

ŽILINSKÁ UNIVERZITA V ŽILINE

FAKULTA RIADENIA A INFORMATIKY

KATEDRA TECHNICKEJ KYBERNETIKY

**VYUŽITIE NEURÓNOVEJ SIETE NA ODHAD
PARAMETROV MONITOROVANÉHO
SYSTÉMU V PROSTREDÍ WSN**

Dizertačná práca

Študijný program: aplikovaná informatika

Študijný odbor: informatika

Pracovisko: Katedra technickej kybernetiky

Fakulta riadenia a informatiky, Žilinská univerzita v Žiline

Školiteľ: doc. Ing. Ondrej Karpiš, PhD.

Registračné číslo: 28360020213001

Žilina, 2021

Ing. Lukáš Formanek

Čestné vyhlásenie

Čestne prehlasujem, že som prácu vypracoval samostatne s využitím dostupnej literatúry a vlastných vedomostí pod odborným vedením školiteľa práce doc. Ing. Ondreja Karpiša, PhD. Všetky zdroje použité v tejto dizertačnej práci som uviedol v súlade s predpismi.

Súhlasím so zverejnením práce a jej výsledkov.

V Žiline, dňa 16.4.2021

.....
Ing. Lukáš Formanek

Pod'akovanie

Ďakujem vedúcemu dizertačnej práce doc. Ing. Ondrejovi Karpišovi, PhD. za odbornú pomoc, pripomienky a usmerňovanie pri tvorbe tejto práce. Moje pod'akovanie patrí aj kolegom z Katedry technickej kybernetiky za konzultácie. Veľké pod'akovanie patrí celej mojej rodine a kamarátom za podporu a pomoc počas celého doktorandského štúdia.

ABSTRAKT

Formanek, Lukáš: *Využitie neurónovej siete na odhad meraných parametrov v prostredí WSN*. [Dizertačná práca]. – Žilinská univerzita v Žiline. Fakulta riadenia a informatiky; Katedra technickej kybernetiky. – Vedúci: doc. Ing. Ondrej Karpiš, PhD. – Stupeň odbornej kvalifikácie: Doktor v odbore informatika. – Žilina: FRI UNIZA, 2021. – 107 s.

Práca sa zaoberá odhadom nameraných parametrov vo WSN pomocou neurónovej siete. Neurónová sieť na základe hodnôt nameraných v ostatných uzloch bezdrôtovej senzorickej siete odhaduje hodnotu v uzle, kde nebola v danom čase meraná. Teoretická časť práce rozoberá problematiku WSN sietí, možné aplikácie a kategorizáciu týchto sietí. Tiež popisuje úvod do neurónových sietí, ich rozdelenie a využitie v prostredí WSN. Praktická časť práce je venovaná simuláciám, reálnym experimentom a porovnaniu dosiahnutých výsledkov. Hlavným cieľom simulačných experimentov bolo overiť možnosti šetrenia energie vo WSN. Boli zrealizované aj dva experimenty s reálnym nasadením WSN do vonkajšieho prostredia (monitoring teploty ovzdušia). V práci sú porovnané rôzne modely neurónových sietí, ktoré boli aplikované na odhad teploty v nami navrhutej bezdrôtovej senzorickej sieti na základe meraní vo zvyšných bodoch. Vzhľadom na energetickú náročnosť koncových zariadení počas procesu komunikácie, môže byť vhodne navrhnutá neurónová sieť použitá na odhad merania v danom bode WSN. Tento odhad môže byť využitý pri výpadku uzla v sieti a hlavne na minimalizáciu prenášaných dát od daného uzla v sieti, čo má za následok výrazné zníženie spotreby daného koncového zariadenia a šetrenie prenosovej kapacity. Simulácie s nameranými hodnotami ukázali, že v závislosti na požadovanej presnosti odhadu môže byť úspora aj viac než 80%.

Kľúčové slová: WSN, neurónové siete, úspora energie, regresia.

ABSTRACT

Formanek, Lukáš: *Use of a neural network to estimate the parameters of the monitored system in the WSN environment*. [Dissertation thesis]. – University of Žilina. Faculty of Management Science and Informatics; Department of Technical Cybernetics. – Tutor: doc. Ing. Ondrej Karpiš, PhD. – Level of qualification: Doctor of Informatics. – Žilina: FRI UNIZA, 2021. – 107 p.

This thesis deals with the estimation of unmeasured parameters in WSN using a neural network. Based on the values measured in the other nodes of the wireless sensor network, the neural network estimates the value in the node not measuring at a given time. The theoretical part of the thesis discusses the issue of WSN networks, possible applications, and categorization of these networks. It also describes the introduction to neural networks, their categorization, and their use in the WSN environment. The practical part of the thesis is devoted to simulations, real experiments, and comparison of achieved results. The main goal of the simulation experiments was to verify the possibilities of energy saving in WSN. Two experiments were also carried out with the real deployment of WSN in the outdoor environment (air temperature monitoring). The thesis compares various models of neural networks, which were applied to estimate the temperature in our wireless sensor network based on measurements at the remaining points. Due to the high energy consumption of the nodes during the communication process, the suitably designed neural network can be used to estimate the measurement at a given WSN point. This estimate can be used in case of failure of a node in the network and particularly to minimize the data transmitted from a given node in the network resulting in a significant reduction in the consumption of a given node device and saving transmission capacity. As shown in simulations with measured values, the savings can be more than 80%, depending on the required accuracy of the estimate.

Key words: WSN, neural networks, energy saving, regression.

Obsah

Zoznam obrázkov	8
Zoznam tabuliek	10
Zoznam skratiek a symbolov	11
Úvod	13
1 WSN siete.....	15
1.1 Aplikácie	15
1.2 Klasifikácia WSN sietí	17
1.2.1 Kategorizácia na základe topológie.....	19
1.3 Štruktúra snímacieho zariadenia vo WSN	20
1.4 Spotreba energie WSN	21
1.4.1 Senzorický podsystem	22
1.4.2 Komunikačný podsystem	23
1.5 LoRa technológia	24
1.5.1 Štruktúra paketu.....	26
1.6 LoRaWAN	27
1.6.1 Rozdelenie vrstiev v sieti.....	28
1.6.2 Zabezpečenie a pripojenie k sieti	30
1.6.3 Spotreba energie	32
2 Neurónová sieť.....	35
2.1 Využitie neurónových sietí.....	35
2.2 Základné prvky neurónovej siete	36
2.3 Topológia neurónovej siete	39
2.4 Perceptrón.....	40
2.5 Dopredná viacvrstvová sieť ako univerzálny aproximátor funkcie	42
2.6 Učenie neurónovej siete	44
2.6.1 Učenie na základe opravy chyby	45
2.6.2 Stochastické učenie	45
2.6.3 Učenie na základe hodnotenia činnosti	45
3 Využitie neurónovej siete v prostredí WSN	47
3.1 Aplikácie neurónových sietí v prostredí WSN.....	47
3.1.1 Lokalizácia	48
3.1.2 Úspora energie.....	48
3.1.3 Spoľahlivosť, bezpečnosť a kvalita WSN	49
3.1.4 Ďalšie aplikácie	49
3.2 Teoretické východiská experimentov.....	50
3.2.1 Implementácia neurónových sietí do WSN.....	51

3.2.2	Časovo-priestorová optimalizácia vzorkovania parametrov systému	52
3.2.3	Rastúce a posuvné okno	53
3.2.4	Frekvencia vzorkovania.....	54
4	Simulačné experimenty	55
4.1	Použité datasety	55
4.2	Vplyv veľkosti neurónovej siete	56
4.3	Vplyv typu vstupných dát	57
4.4	Predikcia časových radov	58
4.5	Simulácia možností šetrenia energie	59
4.5.1	Rozdelenie uzlov siete do skupín	59
4.5.2	Prenos dát na základe odchýlky odhadu.....	61
4.5.3	Porovnanie spôsobov šetrenia energie.....	63
5	Reálne experimenty	64
5.1	Experiment č. 1	65
5.1.1	Hardvérové vybavenie.....	66
5.1.2	Zostavenie datasetu	68
5.1.3	Výsledky experimentu.....	69
5.2	Experiment č. 2	71
5.2.1	Hardvérové vybavenie.....	72
5.2.2	Softvérové vybavenie	74
5.2.3	Zostavenie datasetu	77
5.2.4	Dátová analýza	78
5.2.5	Vplyv typu vstupných dát.....	81
5.2.6	Využitie konvolučnej neurónovej siete	85
5.3	Vyhodnotenie šetrenia energie	87
	Záver	90
	Zoznam použitej literatúry	92
	Zoznam príloh	103
	Prílohy.....	104
	Príloha A: Zoznam vlastných publikácií	105
	Príloha B: Obsah DVD	107

