,2183
Parzen	0,0305	3,4071	4,9526
Nuttall	0,0043	3,5920	4,5528
Chebyshev	0,0024	3,1662	4,5753

Tabuľka 4: Aplikácia rôznych oknových funkcií na signál s parametrami: $f=100\text{Hz}$, $f_{vz}=2000\text{Hz}$; počet riadkov meracej matice = 200; $KP = 10$. Priemerná chyba je vypočítaná z desiatich opakovaní rekonštrukcie.


počet frek.	aplikácia okna	frekv. oblasť max. chyba [%]	čas. oblasť max. chyba [%]
1	nie	15	15
1	áno	7	5
2	nie	15	7
2	áno	5	5

Tabuľka 5: Maximálna prípustná chyba rekonštruovaného signálu $y'(n)$ oproti pôvodnému generovanému signálu $y(n)$. Parametre generovaných signálov sú nasledovné: signál s jednou nosnou frekvenciou: $f_1=100\text{Hz}$, $f_{vz} = 2000\text{Hz}$; signál s dvomi nosnými frekvenciami: $f_1=100\text{Hz}$, $f_2=370\text{Hz}$, $f_{vz} = 2000\text{Hz}$. Aplikované bolo Chebyshevové okno a test rozoznatelnosti bol opakovaný 100-krát.

bez nutnosti ďalšej filtrácie rekonštruovaných dát. Z tabuľky je zrejmé, že pre rozoznanie nosnej frekvencie je dovolená v niektorých prípadoch podstatne väčšia chyba ako pre rozoznanie časového priebehu signálu (detekcia začiatku vysielania). Na základe tabuľky môžeme uvažovať najlepší prípad a to, že maximálna miera chybovosti je 5 %. Ak by sme chceli zachovať kompresný pomer, na rekonštrukčné účely by v tomto prípade mohol byť využitý len nezašumený signál podľa Tab.4. Pri váhovaní zašumených signálov nie je chyba až tak výrazne zredukovaná ako v prvom prípade, dostáva sa však stále pod prípustnú hranicu. Signál bez aplikácie okna v prípade zašumenia nie je vhodný na ďalšie spracovanie. Obr. 17 ukazuje signál vo všetkých troch prípadoch prídania šumu, v tomto prípade bolo použité Chebyshevové okno. Superponovaný šum mal charakter bieleho šumu s nulovou strednou hodnotou.

3.5 Parametre vysielaného signálu

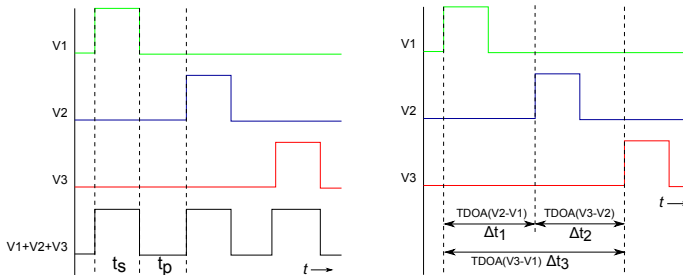
Lokalizačné úlohy založené na TDOA (kap. 3.1) nepredpokladajú, že vysielacie nody majú spoločný synchronizačný signál so snímacím nodom. Synchronizácia



Obr. 17: Singál s aplikovaným Chebyshevovým oknom - bez vplyvu šumu (a), so superponovaným šumom o hodnote (b) SNR = 11dB a (c) SNR = 3dB.

prebieha len vo vysielačoch, pre reálnu WSN môže byť využitý napr. synchronizačný algoritmus *FUSA* [29].

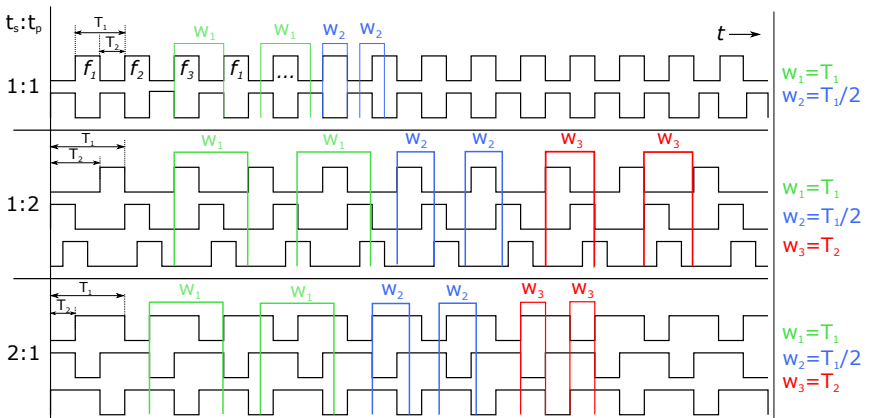
Vo všeobecnosti platí, že vysielače môžu generovať dáta alebo signály, ktoré sú jednoznačne identifikovateľné, pre digitálne signály (RF-sigály) to môže byť napr. identifikátor s definovanou polohou v lokalizačnej mape, unikátne číslo zariadenia, relatívne súradnice alebo presné geografické súradnice. Po získaní identifikátorov a časov rozdielu ich prijatia sa pomocou multilaterácie určí poloha sledovaného objektu.



Obr. 18: Vysielačný cyklus pre tri vysielače V1, V2, V3 a získanie časov oneskorenia.