Zoznam obrázkov

Obrázok 1 Topológie bezdrôtových sietí [2]	19
Obrázok 2 Spotreba energie pri použití vysoko-energetických senzorov	23
Obrázok 3 Vplyv komunikácie na energetickú náročnosť modulu	24
Obrázok 4 Proces modulácie s využitím rozprestretého spektra [6]	25
Obrázok 5 Štruktúra LoRa paketu	26
Obrázok 6 Architektúra LoRaWAN [64]	27
Obrázok 7 Vrstvy protokolu LoRaWAN [64]	29
Obrázok 8 Priebeh komunikácie – Trieda A [64]	30
Obrázok 9 Zabezpečenie správ v LoRaWAN [64]	32
Obrázok 10 Graf závislosti dĺžky vysielania a veľkosti správy pri rôznom nastavení SF [69].....	33
Obrázok 11 Vplyv ADR na prenos správy [69]	34
Obrázok 12 Všeobecná štruktúra neurónu [47]	36
Obrázok 13 Typy neurónov [48]	36
Obrázok 14 Príklady aktivačnej funkcie neurónu [48]	38
Obrázok 15 Príklad viacvrstvovej doprednej neurónovej siete	39
Obrázok 16 Príklad rekurentnej neurónovej siete [48]	40
Obrázok 17 Logické funkcie AND, OR a XOR [47]	41
Obrázok 18 Aproximácia funkcie pomocou NS a vývoj chyby počas tréningu [53].....	43
Obrázok 19 Náhodný výber bodov na testovanie	57
Obrázok 20 Rozdelenie 20 bodov na 2 rovnaké skupiny	60
Obrázok 21 Plocha pokrytá WSN sieťami.....	65
Obrázok 22 Architektúra navrhutej WSN (1. model).....	66
Obrázok 23 Snímacie zariadenie	66
Obrázok 24 Prístupový bod	67
Obrázok 25 Mapa rozmiestnenia jednotlivých senzorických modulov	68
Obrázok 26 Ukážka nameraných dát	69
Obrázok 27 Grafické znázornenie výsledkov	71
Obrázok 28 Architektúra WSN siete (2. model).....	72
Obrázok 29 Mapa rozmiestnenia senzorických modulov	72
Obrázok 30 WSN prístupový bod a server	73

Obrázok 31 Ukážka senzorického modulu v teréne	74
Obrázok 32 Architektúra ChirpStack systému [102].....	75
Obrázok 33 Node-RED konfiguračné prostredie.....	76
Obrázok 34 Node-RED webová aplikácia.....	77
Obrázok 35 Grafická reprezentácia nameraných dát.....	78
Obrázok 36 Histogram nameraných dát za obdobie 08-12/2020	78
Obrázok 37 Dataset s nameranými hodnotami teploty	79
Obrázok 38 Korelácia meraných veličín medzi jednotlivými modulmi.....	80
Obrázok 39 Korelácia meraných veličín	81
Obrázok 40 Grafické znázornenie odhadu pre modul č. 5	83
Obrázok 41 Grafické znázornenie odhadu pre modul č. 5 pri použití časového okna na vstupe.....	85
Obrázok 42 Princíp 1D konvolúcie [106].....	86

Zoznam tabuliek

Tabuľka 1 Špecifikácia LoRaWAN prenosových kanálov EU868MHz.....	28
Tabuľka 2 MSE (priemer a minimum) pre rôznu veľkosť neurónovej siete	56
Tabuľka 3 MSE (priemer a minimum) pre rôzny typ vstupných dát a rôzne modely NS...	58
Tabuľka 4 MSE (priemer a minimum) pre rôznu dĺžku okna a rôzne modely NS.....	59
Tabuľka 5 MSE pre rôzny počet snímaných a počítaných hodnôt - dataset UKCP18.....	60
Tabuľka 6 MSE pre rôzny počet snímaných a počítaných hodnôt - dataset Kilimandžáro.	61
Tabuľka 7 Počet prekročení prahovej hodnoty 0,5 °C - dataset UKCP18.....	62
Tabuľka 8 Počet prekročení prahových hodnôt 0,5 °C a 1 °C - dataset Kilimandžáro.....	62
Tabuľka 9 Približná veľkosť ušetrenej energie	63
Tabuľka 10 Porovnanie chýb výstupov jednotlivých modelov NS	70
Tabuľka 11 Spotreba energie komunikačného modulu RAK811.....	74
Tabuľka 12 Ukážka záznamu prijatého z modulu	77
Tabuľka 13 Porovnanie chýb predikcie jednotlivých modelov	83
Tabuľka 14 Využitie časového okna (30) na vstupe - MLP 32, 32, 32, 1	84
Tabuľka 15 Chyby jednotlivých odhadov pri použití CNN	87
Tabuľka 16 MSE pre rôzny počet snímaných a počítaných hodnôt.....	87
Tabuľka 17 MSE pre rôznu dĺžku okna a rôzne veľkosti neurónovej siete.....	88
Tabuľka 18 Počet prekročení prahových hodnôt.....	89

Zoznam skratiek a symbolov

ABP	Activation By Personalization
ADC	Analog to Digital Converter
ADR	Adaptive Data Rate
AES	Advanced Encryption Standard
ARM	Advanced RISC Machines
ASIC	Application Specific Integrated Circuit
A_{test}	Testovacia množina
A_{train}	Trénovacia množina
BW	Bandwidth
CNN	Convolutional Neural Network
CPU	Central Processing Unit
CR	Code Rate
DSP	Digital Signal Processing
DSSS	Direct Sequence Spread Spectrum
DSSS	Direct Sequence Spread Spectrum
E_{test}	Testovacia kumulovaná chyba
E_{train}	Trénovacia kumulovaná chyba
FPGA	Field Programmable Gate Array
FSK	Frequency Shift Keying
GRU	Gated recurrent unit
GSM	Global System for Mobile Communications
IoT	Internet of Things
ISM	Industrial, Scientific and Medical
LAN	Local Area Network
LSTM	Long Short-Term Memory
MCU	Microcontroller Unit
MIC	Message Integrity Code
MLP	Multilayer perceptron
NS	Neurónová Sieť
OTAA	Over The Air Activation

RF	Radio Frequency
RISC	Reduced Instruction Set Computer
RMSE	Root Mean Square Error
RSSI	Receive Signal Strength Indicator
SD	Secure Digital
SF	Spreading Factor
SPI	Serial Peripheral Interface
SVM	Support Vector Machines
USART	Universal Synchronous/Asynchronous Receiver/Transmitter
WAN	Wide Area Network
WSN	Wireless Sensor Network

Úvod

Bezdrôtové technológie nachádzajú uplatnenie v rôznych oblastiach priemyslu, automatizácie a monitoringu okolitého prostredia. Bezdrôtové senzorické siete predstavujú zoskupenie rôznych zariadení, ktoré na komunikáciu medzi sebou využívajú istý druh bezdrôtovej technológie. Na prenos informácie v sieti sa využíva ako prenosové médium napríklad: rádiové, infračervené alebo mikrovlnné žiarenie. Väčšina súčasných technológií využíva na zber senzorických dát centrálny uzol, ktorý preposiela dáta na server, kde sú namerané hodnoty spracovávané a ďalej vyhodnocované.

Čoraz častejšie sa však stretávame s pojmom tzv. inteligentný senzor. Tento senzor nielen sníma danú veličinu ale aj predspracuje namerané hodnoty a cieľovému prvku v bezdrôtovej sieti zasiela len nevyhnutný objem dát, čím sa šetrí energia zariadenia a kapacita prenosového kanála. Medzi najpodstatnejšie parametre v senzorických bezdrôtových sieťach patria: dosah signálu, priepustnosť siete a spotreba elektrickej energie [1]. Problematiku WSN sietí zaradíme do stále rastúcej oblasti vstavaných systémov. Kapacitu bezdrôtových senzorických sietí možno využiť na veľké spektrum rôznych aplikácií ako napríklad: meranie parametrov ovzdušia (teplota, vlhkosť, koncentrácia plynov, prachových častíc), meranie hustoty dopravného toku, zaznamenávanie dát v priemyselnej výrobe a mnohé iné.