V našom prípade je vysielačný signál akustický. Aby boli jednoznačne určené vysielače, každý vysielač priradený signál so špecifickou frekvenciou v rozsahu 100Hz - 1kHz. Synchronizované vysielače vysielajú podľa časového priebehu navrhnutého na Obr. 18. Čas t_s predstavuje časový úsek, počas ktorého je daný vysielač aktívny. Každý vysielač musí vygenerovať signál s minimálnym počtom periód 10. Ak uvažujeme najjednoduchší príklad, znamená to, že dĺžka t_s je zdola ohraničená vysielačou frekvenciou 100Hz, čo predstavuje vysielačie s dĺžkou 100ms. Vysielač s nastavenou maximálnou frekvenciou ($f_1=1\text{kHz}$) vysiela teda 100 periód signálu. Signál môže obsahovať viacero nosných frekvencií, pre


tento prípad uvažujeme s jednou a dvoma nosnými frekvenciami (Tab. 2 a 3). Okrem času vysielania je definovaný aj pokojový stav t_p . Ak berieme do úvahy obdĺžnikovú miestnosť s rozmermi $a \times b$, potom najväčšia možná vzdialenosť vysielateľa od lokalizovaného objektu je daná dĺžkou uhlopriečky c . Veľkosť prestávky medzi vysielaním je definovaná ako $t_p > c/v$, kde v je rýchlosť šírenia akustického signálu v danom prostredí. V simulácii uvažujeme miestnosť s $a = 30m$ a $b = 30m$, potom je minimálna dĺžka prestávky $t_p > 141ms$ ($42,42m/300ms^{-1}$). Pri rekonštrukcii signálu L1-minimalizáciou by mal byť daný signál čo najreďší, s ohľadom na túto skutočnosť je nutné nastaviť aj vhodný pomer parametrov vysielania t_s a t_p . Na Obr. 19 je znázornený vysielaný signál s rôznymi pomermi $t_s : t_p$. Ďalej sú tieto signály preložené oknami w_1 až w_3 . Okná slúžia na výber úseku signálu, ktorý je analyzovaný. Dĺžka okien na obrázku je určená periódami T_1 a T_2 . V našom prípade využívame druhý typ konfigurácie, čiže $t_s : t_p = 1 : 2$. Pre analýzu signálu je potrebné aplikovať okno w s definovanou dĺžkou, ako vidieť z obrázku 19 (pri konfigurácii 1:2). Najdlhšie okno, ktoré má zmysel pre analýzu sa rovná dĺžke periódy T_1 , čo predstavuje súčet časov vysielania a prestávky. Ako však bolo spomenuté, pre rekonštrukčné účely je snaha analyzovať signál s minimálnym počtom nosných frekvencií. Vzhľadom na to, že počas vysielania sa frekvencie striedajú (v našom prípade tri frekvencie vid Obr. 19 (f1 až f3)) znamená to, že oknom w_1 v niektorých prípadoch zachytíme dva čiastočné burst signály s rôznymi frekvenciami. Keď používame okná w_2 alebo w_3 tak v ideálnom prípade je potrebné rekonštruovať len signál z jedného vysielateľa. Obe okná vyhovujú požiadavkám, čo znamená že $w \in (T_1/2; T_2)$.




Obr. 19: Možnosti konfigurácie vysielacích periód burst signálov a vplyv šírky okna na analyzovaný signál. Použitie troch vysielateľov s nulovým oneskorením signálov. Ilustračný príklad uvažuje ideálny prípad, čo znamená že objekt D1 sa nachádza na priesečníku hyperbol s nulovým oneskorením.

3.6 Vyhodnotenie polohy objektu D1

Odhad rozdielu časov príchodu (TDOA) je možné realizovať dvoma spôsobmi: odpočítaním TOA z merania dvojice vysielačov (systém so spoločným hodinovým signálom) a získať tak relatívny TDOA, alebo použitím metód vzájomnej korelácie. V našom prípade to znamená určiť stredy vysielačských burst signálov a tým pádom aj TDOA. Pomocou multilaterácie na Obr. 20 určujeme polohu hľadaného objektu D1. Na určenie polohy v rovine je potrebné získať minimálne dve hyperboly. Zo známych časov TDOA je zrejmé, ktorá vetva hyperboly je hľadaným riešením [44]. Na uvedenom simulačnom obrázku boli časy oneskorenia $\Delta t_{V_1V_2} = 50ms$, $\Delta t_{V_3,V_2} = 30ms$ a $\Delta t_{V_1V_3} = 20ms$. V prípade, že sa objekt nachádza v rovnakej vzdialenosti od všetkých troch vysielačov, oneskorenie každého signálu po odčítaní t_p medzi vysielačmi je nulové, ilustrácia je na Obr.21.



Obr. 20: Multilaterácia.



Obr. 21: Multilaterácia, $\Delta t_1 = 0$, $\Delta t_2 = 0$.

3.7 Simulácia

Na základe predošlej analýzy sme pristúpili ku konkrétnym scenárom overenia predložených poznatkov. V simuláciách sme sa rozhodli použiť pre zvýšenie presnosti určenia polohy štyri vysielače. Ďalším faktorom, ktorý rozhoduje o presnosti riešenia je aj frekvencia vzorkovania signálu. Pri vzorkovaní frekvenciou 8 kHz sa dostávame na rozlíšenie 125ms. Keď pracujeme s frekvenciou 44,1 kHz presnosť sa zvýši na $22,6\mu s$ čo predstavuje odchýlku $\pm 6,8mm$. Plocha na ktorej je simulovaná lokalizačná úloha má rozmer $a = 30m$ a $b = 30m$, rovnako ako v predošlej analýze. Z toho vyplýva aj minimálna dĺžka prestávky 141ms. Trvanie základného cyklu vysielača po pridaní ďalšieho vysielača je 1200ms, pričom pre každý vysielač je $t_s = 100ms$ a $t_p = 1,1s$. Vysielače sú umiestnené v rohoch simulovanej miestnosti. Ďalší postup simulácie je nasledovný:

- vygeneruje sa náhodná pozícia lokalizovaného objektu,
- vypočíta sa fázový posunu signálu vzhľadom na dané miesto,

- v náhodnom čase začne vzorkovanie signálu,
- uskutoční sa rekonštrukcia signálu
- identifikuje sa stred burst signálu,
- odpočítajú sa vzdialenosti stredov signálu, čiže TDOA,
- určí sa pozícia lokalizovaného objektu,
- vyhodnotí sa absolútna odchýlka vygenerovanej pozície a určenej pozície.

Experiment bol ďalej rozdelený na dve kategórie: vysielanie signálu s jednou nosnou frekvenciou jedným vysielateľom a vysielanie signálu s dvomi nosnými frekvenciami jedným vysielateľom. Parametre a výsledky jednotlivých experimentov sú popísané v nasledujúcich scenároch.

3.7.1 Scenár A

Pri simulácii vysielania sme použili akustický signál s jednou frekvenciou pre každý vysielateľ. V tomto prípade mali jednotlivé vysielateľe priradené nasledovné frekvencie: $V1 : 100Hz$, $V2 : 300$, $V3 : 500$, $V4 : 700Hz$. Na signál bolo aplikované Chebyshevové okno. Lokalizácia bola testovaná pre nezašumené a zašumené signály. Výsledky možno nájsť v nasledujúcej Tab. 6.

KP	SNR [dB]	chyba rek. [%]	AO [cm]	KP	SNR [dB]	chyba rek. [%]	AO [cm]
88	-	0,078	4,21	100	-	0,083	4,34
88	11	2,42	13,98	100	11	4,23	18,12
88	2,5	4,25	33,57	100	2,5	3,89	39,45

Tabuľka 6: Scenár A. AO - absolútna odchýlka

3.7.2 Scenár B

Pri tomto scenári boli pre každý vysielateľ použité dve frekvencie. Z predchádzajúcej analýzy bolo zistené, že pomer (násobnosť) f_1 a f_2 nemajú zásadný vplyv na rekonštrukciu. Pre jednotlivé vysielateľe boli zvolené nasledujúce frekvencie: $V1 : 1kHz$ a $300Hz$; $V2 : 700Hz$ a $400Hz$; $V3 : 300Hz$ a $500Hz$; $V4 : 100Hz$ a $600Hz$. Lokalizácia bola ako v predchádzajúcom prípade testovaná so zašumenými a nezašumenými signálmi a bolo aplikované Chebyshevové okno.

KP	SNR [dB]	chyba rek. [%]	AO [cm]	KP	SNR [dB]	chyba rek. [%]	AO [cm]
88	-	0,06	5,01	100	-	0,22	5,79
88	11	0,98	15,21	100	11	1,81	13,45
88	2,5	3,21	37,24	100	2,5	5,33	45,01

Tabuľka 7: Scenár B. AO - absolútna odchýlka

Simuláciou bolo overené, že výsledky oboch scenárov sú porovnateľné. V jednom prípade vykazuje Scenár B lepšie riešenie ako Scenár A (Tab. 7: KP = 100, SNR = 11). Vo väčšine prípadov, sú však výsledky získané scenárom A presnejšie. Pre každý prípad bolo uskutočnených 50 simulácií. Použitý kompresný pomer je oveľa väčší ako KP, ktorý bol použitý v analýze. Experimentálne bolo potvrdené, že pri $f_{vz}z = 44,1kHz$ je dosiahnutá maximálna prípustná chyba s vybratím len 441 vzoriek - čomu zodpovedá KP = 100. V jednom prípade bola hranica prípustnej chyby 5 % prekročená, Tab.7, KP=100, SNR = 2,5. Kompresný pomer nebol ďalej zvyšovaný vzhľadom na dlhší čas rekonštrukcie, ktorý by bol potrebný a v reálnych aplikáciach by algoritmus potom nemusel mať uplatnenie. Čas rekonštrukcie pri KP = 100 bol približne 35 sekúnd a pri KP = 88 priemerne 8 sekúnd. Rekonštrukcia bola realizovaná na PC s výkonovými parametrami: procesor Intel Core i3 2,4GHz; RAM: 4GB, 64-bitový operačný systém Windows 8.1.

3.8 Vplyv na spotrebu

Určenie spotreby WSN modulov je komplexná záležitosť, závisí od viacerých faktorov - od počtu inštrukcií ktoré ovplyvňuje hlavne nastavenie kompilátora, štýl programovania, využívanie pamäte, ale aj typ inštrukcií, ktoré daný MCU podporuje. Najväčšie požiadavky na energiu má zvyčajne práca s perifériami, tu spadajú napr. získavanie dát AČ-prevodom, vysielanie informácií pomocou externého komunikačného modulu a ovládanie ďalších potrebných periférnych zariadení. V našom prípade sa zameriavame na rozdiel v spotrebe pri využití kompresného snímania a bez jeho používania. Pre zovšeobecnenie vyhodnotenia použijeme nasledujúce premenné:

- C_1, C_2, C_3 - celkové náklady na vzorkovanie, spracovanie a prenos,
- e_1, e_2, e_3 - energia potrebná na vykonanie jednej operácie (vzorkovanie, spracovanie a prenos),
- N - počet prvkov úlohy s klasickým prístupom,
- M - počet prvkov úlohy s využitím KS.