Internet vecí produkuje obrovské množstvo údajov a vzhľadom na rozmach tohto trendu bude dochádzať naďalej k enormnému nárastu zdieľaných informácií a technológií. Napriek nastupujúcim 5G sieťam a rozvoju špecializovaných sietí pre IoT, ako sú SigFox či LoRaWAN, bude problém obslúžiť takéto množstvo zariadení a údajov. Problém je s prenosovou kapacitou, s latenciou, ale aj s energetickými zdrojmi. Preto nebude vždy možné posielat' všetky údaje do cloudu. Posielanie údajov na dlhé vzdialenosti je neefektívne, vznikajú časové oneskorenia, údaje preťažujú siete, čo v praxi znamená pokles spoľahlivosti a pridružené problémy s kvalitou. Z dôvodu časového oneskorenia nemožno vytvárať riadiace slučky pre riadenie rýchlych procesov. Taktiež treba brať do úvahy aj problém bezpečnosti a spoľahlivosti prenosu dát najmä pri riadení alebo monitorovaní bezpečnostne kritických systémov a procesov. Výpočet na okraji (tzv. Edge Computing) je názov výpočtovej topológie, v ktorej sú procesy spracovania informácií umiestnené bližšie k zdrojom týchto informácií. Táto technológia rieši problémy s konektivitou, rýchlosťou reakcie či obmedzenou rýchlosťou pripojenia a poskytuje širšiu

škálu funkcií. Typický príklad je mikrokontrolér, ktorý lokálne spracuje alebo aj úplne spracuje údaje zo senzorov. Namerané hodnoty je možné spracovať v čo najväčšej miere priamo vo WSN sieti a na server posielat' len nevyhnutný objem dát.

Teoretická časť práce, kapitola 1 a 2, rozoberá problematiku WSN sietí, možné aplikácie ich využitia a kategorizáciu týchto sietí. Taktiež popisuje úvod do problematiky neurónových sietí, ich základné rozdelenia a metódy učenia NS. Kapitola 3 popisuje možnosti využitia NS v prostredí WSN a teoretické východiská pre realizáciu experimentov. Praktická časť práce, kapitola 4 a 5, je venovaná dosiahnutým výsledkom.

Bolo vykonaných niekoľko simulačných experimentov vzhľadom na šetrenie energie s dostupnými dastasetmi. V simuláciách boli otestované rôzne štruktúry neurónových sietí. V priebehu práce na tomto projekte boli vykonané aj dva experimenty s reálnym nasadením WSN do prostredia. V oboch prípadoch bola na komunikáciu využitá LoRa technológia, v druhom experimente aj komunikačný protokol LoRaWAN. V práci sú porovnané rôzne modely neurónových sietí, ktoré boli aplikované na predikciu teploty v nami navrhutej bezdrôtovej senzorickej sieti na základe meraní vo zvyšných bodoch.

Vzhľadom na energetickú náročnosť koncových zariadení počas procesu komunikácie, môže byť vhodne navrhnutá neurónová sieť použitá na predikciu merania v danom bode WSN. Táto predikcia môže byť využitá na minimalizáciu prenášaných dát od daného uzla v sieti, čo má za následok výrazné zníženie spotreby tohto koncového zariadenia a šetrenie prenosovej kapacity. Taktiež môže byť využitá pri výpadku uzla v sieti. V určitých prípadoch aplikácie WSN sietí sa stretávame s problémom, kedy nie je možné dlhodobé umiestnenie snímača na danom mieste, napr. z dôvodu, že dlhodobá prevádzka tohto snímača je z hľadiska spotreby energie alebo ekonomických dôvodov neudržateľná. Senzorické dáta sú decentralizované, zašumené a často je problematické medzi meranými veličinami odhaliť skryté súvislosti, explicitne ich vyjadriť, resp. získať relevantné informácie a dospieť k exaktnému riešeniu úlohy. Vhodne navrhnutá neurónová sieť by mala byť schopná odhaliť tieto závislosti a maximalizovať informačný obsah.

Medzi hlavné tézy dizertačnej práce patrí:

- Návrh neurónovej siete vhodnej na odhad meranej veličiny v daných bodoch bezdrôtovej senzorickej siete.
- Simulačné a experimentálne overenie navrhnutých neurónových sietí.
- Porovnanie dosiahnutých výsledkov a ich vplyv na šetrenie energie.

1 WSN siete

Bezdrôtové senzorické siete (WSN) predstavujú vzájomné prepojenie rôznych senzorických uzlov, ktoré komunikujú bezdrôtovo a zhromažďujú alebo preposielajú namerané údaje z okolitého prostredia [2]. Hoci tieto siete v dnešnej dobe získavajú veľkú popularitu, pri implementácii sa stále stretávame s obmedzeniami, ktoré sa týkajú výpočtového výkonu, veľkosti pamäte, výdrže batérií, kapacity prenosového kanála a implementácie zabezpečenia.

V súčasnosti sa zariadenia schopné snímať rôzne parametre prostredia v rámci rôznych aplikačných oblastí stávajú stále viac a viac realitou. Väčšina týchto zariadení je schopná vzájomnej komunikácie a priamo, alebo prostredníctvom prístupových zariadení sú integrované do siete Internet. Týmto spôsobom je definovaný Internet vecí, tzv. Internet-of-Things (IoT).

Táto kapitola je venovaná problematike, ktorá predstavuje teoretický základ k bezdrôtovým senzorickým sieťam. Sú tu popísané rôzne oblasti využitia WSN [3], [4]. Nachádza sa tu taktiež taxonómia bezdrôtových sietí na základe rôznych kritérií a aplikácií využitia. Taktiež tu je v stručnosti vysvetlená základná štruktúra uzla WSN s dôrazom na energetickú náročnosť. Nakoľko v reálnych experimentoch tejto práce bola využitá na komunikáciu v navrhutej WSN LoRa technológia [5],[6], rozhodli sme sa taktiež stručne popísať princíp tejto modulácie a komunikačný protokol LoRaWAN, ktorý je implementovaný nad touto technológiou.

1.1 Aplikácie

Bezdrôtové senzorické siete, ako priestorovo distribuované siete tvorené relatívne jednoduchými vzájomne spolupracujúcimi prvkami majú veľký aplikačný potenciál vo vojenských [7], [8], [9], priemyselných [10] dopravných [11], environmentálnych [12] a mnohých ďalších oblastiach.

Vo vojenskej oblasti sa vyskytuje množstvo úloh spojených s monitorovaním územne rozľahlých oblastí [13], pričom ekonomické hľadiská zavádzania nových technológií nie sú až natoľko prioritné ako v iných odvetviach hospodárstva. Spomeňme aspoň systémy navádzania a sledovania cieľa, systémy na detekciu pohybu a identifikáciu druhu bojových prostriedkov, monitorovanie bojového poľa (battlefield surveillance)

aplikácie IoT v súvislosti s monitorovaním a ovládaním mŕnových polí, detekciu nukleárných, biologických a chemických útokov a mnohé ďalšie [14].

Ďalšie zaujímavé aplikácie IoT je možné nájsť pri monitorovaní a ochrane životného prostredia. Monitorovanie prostredia patrí dnes snáď medzi najčastejšie aplikácie bezdrôtových sietí senzorov [15]. Práve tieto aplikácie si vyžadujú použitie veľkého počtu lacných snímacích prvkov, ktoré je možné jednoducho rozmiestniť do sledovanej oblasti. Ako najčastejšie aplikácie je možné uviesť monitorovanie pohybu ľadovcov [16], [17], monitorovanie a ochrana lesa pred požiarmi, nepovoleným výrubom, pytlakmi, varovné systémy pred záplavami a ďalšími prírodnými katastrofami [18], [19], sledovanie zmien mikroklímy, intenzity slnečného žiarenia a množstvo ďalších zaujímavých aplikácií.

Ďalšou perspektívnou aplikačnou oblasťou bezdrôtových senzorických sietí je oblasť starostlivosti o zdravie, záchrana služba a asistenčné systémy (e-Health). Je zrejmé, že s využitím technológií IoT je možné zvýšiť súčasnú úroveň monitorovania pacientov [20], [21], ako aj úroveň zdravotnej starostlivosti. Ako príklad uvedme monitorovanie vitálnych funkcií pacientov v nemocnici. Tieto monitorovacie systémy umožňujú pohyb pacienta pri zachovaní všetkých funkcií statických systémov. Pripomeňme oblasť starostlivosti o staršiu generáciu [22], prípadne o ľudí s telesným postihnutím, ktorým moderné technológie dovoľujú zvýšiť kvalitu života. V tejto oblasti by bolo možné nájsť mnoho zaujímavých a inšpiratívnych príkladov.