Ďalej predpokladáme, že $e_3 \gg e_1 > e_2$. Na základe nasledujúcich vzťahov je možné porovnať výhodnosť jednotlivých riešení na vybranom zariadení.

$$C = C_1 + C_2 + C_3,$$

Vzorkovanie a spracovanie Pri klasickom snímaní je vzorkovaný celý úsek okna w počtom vzoriek N (a), pri kompresnom snímaní počtom vzoriek M (b) a často je využívaná aj kombinácie týchto metód v zmysle klasického vzorkovania a následného vyberania M požadovaných vzoriek (c).

$$(a) C_1 = Ne_1; C_2 = 0e_2,$$

$$(b) C_1 = Me_1; C_2 = 0e_2,$$

$$(c) C_1 = Ne_1; C_2 = Me_2.$$

Prenos dát Konštanta e_3 je považovaná za najväčšiu z toho dôvodu, že vysielacie moduly požadujú najväčšie množstvo energie pre svoju činnosť. Energiu na prenos v jednotlivých prípadoch môžeme vyjadriť nasledovne

$$(a) C_3 = Ne_3, (b) C_3 = Me_3, (c) C_3 = Me_3.$$

Celková spotreba Celkovú spotrebu zariadenia pri rôznych scenároch môžeme vyjadriť nasledovne

$$C_a = Ne_1 + 0e_2 + Ne_3,$$

$$C_b = Me_1 + 0e_2 + Me_3,$$

$$C_c = Ne_1 + Me_2 + Me_3.$$

Vieme, že $KP = N/M$, v simuláciách sme dosiahli použiteľný $KP \approx 10$. Konštantu N teda môžeme substituovať ako $10M$ a vyjadriť porovnanie riešení

$$C_a = 10Me_1 + 10Me_3,$$

$$C_b = Me_1 + Me_3,$$

$$C_c = 10Me_1 + Me_2 + Me_3.$$

Z uvedených vzťahov vyplýva, že scenár (a) má najvyššie nároky na energiu, za ním nasleduje scenár (c). Spotreba na (pred)spracovanie v prípade scenára (b) závisí vo všeobecnosti aj od toho ako je implementovaný algoritmus kompresného vzorkovania. V tomto prípade je vyjadrená ako nulová, nemusí to však platiť vo všetkých prípadoch. Výhodnosť použitia riešenia s kompresným snímaním závisí aj od hodnoty kompresného pomeru. Vo výpočte spotreby nie sú zahrnuté náklady na rekonštrukciu, lebo v návrhu aplikácie uvažujeme s centrálnym nodom ktorý spĺňa energetické aj výkonové nároky na rekonštrukciu dát.

Záver

Možnosti využitia kompresného snímania vo WSN aplikáciách sa neustále rozširujú. Úlohou práce bolo preskúmať možnosti využitia kompresného snímania v aplikácii lokalizácie objektu v bezdrôtových sieťach senzorov. Pomocou tejto aplikácie by bolo možné sledovať napríklad pohyb prepravného vozíka vo výrobnnej (logistickej) hale alebo sledovať polohu robotického ramena a následne aj riadiť. Nedávno pomenovanou oblasťou využívajúcou senzorové riešenia a WSN je Industry IoT (IIOT) v ktorej by mohli mať tieto metódy využitia a výsledky

by mohli byť poskytované prostredníctvom intranetu alebo internetu. V práci boli skúmané viaceré aspekty tejto úlohy podľa definovaných cieľov.

Kompresné snímanie vychádza z teórie riedkej reprezentácie dát. Preto bolo základnou úlohou nájsť vhodný signál, ktorý je riedky v určitej doméne. Ďalšou požiadavkou na signál bolo, aby sa dal jednoducho generovať s obmedzenými HW prostriedkami. Akustický signál spĺňal všetky podmienky a preto sme ho ďalej použili v simulačnom príklade. Pri návrhu vysielaného signálu bolo potrebné určiť aj nosné frekvencie signálu. Pre experimentálne účely sme ostali v počutelnej oblasti. Ďalším predmetom skúmania bol typ vysielania. Do úvahy pripadali dva typy: nepretržité vysielanie a dávkové vysielanie. Pri prvom type vysielania bol dosiahnutý veľmi dobrý kompresný pomer. Na jeho analýzu by však boli potrebné ďalšie implementácie synchronizačných signálov, čo by odsunulo pôvodnú aplikáciu kompresného snímania do úzadia. Vybraný bol dávkový spôsob vysielania signálu. Hoci pri ňom dosahujeme mierne nižší kompresný pomer, vieme ho presne analyzovať. Tento spôsob vysielania však prináša aj zníženie riedkosti signálu vo frekvenčnom spektre. Signál obsahuje mimo vysielacej periódy vzorky s nulovou hodnotou a taktiež je prítomný superponovaný šum počas celej doby vysielania. Jedným z prínosov práce je aj využitie váhovacích okien na potlačenie spomenutého efektu. Vďaka ich použitiu sa výrazne znížila chyba rekonštrukcie.

Pre lokalizačnú úlohu boli definované konfigurácie vysielania a snímania signálu, ktoré sú závislé od veľkosti miestnosti a taktiež od požadovanej presnosti. Simulačný príklad spočíval v rozložení vysielateľov do súradnicového systému požadovaných rozmerov. Lokalizáciu je možné vykonávať dvoma spôsobmi. Prvý spôsob vyžaduje synchronizáciu snímača a vysielateľov, pri druhom spôsobe sú synchronizované len vysielateľe. Rozhodli sme sa pre druhý prípad, kedy nebola potrebná ďalšia réžia na synchronizáciu. Každý vysielateľ generoval signál so špecifickou frekvenciou a jeho poloha v súradnicovom systéme bola daná. Meraním časov oneskorení (známe ako TDOA) jednotlivých dávkových signálov sme boli schopní na základe známych algoritmov určiť polohu priesečníka hyperbol. Okrem toho sme v poslednej podkapitole popísali scenáre závislosti spotreby energie, čo bolo posledným z definovaných cieľov práce.

Zoznam použitej literatúry

- [1] ‘Body sensor network’, <http://www3.imperial.ac.uk/roboticsurgery/research/bsn/>, dostupné: 1.4.2015
- [2] ‘Chebyshev window function’, https://www.dsprelated.com/freebooks/sasp/Dolph_Chebyshev_Window.html, dostupné: 7.4.2017
- [3] ‘Indoor positioning and navigation’, <https://www.infsoft.com/portals/0/images/-solutions/basics/whitepaper/en-indoor-navigation-indoor-positioning-infsoft-ebook.pdf>, dostupné: 8.3. 2017
- [4] ‘Matlab, signal processing toolbox’, <https://www.mathworks.com/help/signal/index.html>, dostupné: 7.4.2017

- [5] ‘Michal chovanec, git hub repozitár, image reconstruction’, https://github.com/michalnand/machine_learning/tree/master/image_reconstruction, dostupné: 26.3.2017
- [6] ‘Nonuniform sampling’, Application Note, 2001, dostupné: 20.3. 2016
- [7] ‘Rozdelenie senzorov’, www.kam.sjf.stuba.sk/katedra/publikacie/edutrac/mtv/ucebnica/obsah.htm/, dostupné: 1.4.2016
- [8] ‘Wikipedia, štandard jpeg’, <https://en.wikipedia.org/wiki/JPEG>, dostupné: 21.3.2017
- [9] ‘Wireless sensor networks’, <http://www.idtechex.com/research/reports/wireless-sensor-networks-wsn-2014-2024-forecasts-technologies-players-000382.asp>, iDTechEx 2008, dostupné: 30.8. 2016
- [10] ‘Zdroj obr. alias efekt’, <http://www.edi.lv/media/uploads/UserFiles/dasp-web/sec5.htm>, dostupné: 10.3. 2017
- [11] ‘Zdroj obr. frekvenčné spektrum signálu’, <https://www.dewesoft.com/pro/course/-spectral-analysis-using-the-fft-29>, dostupné: 10.3. 2017
- [12] Antolín, D., Bayo, A., et al.: ‘Wubinet: A flexible wsn for applications in environmental monitoring’, *2012 IEEE International Instrumentation and Measurement Technology Conference Proceedings*, pp. 2608–2611, 2012, ISSN 1091-5281, doi:10.1109/I2MTC.2012.6229383
- [13] Balouchestani, M., Raahemifar, K., Krishnan, S.: ‘Low power wireless body area networks with compressed sensing theory’, *2012 IEEE 55th International Midwest Symposium on Circuits and Systems (MWSCAS)*, pp. 916–919, 2012, ISSN 1548-3746, doi:10.1109/MWSCAS.2012.6292170
- [14] Berger, R.: ‘Introduction to wireless sensor networks’, www.ieee.li/pdf/viewgraphs/introduction_to_wireless_sensor_networks.pdf, 2009, nI Technical Symposium, dostupné: 17.7. 2016
- [15] Boyd, S., Vandenberghe, L.: *Convex Optimization*, Cambridge University Press, 2004
- [16] Brída, P.: ‘Rádiové určovanie polohy v cdma bunkových sieťach’, *Proceedings of 5th International Conference Elektro*, ISBN 80-8070-252-7, 2004
- [17] Brito, J., Gomes, T., et al.: ‘An intelligent home automation control system based on a novel heat pump and wireless sensor networks’, *2014 IEEE 23rd International Symposium on Industrial Electronics (ISIE)*, Institute of Electrical and Electronics Engineers (IEEE), 2014, doi:10.1109/isie.2014.6864827
- [18] Bruckstein, A.M., Donoho, D.L., Elad, M.: ‘From sparse solutions of systems of equations to sparse modeling of signals and images’, *SIAM Review*, vol. 51, no. 1, pp. 34–81, 2009, doi:10.1137/060657704
- [19] Candes, E.: ‘Stanfordova univerzita’, <https://statweb.stanford.edu/candes/publications.html>, dostupné: 21.3.2017
- [20] Candes, E., Tao, T.: ‘The dantzig selector: Statistical estimation when p is much larger than n’, *The Annals of Statistics*, vol. 35, no. 6, pp. 2313–2351, 2007, doi:10.1214/009053606000001523
- [21] Candes, E.J., Tao, T.: ‘Decoding by linear programming’, *IEEE Transactions on Information Theory*, vol. 51, no. 12, pp. 4203–4215, 2005, ISSN 0018-9448, doi:10.1109/TIT.2005.858979