S využitím technológie IoT sa dnes často stretáme v dopravných aplikáciách. Pri monitorovaní a riadení dopravy sú zdroje informácií priestorovo rozptýlené v rozľahlej oblasti. Komplexný prehľad o stave dopravy je možné získať len na základe informácií získaných z veľkého počtu vhodne rozmiestnených snímačov. Problematika monitorovania a riadenia dopravy preto prirodzene smeruje aj do oblasti aplikácií senzorických sietí [23], [24], [25].

Bezdrôtové senzorické siete nachádzajú uplatnenie aj v priemysle. V priemyselných aplikáciách sa najčastejšie stretávame s úlohami monitorovania výroby, pri riadení skladového hospodárstva, prípadne dnes už častejšie, s riadením technologických procesov [26]. Pripomeňme, že v prípade aplikácií v riadení technologických procesov sa často stretávame s pojmami „bezdrôtová sieť senzorov a akčných členov“, „Wireless Sensor and

Actuator Networks“ – WSN [27], prípadne tiež „priemyselná bezdrôtová sieť senzorov“, Industrial Wireless Sensor Networks“, IWSN [28], [29].

Poznamenajme, že popísané aplikácie tvoria len malú oblasť celého aplikačného priestoru IoT. Neboli spomenuté viaceré aplikačné oblasti, s ktorými sa dnes v praxi často stretáme – automatizácia budov, monitorovanie produktovodov, zabezpečovacie systémy, poľnohospodárstvo [30] a mnohé ďalšie.

1.2 Klasifikácia WSN sietí

Vzhľadom na existenciu veľkého množstva bezdrôtových sietí a technológií, bolo potrebné vytvoriť systém klasifikácie a kategorizácie, ktorý tieto siete zoskupuje do kategórií na základe spoločných znakov a vlastností. Tieto spoločné črty tvoria hodnotiace kritériá. Vďaka tomuto rozdeleniu je používateľ schopný vybrať vhodný typ siete pre jeho konkrétnu aplikáciu. V niektorých prípadoch je potrebné použiť viac kritérií na kategorizáciu, aby sa systém dal jednoznačne klasifikovať [31]. Členenie bezdrôtových sietí je rôznorodé, no môže byť realizované najmä podľa nasledovných kategórií:

- topológie,
- prenosovej rýchlosti,
- použitej technológie,
- vlastníctva,
- územnej rozľahlosti,
- smeru prenosu,
- typu komunikačného protokolu,
- spôsobu prepojovania,
- typu poskytovaných služieb,
- zdieľania zdroja.

Na základe komunikačnej rýchlosti môžeme rozdeliť bezdrôtové siete na:

- vysokorýchlostné,
- nízkorýchlostné.

V minulosti boli siete typu WAN a LAN delená hlavne na základe tohto parametra, v súčasnosti sa však rozdiel v prenosovej rýchlosti znižuje. V sieťach určených pre IoT

aplikácie je kladený dôraz skôr na dosah signálu ako na prenosovú rýchlosť, ktorá pri týchto aplikáciách nie je kľúčová.

Na základe územnej rozľahlosti sa komunikačné siete rozdeľujú do dvoch základných skupín a na lokálne a na rozľahlé [31]. Postupne však pribudli ďalšie skupiny sietí, vďaka ktorým do rozdelenia pribudli nasledujúce kategórie:

- GAN (Global Area Networks),
- WAN (Wide Area Networks),
- MAN (Metropolitan Area Networks),
- LAN (Local Area Networks),
- PAN (Personal Area Networks)
- BAN (Body Area Networks).

Každá sieť spravidla poskytuje možnosť zdieľať určité informácie ostatným zariadeniam v sieti. Z hľadiska zdieľania zdroja môžeme kategorizovať siete na:

- klient-server,
- peer to peer.

V prípade klient-server sú zdieľané položky centralizované na jednom mieste, väčšinou na spoločnom serveri. V druhom prípade sú zdieľané položky lokalizované na pôvodnom mieste, odkiaľ je možné ich následne zdieľať.

Ďalšiu kategorizáciu možno uskutočniť na základe vlastníctva siete:

- verejné siete,
- privátne siete,
- virtuálne privátne siete (VPN) [31].

Rozdiel medzi verejnou a privátnou sieťou je zrejmý. Vlastník verejnej siete ponúka využitie svojej siete iným subjektom na komerčné použitie. Vlastníkom privátnej siete je jeden subjekt, napríklad spoločnosť, ktorá sieť využíva len na svoje účely. VPN je služba, má základnú myšlienku vytvorenie privátnej virtuálnej siete v rámci verejných komunikačných sietí.

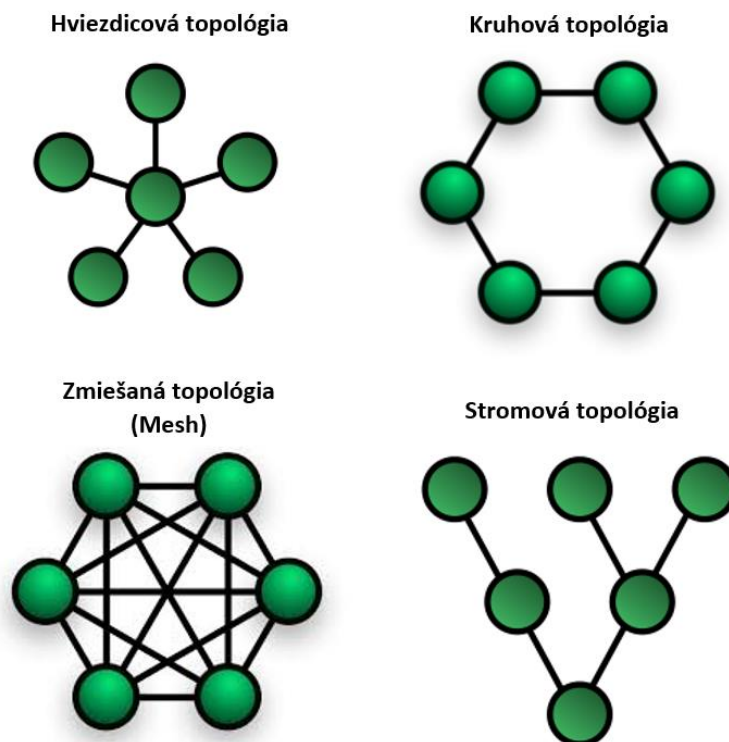
Podľa smeru komunikácie môžeme siete rozdeliť na:

- simplex (jednosmerný prenos),
- half duplex / polo duplex (prepínaný jednosmerný prenos),
- duplex (obojsmerný súčasný prenos).

1.2.1 Kategorizácia na základe topológie

Bezdrôtové siete môžeme na základe topológie rozdeliť do štyroch základných skupín. Topológia siete určuje spôsob vzájomného komunikačného prepojenia zariadení medzi sebou. V bezdrôtovej sieti sa to týka najmä toho, ktoré zariadenie je schopné komunikovať s ktorým. Topológiu siete môžeme ďalej rozdeliť na logickú a fyzickú. Logická topológia určuje spôsob prepojenia na danej fyzickej topológii. Fyzická topológia predstavuje priestorové rozloženie jednotlivých zariadení. Medzi najviac využívané topológie bezdrôtových sietí, zobrazené na obrázku č. 1, s viacerými komunikačnými zariadeniami patrí:

- hviezdicová topológia,
- kruhová topológia,
- zmiešaná topológia (mesh),
- stromová topológia.



Obrázok 1 Topológie bezdrôtových sietí [2]

Hviezdicová topológia patrí v bezdrôtových sieťach medzi najpopulárnejšie. Koncové uzly komunikujú výlučne s centrálnym prvkom v sieti. To platí aj v prípade, keď chcú komunikovať medzi sebou. Nevýhodou spočíva v tom, že celá sieť je závislá na spoľahlivosti centrálného zariadenia. Hviezdicová topológia je využívaná vo WiFi sieťach. Pri kruhovej topológii zariadenia komunikujú len so susednými zariadeniami. Prenos je zväčša realizovaný len jednosmerne na základe distribúcie prístupu k prenosovému médiu. Spoľahlivosť siete je určená spoľahlivosťou jednotlivých zariadení v sieti. Zmiešaná topológia (mesh) predstavuje možnosť komunikácie každého zariadenia s každým, pričom toto prepojenie nemusí byť úplné. Predstavuje najspoľahlivejšiu topológiu zo všetkých spomenutých. Výpadok jedného zariadenia v sieti neobmedzí komunikáciu medzi ostatnými prvkami siete. Topológia typu strom je tvorená postupným pridávaním zariadení k vrcholovému komunikačnému uzlu siete. Táto topológia sa využíva v telefónnych sieťach typu GSM. Všeobecne platí, že modely komunikačných sietí môžu obsahovať viac druhov topológií [31].