- [22] Candes, E.J., Tao, T.: ‘Near-optimal signal recovery from random projections: Universal encoding strategies?’, *IEEE Transactions on Information Theory*, vol. 52, no. 12, pp. 5406–5425, 2006, doi:10.1109/tit.2006.885507
- [23] Candes, E.J., Wakin, M.B.: ‘An introduction to compressive sampling’, *IEEE Signal Processing Magazine*, vol. 25, no. 2, pp. 21–30, 2008, ISSN 1053-5888, doi:10.1109/MSP.2007.914731
- [24] Cao, W., Xu, G., et al.: ‘Using wireless sensor networking (wsn) to manage microclimate in greenhouse’, *2008 IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications*, pp. 636–641, 2008, doi:10.1109/MESA.2008.4735706
- [25] Chen, S.S., Donoho, D.L., Saunders, M.A.: ‘Atomic decomposition by basis pursuit’, *SIAM Review*, vol. 43, no. 1, pp. 129–159, 2001, doi:10.1137/s003614450037906x
- [26] Chen, W., Chen, L., et al.: ‘A wireless sensor network for intelligent transportation system’, *First International MultiSymposiums on Computer and Computational Sciences 2006*, Institute of Electrical and Electronics Engineers, IEEE, 2006, doi:10.1109/imscs.2006.286
- [27] Chong, C.Y., Kumar, S.: ‘Sensor networks: Evolution, opportunities, and challenges’, *Proceedings of the IEEE*, vol. 91(8), p. 1247–1256, IEEE, 2003
- [28] Chou, C.T., Rana, R., Hu, W.: ‘Energy efficient information collection in wireless sensor networks using adaptive compressive sensing’, *2009 IEEE 34th Conference on Local Computer Networks*, Institute of Electrical and Electronics Engineers (IEEE), 2009, doi:10.1109/lcn.2009.5355162
- [29] Chovanec, M., Púchyová, J., et al.: ‘Universal synchronization algorithm for wireless sensor networks - fusa algorithm’, *Proceedings of the 2014 Federated Conference on Computer Science and Information Systems*, IEEE, 2014, doi:10.15439/2014f270
- [30] Christensen, O.: *Frames and Bases*, Springer Nature, 2008, doi:10.1007/978-0-8176-4678-3
- [31] Cohen, A., Dahmen, W., DeVore, R.: ‘Compressed sensing and best term approximation’, *Journal of the American Mathematical Society*, vol. 22, no. 1, pp. 211–231, 2008, doi:10.1090/s0894-0347-08-00610-3
- [32] Corke, P., Wark, T., et al.: ‘Environmental wireless sensor networks’, *Proceedings of the IEEE*, vol. 98, no. 11, pp. 1903–1917, 2010, ISSN 0018-9219, doi:10.1109/JPROC.2010.2068530
- [33] Dai, W., Milenkovic, O.: ‘Subspace pursuit for compressive sensing signal reconstruction’, *IEEE Transactions on Information Theory*, vol. 55, no. 5, pp. 2230–2249, 2009, doi:10.1109/tit.2009.2016006
- [34] Dong, L., Wu, J., et al.: ‘Extraction of gait features using a wireless body sensor network (BSN)’, *2006 6th International Conference on ITS Telecommunications*, Institute of Electrical and Electronics Engineers (IEEE), 2006, doi:10.1109/itst.2006.288719
- [35] Donoho, D.: ‘Stanfordova univerzita’, <http://statweb.stanford.edu/donoho/reports.html>, dostupné: 21.3.2017
- [36] Donoho, D.L., Elad, M.: ‘Optimally sparse representation in general (nonorthogonal) dictionaries via ℓ_1 minimization’, *Proceedings of the National Academy of Sciences*, vol. 100, no. 5, pp. 2197–2202, 2003, doi:10.1073/pnas.0437847100
- [37] Efron, B., Hastie, T., et al.: ‘Least angle regression’, *Ann. Statist.*, vol. 32, no. 2, pp. 407–499, 2004, doi:10.1214/009053604000000067

- [38] Elad, M.: *Sparse and redundant representations: from theory to applications in signal and image processing*, Springer, 2010, ISBN 78-1-4419-7010-7
- [39] Engan, K., Aase, S.O., Husøy, J.H.: ‘Multi-frame compression: theory and design’, *Signal Processing*, vol. 80, no. 10, pp. 2121–2140, 2000, doi:10.1016/s0165-1684(00)00072-4
- [40] Fornasier, M., Rauhut, H.: *Handbook of Mathematical Methods in Imaging*, Springer Nature, 2011, doi:10.1007/978-0-387-92920-0
- [41] Gorodnitsky, I.F., Rao, B.D.: ‘Sparse signal reconstruction from limited data using focuss: a re-weighted minimum norm algorithm’, *IEEE Transactions on Signal Processing*, vol. 45, no. 3, pp. 600–616, 1997, ISSN 1053-587X, doi:10.1109/78.558475
- [42] Gribonval, R., Nielsen, M.: ‘Sparse representations in unions of bases’, *IEEE Transactions on Information Theory*, vol. 49, no. 12, pp. 3320–3325, 2003, doi:10.1109/tit.2003.820031
- [43] Guo, D.G., Tay, F.E.H., et al.: ‘A wearable BSN-based ECG-recording system using micromachined electrode for continuous arrhythmia monitoring’, *2008 5th International Summer School and Symposium on Medical Devices and Biosensors*, Institute of Electrical and Electronics Engineers (IEEE), 2008, doi:10.1109/issmddb.2008.4575011
- [44] Herath, S.C.K., Pathirana, P.N.: ‘Robust localization with minimum number of TDoA measurements’, *IEEE Signal Processing Letters*, vol. 20, no. 10, pp. 949–951, 2013, doi:10.1109/lsp.2013.2274273
- [45] Hrbáček, R., Rajmic, P., et al.: ‘Řídké reprezentace signálů: komprimované snímání’, *Elektrorevue*, vol. 13, no. 6, 2011
- [46] Hrbáček, R., Rajmic, P., et al.: ‘Řídké reprezentace signálů: úvod do problematiky’, *Elektrorevue*, vol. 2011/50, 2011, ISSN 1213-1539
- [47] Ingelrest, F., Barrenetxea, G., et al.: ‘SensorScope’, *ACM Transactions on Sensor Networks*, vol. 6, no. 2, pp. 1–32, 2010, doi:10.1145/1689239.1689247
- [48] Isley, P.: ‘The radio regulations, edition of 2012’, <http://www.itu.int/pub/R-REG-RR-2012>, dostupné: 29.2. 2016
- [49] Jellali, Z., Atallah, L.N., Cherif, S.: ‘A study of deterministic sensors placement for sparse events detection in WSN based on compressed sensing’, *Fourth International Conference on Communications and Networking, ComNet-2014*, Institute of Electrical and Electronics Engineers (IEEE), 2014, doi:10.1109/comnet.2014.6840911
- [50] Kapitulík, J., Miček, J., et al.: ‘Wireless sensor network value added subsystem of ITS communication platform’, *Proceedings of the 2014 Federated Conference on Computer Science and Information Systems*, Polish Information Processing Society PTI, 2014, doi:10.15439/2014F370
- [51] Kim, S.J., Koh, K., et al.: ‘An interior-point method for large-scale ℓ_1 -regularized least squares’, *IEEE Journal of Selected Topics in Signal Processing*, vol. 1, no. 4, pp. 606–617, 2007, doi:10.1109/jstsp.2007.910971
- [52] Lazarescu, M.T.: ‘Design of a wsn platform for long-term environmental monitoring for iot applications’, *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, vol. 3, no. 1, pp. 45–54, 2013, ISSN 2156-3357, doi:10.1109/JETCAS.2013.2243032
- [53] Leinonen, M., Codreanu, M., Juntti, M.: ‘Distributed correlated data gathering in wireless sensor networks via compressed sensing’, *2013 Asilomar Conference on Signals, Systems and Computers*, Institute of Electrical and Electronics Engineers (IEEE), 2013, doi:10.1109/acssc.2013.6810310

- [54] Liu, Y., Zhu, X., et al.: ‘Multiple event detection in wireless sensor networks using compressed sensing’, *2011 18th International Conference on Telecommunications*, Institute of Electrical and Electronics Engineers (IEEE), 2011, doi:10.1109/cts.2011.5898935
- [55] Lustig, M., Donoho, D.L., et al.: ‘Compressed sensing mri’, *IEEE Signal Processing Magazine*, vol. 25, no. 2, pp. 72–82, 2008, ISSN 1053-5888, doi:10.1109/MSP.2007.914728
- [56] Mainetti, L., Palano, L., et al.: ‘Integration of rfid and wsn technologies in a smart parking system’, *2014 22nd International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, pp. 104–110, 2014, doi:10.1109/SOFTCOM.2014.7039099
- [57] Mallat, S., Zhang, Z.: ‘Matching pursuits with time-frequency dictionaries’, *IEEE Transactions on Signal Processing*, vol. 41, no. 12, pp. 3397–3415, 1993, doi:10.1109/78.258082
- [58] Martinez, K., Padhy, P., et al.: ‘Glacial environment monitoring using sensor networks’, *In Proceedings of Real-World Wireless Sensor Networks*, ACM Press, 2005
- [59] Mautz, R.: ‘Indoor positioning technologies’, 2012, doi:10.3929/ethz-a-007313554
- [60] Myers, C., Oppenheim, A., et al.: ‘Knowledge-based speech analysis and enhancement’, *Proc. of the International Conference on Acoustics, Speech and Signal Processing*, 1984
- [61] Špiřík, J., Rajmic, P., Veselý, V.: ‘Reprezentace signálů: od bázi k framům’, *Elektrorevue*, vol. 12, no. 6, 2010
- [62] Pister, K.S.J.: ‘Military applications of sensor networks’, *of Institute for Defense Analyses Paper P-3531*, Defense Science Study Group, 2000
- [63] Poularikas, A.: *Handbook of Formulas and Tables for Signal Processing*, Electrical Engineering Handbook, CRC-Press, 1998, ISBN 9780849385797
- [64] Strohmer, T., Heath, R.W.: ‘Grassmannian frames with applications to coding and communication’, *Applied and Computational Harmonic Analysis*, vol. 14, no. 3, pp. 257–275, 2003, doi:10.1016/s1063-5203(03)00023-x
- [65] Sudevalayam, S., Kulkarni, P.: ‘Energy harvesting sensor nodes: Survey and implications’, Tech. rep., Department of Computer Science and Engineering, Indian Institute of Technology Bombay, tR-CSE-2008-19
- [66] Sudhaakar, R., Sanzgiri, A., et al.: ‘A plant-and-play wireless sensor network system for gate monitoring’, *2009 IEEE International Symposium on a World of Wireless, Mobile and Multimedia Networks Workshops*, pp. 1–9, 2009, doi:10.1109/WOWMOM.2009.5282488
- [67] Svrček, T.: ‘Sítě typu wmn (wireless mesh network) a jejich směrovačí protokoly’, Master’s thesis, Masarykova univerzita, Fakulta informatiky, Bakalářská práce 2012, dostupné: 7. 5.2016
- [68] Tibshirani, R.: ‘Regression shrinkage and selection via the lasso’, *Journal of the Royal Statistical Society, Series B*, vol. 58, pp. 267–288, 1994
- [69] Tropp, J.: ‘Greed is good: Algorithmic results for sparse approximation’, *IEEE Transactions on Information Theory*, vol. 50, no. 10, pp. 2231–2242, 2004, doi:10.1109/tit.2004.834793
- [70] Valverde, J., Rosello, V., et al.: ‘Wireless sensor network for environmental monitoring: Application in a coffee factory’, *International Journal of Distributed Sensor Networks*, vol. 2012, pp. 1–18, 2012, doi:10.1155/2012/638067

- [71] Wang, Q., Balasingham, I.: *Wireless Sensor Networks - An Introduction, Wireless Sensor Networks: Application - Centric Design*, InTech, 2010, ISBN 978-953-307-321-7
- [72] Xiao, H., Ogai, H.: 'A distributed localized decision self-health monitoring system in WSN developed for bridge diagnoses', *2011 IEEE 3rd International Conference on Communication Software and Networks*, Institute of Electrical and Electronics Engineers (IEEE), 2011, doi:10.1109/iccsn.2011.6013653
- [73] Zhang, K., Wang, W.: 'The research of environmental monitor system in brewage house of alcohol factory based on WSN', *Proceedings of the 10th World Congress on Intelligent Control and Automation*, Institute of Electrical and Electronics Engineers (IEEE), 2012, doi:10.1109/wcica.2012.6359221