1.3 Štruktúra snímacieho zariadenia vo WSN

Vo všeobecnosti sa každé snímacie zariadenie, ktoré predstavuje uzol vo WSN skladá z niekoľkých základných komponentov, ktorými sú:

- riadiaca jednotka,
- snímacie prvky,
- napájacia jednotka,
- pamäť,
- komunikačný modul.

Hlavnou úlohou riadiacej jednotky je spracovanie dát od jednotlivých senzorov a riadenie funkcií všetkých ostatných hardvérových komponentov, ktoré sú nevyhnutné na správnu činnosť celého systému. Táto časť je zodpovedná za získanie a následné spracovanie signálov od jednotlivých snímacích komponentov. Taktiež má za úlohu zabezpečiť odoslanie, resp. príjem dát s komunikačným modulom. Riadiaca jednotka môže byť tvorená napríklad mikrokontrolérom (MCU), poľom programovateľných hradiel (FPGA), zákaznickým obvodom (ASIC) alebo číslicovým signálnym procesorom (DSP). Vo väčšine prípadov sa ako hlavná riadiaca jednotka používa mikrokontrolér, hlavne

z dôvodu flexibility a implementácie množstva periférií. Ďalšou výhodou je pomerne nízka cena a nízka spotreba energie, na ktorú sa kladie dôraz vo väčšine aplikácii WSN.

Snímacie prvky sú tvorené senzormi, ktorých hlavnou úlohou je detegovať a reagovať na rôzne vstupy z okolitého sveta. Tieto špecifické vstupy môžu byť napríklad: svetlo, teplota, tlak, vlhkosť, rýchlosť, intenzita elektromagnetického poľa, atď. Tieto senzory umožňujú transformovať neelektrickú veličinu na elektrický signál. Vstupný signál je všeobecne analógový signál, ktorý sa prevádza do digitálnej formy pomocou analógovo-číslicového prevodníka (ADC). V niektorých prípadoch je tento prevodník už súčasťou daného senzoru.

Na vykonávanie jednotlivých operácií potrebuje každý prvok v sieti zdroj energie. Vo väčšine prípadov sú hlavným zdrojom energie batérie. Vzhľadom sa obmedzené možnosti napájania je potrebné minimalizovať spotrebu jednotlivých prvkov. V súčasnosti prebieha aj výskum v oblasti energy-harvestingu. Cieľom je využívať energiu z okolitého prostredia a následne ju premieňať na elektrickú energiu. Tá by bola následne využitá ako zdroj energie, čo má za následok predĺženie prevádzky daného prvku.

Ak je potrebné uchovávať časť, alebo všetky namerané údaje, tak daný uzol obsahuje aj externú pamäť. To však závisí výlučne od danej aplikácie. Najčastejším príkladom využitia externej pamäte je microSD karta alebo externá FLASH pamäť. Väčšina mikrokontrolérov poskytuje obmedzenú RAM, FLASH alebo EEPROM pamäť, ktorá sa nachádza priamo v integrovanom obvode.

Aby bola zabezpečená komunikácia v sieti, každý uzol musí obsahovať komunikačný modul. To, ako jednotlivé uzly medzi sebou, prípadne centrálnymi uzlami v sieti komunikujú závisí od použitej technológie a komunikačného protokolu. Často sa jednotlivé uzly nachádzajú v ťažko prístupnom teréne a pokrývajú rozsiahle územie. Preto je voľba komunikačnej technológie a protokolu kľúčová.

1.4 Spotreba energie WSN

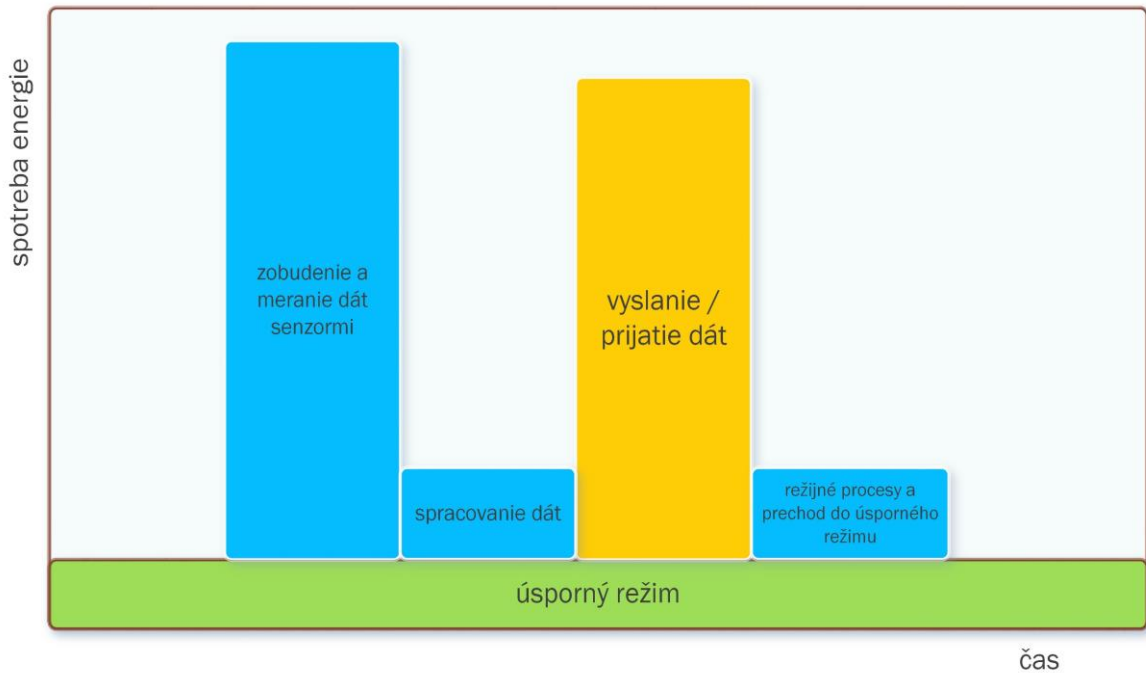
Hlavné obmedzenia vo WSN predstavujú v súčasnosti zdroje energie. Často sa jednotlivé moduly nachádzajú v nedostupnom teréne, kde trvalé zdroje elektrickej energie z ktorých by mohli byť jednotlivé moduly napájané sú nedostupné. Vo všeobecnosti možno spotrebu energie v jednotlivých uzloch WSN rozdeliť do troch základných častí:

- senzorický podsystem,
- podsystem spracovania signálov,
- komunikačný podsystem.

WSN modul má z pohľadu spotreby energie nasledovnú štruktúru: jeden alebo viacero senzorov s analógovým alebo digitálnym výstupom, nízkoenergetický AD prevodník v prípade analógových senzorov, a mikrokontrolér, ktorý sa väčšinou uvádza do niektorého z režimov spánku, aby sa tak znížila spotreba energie a zobúda sa periodicky, keď je potrebné získať dáta zo senzorov, uloží ich vo svojej pamäti alebo na externom pamäťovom médiu a v určenom intervale odošle väčšinou nízko-rýchlostnou rádiovou linkou do zberného miesta. Z týchto troch štádií má zvyčajne najväčšie požiadavky na energiu posledný proces. Jeho energetický profil vyzerá ako relatívne krátka sekvencia vysokých prúdových špičiek po ktorých nasleduje relatívne dlhá pokojová fáza (rádovo minúty a niekedy dokonca hodiny). Dlhodobá udržateľnosť batérií je dôležitá hlavne pri inštaláciách v odľahlých lokalitách, ako napr. aplikácie v oceánoch ďaleko od pobrežia [57], alebo pri systémoch využívajúcich energy-harvesting [58][59][60]. Nakoľko vo väčšine aplikácií WSN prevláda spotreba energie senzorického a komunikačného podsystemu, nasledujúce časti sa venujú popisu týchto periférií.

1.4.1 Senzorický podsystem

Senzory, ktoré tvoria periférie WSN modulu, môžeme z hľadiska spotreby rozdeliť tiež na dve základné kategórie: nízko-energetické a vysoko-energetické. Pri použití niektorých senzorov je nie len samotné meranie požadovanej veličiny energeticky náročné ale aj samotné napájanie senzora má relatívne vysoký odber. K tomuto javu dochádza napríklad u senzorov, ktoré pre svoju korektnú činnosť potrebujú nepretržité napájanie zo zdroja. Môže sa jednať napríklad o senzory znečistenia ovzdušia, kde je potrebné aby mal snímací element konštantnú teplotu, na čo slúži ohrievač vo vnútri zariadenia (napr. senzor MQ135 od firmy Olimex). Tu je na mieste otázka vhodnosti použitia takejto metódy merania, ak existuje náhrada. Energeticky náročné senzory bývajú použité napríklad len pri vývoji prototypu modulu a neskôr sa môžu nahradiť senzormi založenými na inom princípe detekcie, ktoré bývajú však zvyčajne finančne náročnejšie. Ilustračný graf spotreby energie na obrázku č. 2, znázorňuje, že pri vysoko-energetických moduloch, môže spotreba senzora prevýšiť aj spotrebu energie potrebnú na komunikáciu modulu, ktorá býva zvyčajne energeticky najnáročnejšia.



Obrázok 2 Spotreba energie pri použití vysoko-energetických senzorov

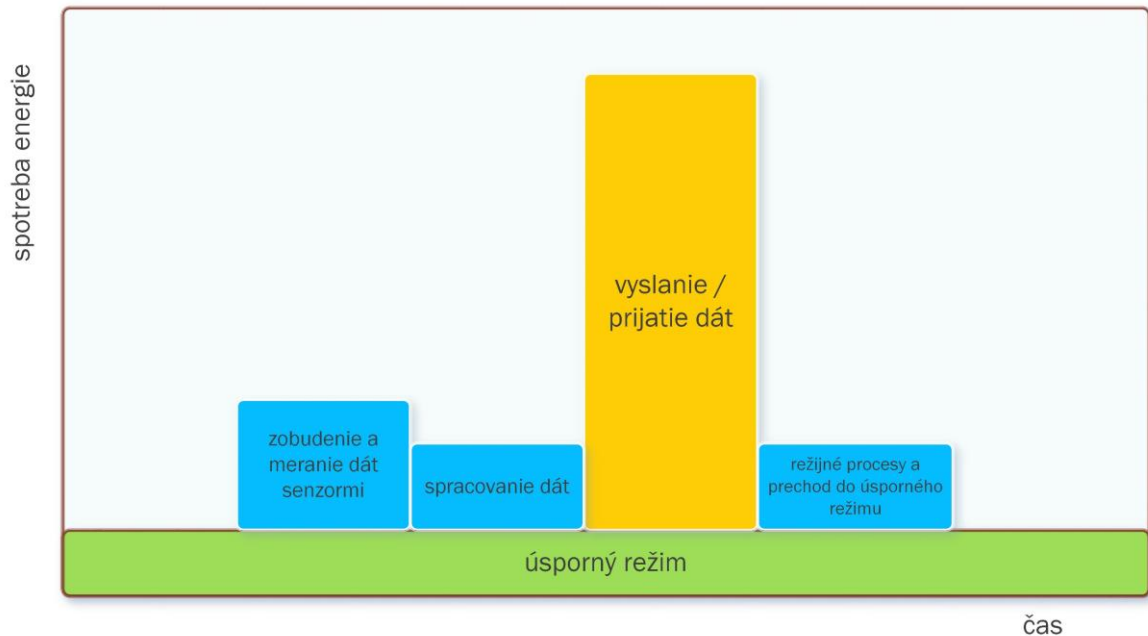
1.4.2 Komunikačný podsystém

Komunikácia v rámci bezdrôtovej siete má zvyčajne najvyššiu spotrebu z celého WSN systému. Spotreba energie pri vysielaní požadovaných správ je oproti ostatným procesom, ktoré prebiehajú v rámci jedného WSN modulu spravidla najvýraznejšia, čo je ilustrované na obrázku č. 3. Množstvo energie potrebnej na komunikáciu je závislé na vzdialenosti od komunikačného bodu, od tejto vzdialenosti je závislý vysielací výkon zariadenia, ďalej je spotreba závislá od rýchlosti prenosu a v neposlednom rade aj od množstva dát, ktoré je potrebné odoslať. Ak sa pozrieme na množstvo prenesených dát detailne, je možné vidieť priestor pre šetrenie vysielacieho výkonu. Je viacero prístupov, akým spôsobom sa dáta do komunikačného / zberného bodu odosielajú:

- modul odošle všetky surové dáta získané zo senzorov do centrálného uzla,
- modul odošle predspracované dáta,
- modul odošle len užitočnú informáciu, získanú spracovaním priamo v module.

Existuje viacero techník ako znižovať najmä objem prenášaných dát. V druhom type prenosu môže ísť napr. o vytvorenie aritmetického priemeru z n po sebe nasledujúcich vzoriek a odošlú sa len priemery, čo predstavuje niekoľkonásobné zníženie prenášaného objemu dát. Ďalej môžu byť nasadené iné matematické operácie, rôzne transformácie, tiež je možné dáta skomprimovať a odoslať v menšom objeme. Tretí prístup, keď koncové

zariadenie posiela do centrály len konkrétnu informáciu, môže implementovať napr. natrénovanú jednoduchú neurónovú sieť navrhnutú priamo pre merané veličiny. Okrem týchto prístupov existujú aj mnohé algoritmy, ktoré vhodne prerozdeľujú komunikáciu v rámci WSN alebo v rámci klastra WSN modulov, napr. [61][62].



Obrázok 3 Vplyv komunikácie na energetickú náročnosť modulu

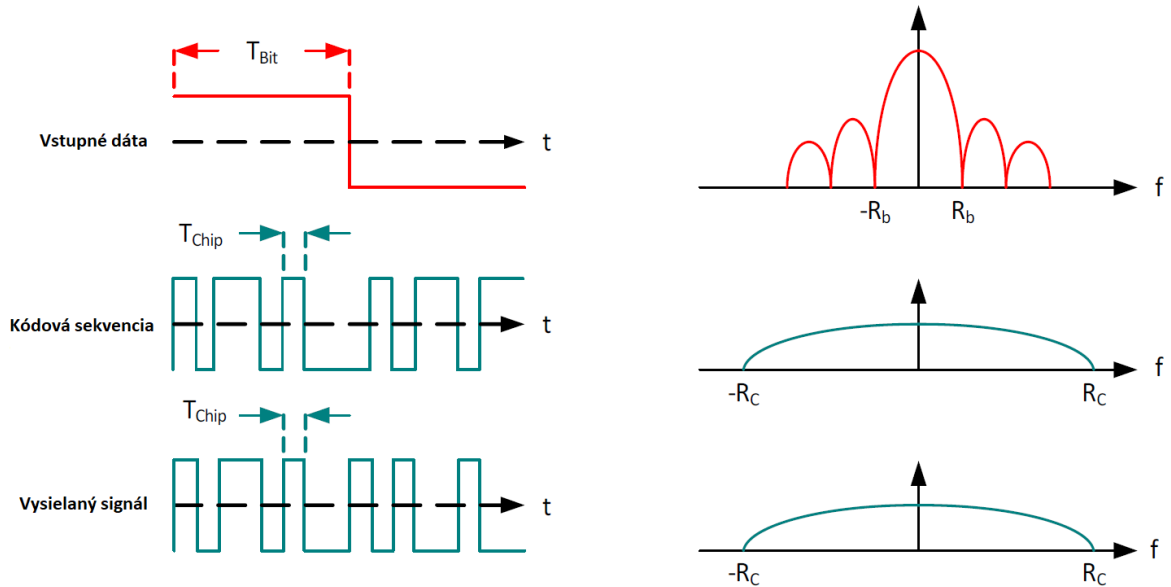
1.5 LoRa technológia

LoRa technológia je jednou z množstva technológií, ktoré sú určené na komunikáciu v rámci internetu vecí (IoT), a najmä pre zariadenia, ktoré medzi sebou komunikujú na väčšiu vzdialenosť. Tieto zariadenia sú nainštalované na veľkej rozlohe (Wide Area Network). Je pre ne charakteristický nízky dátový tok a malá spotreba energie.

Technológia má základ na modulácii rozprestretého spektra, pričom má podobnú charakteristiku ako FSK modulácia (frekvenčné kľúčovanie), ale s oveľa dlhším dosahom. Modulácia využívajúca rozprestreté spektrum sa začala používať vo vojenskom priemysle pred niekoľkými desaťročiami práve z dôvodu dlhého dosahu a robustnosti siete voči rušeniu. Proces modulácie pri vysielaní dát sa nachádza na obrázku č. 4. Pri demodulácii je postup podobný, len v opačnom poradí [4].