Zoznam vlastných publikácií

1. *The measurement of CO₂ by using Yrobot platform = Meranie CO₂ s využitím platformy Yrobot*. Peter Šarafín, Veronika Olešnaníková and Róbert Žalman. In: *Otvorený softvér vo vzdelávaní, výskume a v IT riešeníach: zborník príspevkov medzinárodnej konferencie OSSConf 2015: 1.-3. júla 2015 Žilina, Slovensko*. - Žilina: Žilinská univerzita, 2015. - ISBN 978-80-970457-7-7. - S. 89-94.
2. *Monitoring of CO₂ amount in closed objects via WSN*. Róbert Žalman, Veronika Olešnaníková, Peter Ševčík, Peter Šarafín. In: *FedCSIS: proceedings of the 2015 Federated conference on Computer science and information systems: September 13-16, 2015, Łódź, Poland*. - Warsaw; Los Alamitos: Polskie Towarzystwo Informatyczne; IEEE, 2015 - (*Annals of computer science and information systems*, Vol. 5. - ISSN 2300-5963). - ISBN 978-83-60810-65-1. - S. 1257-1260.
3. *Using of compressed sensing in energy sensitive WSN applications*. Ondrej Karpiš, Juraj Miček, Veronika Olešnaníková. In: *FedCSIS: proceedings of the 2015 Federated conference on Computer science and information systems: September 13-16, 2015, Łódź, Poland*. - Warsaw; Los Alamitos: Polskie Towarzystwo Informatyczne; IEEE, 2015 - (*Annals of computer science and information systems*, Vol. 5. - ISSN 2300-5963). - ISBN 978-83-60810-65-1. - S. 1233-1238.
4. *Monitoring of water level based on acoustic emissions*. Juraj Miček, Ondrej Karpiš, Veronika Olešnaníková, Michal Kochláň. In: *ISCC 2015: 20th IEEE Symposium on Computers and Communications: 6-9 July 2015 Larnaca, Cyprus*. - [S.l.]: IEEE, 2015. - ISBN 978-1-4673-7194-0. - USB kľúč, s. 988-992.
5. *Analysis of methods for reducing energy requirements in WSN*. Veronika Olešnaníková. In: *MIST 2015 = Mathematics in Science and Technologies: proceedings of the MIST conference 2015: Fačkovské sedlo, Kľak, Slovakia*. - [S.l.]: CreateSpace Independent Publishing Platform, 2015. - ISBN 978-1514866382. - [6] s.

6. *Power consumption analysis and possibilities of energy saving in WSN applications* Veronika Olešnaníková, Peter Šaraffín, Róbert Žalman, Ondrej Karpiš. In: TRANSCOM 2015: 11-th European conference of young researchers and scientists: Žilina, June 22-24, 2015, Slovak Republic. Section 3: Information and communication technologies. - Žilina: University of Žilina, 2015. - ISBN 978-80-554-1045-6. - CD-ROM, s. 45-49.
7. *Analysis of acoustic signals in transport systems using WSN*. Róbert Žalman, Veronika Olešnaníková, Peter Šaraffín, Ján Kapitulík. In: TRANSCOM 2015: 11-th European conference of young researchers and scientists: Žilina, June 22-24, 2015, Slovak Republic. Section 3: Information and communication technologies. - Žilina: University of Žilina, 2015. - ISBN 978-80-554-1045-6. - CD-ROM, s. 105-109.
8. *Methods of input shapers realization*. Peter Šaraffín, Veronika Olešnaníková, Róbert Žalman, Peter Ševčík. In: TRANSCOM 2015: 11-th European conference of young researchers and scientists: Žilina, June 22-24, 2015, Slovak Republic. Section 3: Information and communication technologies. - Žilina: University of Žilina, 2015. - ISBN 978-80-554-1045-6. - CD-ROM, s. 84-88.
9. *Case-study of localization via WSN using distributed compressed sensing*. Veronika Olešnaníková, Michal Kochláň, Róbert Žalman. In: FedCSIS: proceedings of the 2016 Federated conference on Computer science and information systems: September 11-14, 2016, Gdańsk, Poland. - Warsaw; Los Alamitos: Polskie Towarzystwo Informatyczne; IEEE, 2016 - (Annals of computer science and information systems, Vol. 8. - ISSN 2300-5963). - ISBN 978-83-60910-92-7. - S. 1093-1096.
10. *System analytics approach using wireless sensor network technologies and big data visualization for continuous assessment of air quality in a workplace environment*. Judith Molka-Danielsen, Veronika Olešnaníková, Peter Šaraffín, Róbert Žalman, Per Engseth. In: NOKOBIT 2016 = Norsk konferanse for organisasjoners bruk av informasjonsteknologi. - ISSN 1894-7719. - Vol. 24, no. 1 (2016), online, [10]s.
11. *Mobile sensor elements based on robotic platform Yrobot*. Juraj Miček, Ondrej Karpiš, Veronika Olešnaníková. In: FedCSIS: proceedings of the 2016 Federated conference on Computer science and information systems: September 11-14, 2016, Gdańsk, Poland. - Warsaw; (ISSN 2300-5963). - ISBN 978-83-60910-92-7. - S. 1085-1088.
12. *Water level monitoring based on the acoustic signal using the neural network*. Veronika Olešnaníková, Ondrej Karpiš, Michal Chovanec, Peter Šaraffín, Róbert Žalman. In: Information and digital technologies 2016: 5-7 July 2016 Rzeszow, Poland. - [S.l.]: IEEE, 2016. - ISBN 978-1-4673-8860-3. - USB klúč, s. 203-206.