V typických systémoch, ktoré využívajú rozprestreté spektrum (DSSS) sa nosná fáza vysielača mení v závislosti na kódovej sekvencii. Tento proces je vo všeobecnosti dosiahnutý vynásobením požadovaného dátového signálu a rozširujúceho kódu, ktorý sa nazýva postupnosť čipov. Táto sekvencia sa vo finálnom signáli vyskytuje s vyššou

frekvenciou (R_c) ako samotný dátový signál (R_b) a tým rozširuje šírku pásma pôvodného signálu. Označenie čip sa používa, aby sa odlišili kratšie kódované bity od dlhších nekódovaných bitov informačného signálu [5].



Obrázok 4 Proces modulácie s využitím rozprestretého spektra [6]

Technológia LoRa využíva na rozšírenie spektra špeciálny signál¹, ktorý kontinuálne mení svoju frekvenciu. Výhoda tejto metódy spočíva v tom, že časové a frekvenčné odchýlky medzi vysielačom a prijímačom sú ekvivalentné, čo výrazne znižuje zložitosť návrhu prijímača. Táto technológia najčastejšie využíva nasledujúce šírky pásma: 125 kHz, 250 kHz a 500 kHz. Technológia LoRa tiež zahŕňa variabilnú korekciu chýb, ktorá zlepšuje odolnosť celého riešenia. Táto implementácia sa vykonáva kódovaním 4-bitových slov do 5, 6, 7 alebo až 8-bitových redundantných dát. Vďaka tomu je riešenie robustné voči krátkym interferenciám signálu. Hodnotu kódovacej rýchlosti je potrebné modifikovať podľa použitého kanála na prenos dát. Ak sa v tam nachádza veľké rušenie, odporúča sa zvýšiť hodnotu kódovacej rýchlosti. Zvýšenie tohto parametra však predĺži dobu prenosu. Kódovacia rýchlosť sa často označuje aj symbolmi 4/5, 4/6, 4/7 a 4/8. Čím je vyšší faktor rozšírenia, tým je dosah signálu dlhší, avšak na úkor prenosovej rýchlosti. Prenosová rýchlosť sa pohybuje v rozsahu od 300 bitov až do 50 kilobitov za sekundu na

¹ V odbornej literatúre písanej v angličtine sa používa termín „chirp signal“.

základe faktoru rozšírenia, kódovacej rýchlosti a šírke pásma modulácie. Nominálnu prenosovú rýchlosť je možné definovať na základe vzťahu [6]:

$$R_b = SF * \frac{4 + CR}{\frac{2^{SF}}{BW}} \quad (1.1)$$

kde:

R_b = nominálna prenosová rýchlosť [bit/s]

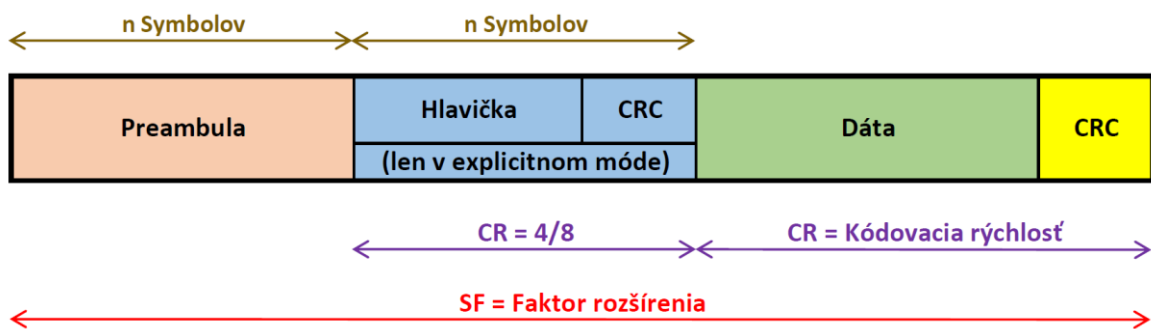
SF = faktor rozšírenia [7..12]

CR = kódovacia rýchlosť [1..4]

BW = šírka pásma modulácie [Hz]

1.5.1 Štruktúra paketu

LoRa technológia podporuje implicitný a explicitný formát dátových paketov. Explicitný formát obsahuje krátku hlavičku, informácie o počte dátových bajtov, o kódovacej rýchlosti a o prítomnosti 16-bitového CRC kódu. Štruktúra celého paketu sa nachádza na obrázku č. 5.



Obrázok 5 Štruktúra LoRa paketu

Paket sa skladá z troch hlavných častí:

- preambula,
- voliteľná hlavička,
- užívateľské dáta.

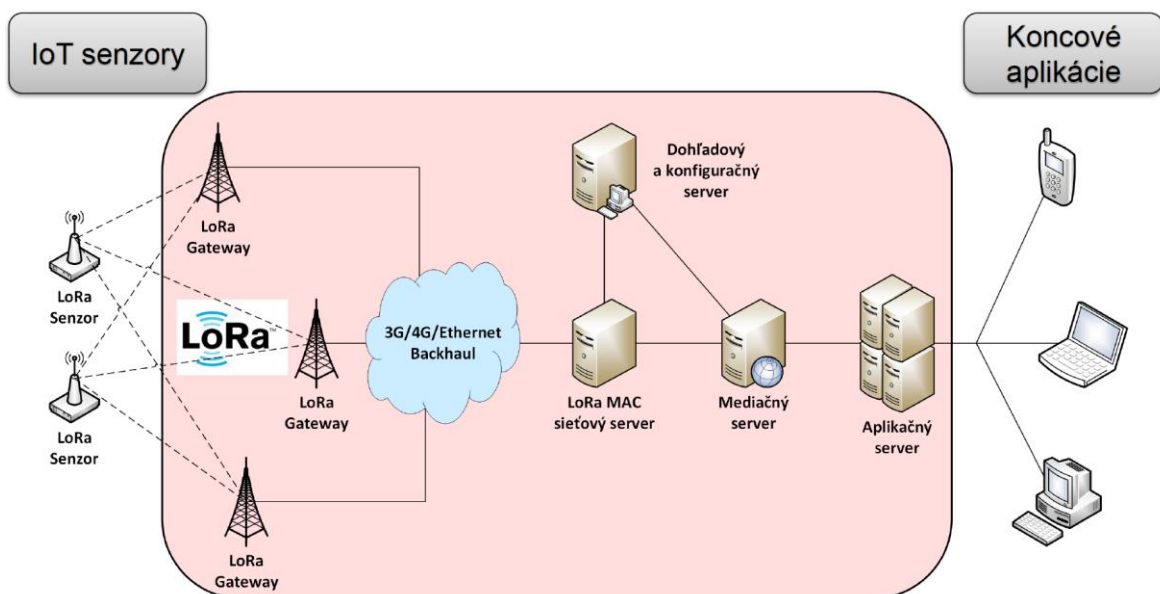
Preambula sa využíva na synchronizáciu vysielača a prijímača. V predvolenom nastavení preambula obsahuje 12 symbolov. Dĺžka preambuly sa môže programovo nastaviť v rozsahu od 6 do 65535 symbolov. Prijímač periodicky vykonáva detekciu preambuly. Z tohto dôvodu by mala byť nastavená na rovnakú hodnotu na oboch stranách

komunikačného kanála. Ak dĺžka preamble nie je dopredu známa, prípadne sa v priebehu vysielania mení, tak na strane prijímača by mala byť nakonfigurovaná maximálna dĺžka.

V prípadoch, že sú dopredu známe a nemenné všetky parametre a počet bajtov prenášaných dát, je vhodné využiť implicitný mód, ktorý neobsahuje hlavičku paketu. To má za následok redukovanie celkového vysielacieho času paketu. V tomto prípade musia byť dané parametre dopredu manuálne nakonfigurované [63].

1.6 LoRaWAN

LoRaWAN predstavuje štandardizovaný komunikačný protokol, ktorý využíva LoRa technológiu na najnižšej – fyzickej vrstve komunikácie. Tento komunikačný protokol je použiteľný na aplikácie, ktoré potrebujú komunikovať na dlhšiu vzdialenosť s nízkou prenosovou rýchlosťou a nízkymi požiadavkami na spotrebu energie.



Obrázok 6 Architektúra LoRaWAN [64]

Tento protokol využíva hviezdicovú topológiu siete, ktorá má pozitívny efekt na životnosť batérií uzlov v sieti pri zachovaní dosahu siete. Architektúra LoRaWAN sa nachádza na obrázku č. 6. Každé koncové zariadenie obsahuje LoRa rádiový modul. Správy posielané koncovým zariadením môžu byť prijaté viacerými prístupovými bodmi zároveň. Prístupový bod prijíma správy od koncových zariadení a preposiela ich na sieťový server. Duplicitné správy (prijaté viacerými prístupovými bodmi zároveň) sa filtrujú na serveri. Tento server spravuje rádiovú vrstvu a má na starosti optimalizáciu celej komunikácie. Ďalej sa tu využíva aj server, ktorý slúži na konfiguráciu a monitoring

siete. Mediačný a aplikačný server spracovávajú a uchovávajú prijaté dáta. Koncové aplikácie sú určené na vizualizáciu zozbieraných dát od koncových zariadení, ktoré predstavujú hlavne rôzne senzory. O štandardizáciu a rozvoj tejto siete sa stará LoRa Aliancia, ktorej súčasťou sú aj desiatky firiem.

V Európe LoRaWAN definuje 10 kanálov. Z toho je jeden vysokorýchlostný s rýchlosťou 11 kbps, 8 ďalších kanálov s prenosovými rýchlosťami od 250 bps do 5,5 kbps a jeden samostatný FSK kanál (868,8 MHz) o rýchlosti 50 kbps. Jednotlivé prenosové kanály, ktoré využívajú LoRa moduláciu sú špecifikované v tabuľke č. 1. Systém má taktiež podporu tzv. geolokalizácie s presnosťou približne 20 m, ak vysielajúce zariadenie zachytia aspoň 3 prístupové body. Sieť využíva všetkých 6 faktorov rozšírenia (SF7 až SF12) a prispôsobuje rýchlosť prenášaných údajov. Čím je potrebný dlhší dosah, tým je faktor rozšírenia vyšší. To má ale za následok pokles prenosovej rýchlosti, ktorá je závislá aj na šírke pásma kanálu [64].

Tabuľka 1 Špecifikácia LoRaWAN prenosových kanálov EU868MHz

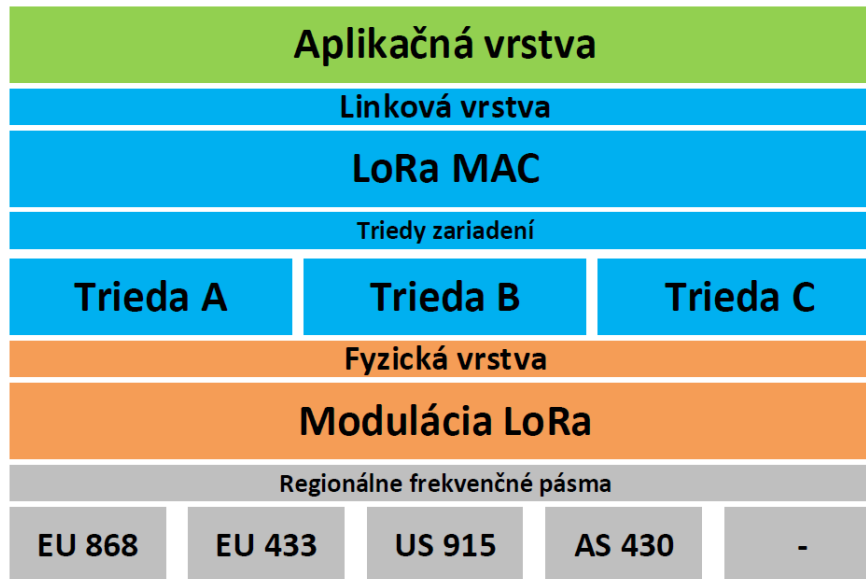
Číslo kanála	Downlink / Uplink [D/U]	Frekvencia [MHz]	Šírka pásma [kHz]	Faktor rozšírenia
1	D/U	868,1	125	7 - 12
2	D/U	868,3	125 / 250	7 - 12 / 7
3	D/U	868,5	125	7 - 12
4	D/U	867,1	125	7 - 12
5	D/U	867,3	125	7 - 12
6	D/U	867,5	125	7 - 12
7	D/U	867,7	125	7 - 12
8	D/U	867,9	125	7 - 12
9	D	869,525	125	9

Koncové zariadenia v sieti sú asynchrónne a posielajú správy prístupovému bodu v pravidelných intervaloch, alebo pri výskyte nejakej konkrétnej udalosti. Tento typ protokolu sa často označuje pod názvom Aloha. V porovnaní s inými nízkoenergetickými WAN technológiami dosahuje LoRaWAN 3 až 5-krát dlhšiu životnosť batérie [65].

1.6.1 Rozdelenie vrstiev v sieti

Jednotlivé vrstvy tohto protokolu sa nachádzajú na obrázku č. 7. Zatiaľ čo LoRa modulácia zabezpečuje komunikačnú linku na najnižšej úrovni, LoRaWAN definuje komunikačný protokol a samotnú architektúru siete. Práve sieťová architektúra a komunikačný protokol majú najväčší vplyv na kapacitu siete, priepustnosť, životnosť

batérií jednotlivých uzlov, bezpečnosť, QoS (Quality of Services) a rôznych aplikácií poskytovaných sieťou.



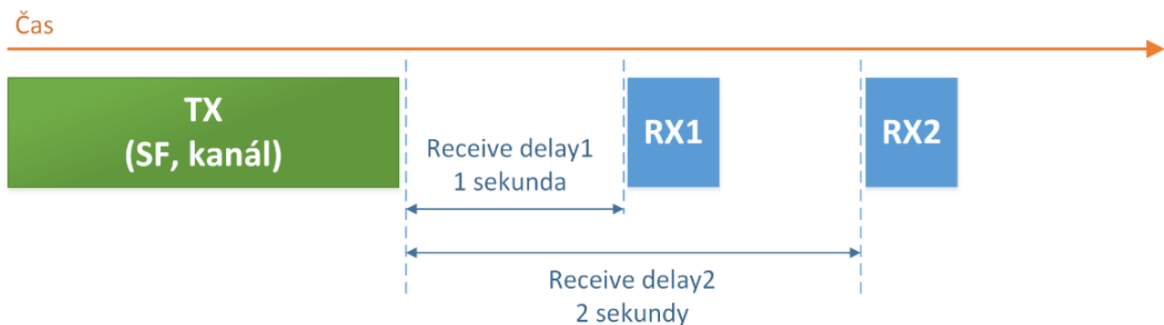
Obrázok 7 Vrstvy protokolu LoRaWAN [64]

Tento komunikačný protokol rozdeľuje zariadenia v sieti na linkovej vrstve do troch základných tried:

- **Trieda A** – Predstavuje energeticky najúspornejšie zariadenia, ktoré podporujú obojsmernú komunikáciu. Každá správa, ktorá smeruje od koncového zariadenia k bráne (uplink) je nasledovaná dvomi krátkymi časovými oknami, v ktorých je možná komunikácia opačným smerom (downlink). Oneskorenie medzi jednotlivými časovými oknami je možné zmeniť podľa potreby cez sieťový server. Downlinková správa v inom čase musí byť zaradená do fronty správ na sieťovom serveri a vyslanie správy je možné až po prijatí uplinkovej správy z koncového uzla siete. Pri uplinkovej komunikácii sa využíva protokol typu ALOHA s malou odchýlkou založenou na náhodnom čase. Priebeh komunikácie je znázornený na obrázku č. 8. Koncové zariadenie je schopné prejsť do režimu s nízkou spotrebou energie na tak dlhý čas, aký definuje konkrétna aplikácia. Nie je potrebné žiadne periodické prebúdzanie zariadení z dôvodu sieťových požiadaviek. Najčastejšie sa používajú zariadenia tohto typu.
- **Trieda B** – Okrem časových okien definovaných v triede A môžu zariadenia triedy B prijímať správy (downlink) v pravidelných časových slotoch. Zariadenia sa synchronizujú so sieťou pomocou špeciálnych správ zvaných beacons. Toto

poskytuje sieti schopnosť odosielať správy koncovým zariadeniam s deterministickou latenciou, čo má ale za následok zvýšenie spotreby energie v koncových uzloch siete.

- **Trieda C** – Zariadenia tejto triedy znižujú latenciu downlinku tým, že prijímač koncového zariadenia je vždy aktívny, okrem času keď zariadenie vysiela (polovičný duplex). Z toho vyplýva, že sieťový server môže kedykoľvek zahájiť downlinkový prenos, za predpokladu, že dané zariadenie momentálne nevysiela. To má za následok minimálnu latenciu, avšak vysokú energetickú náročnosť koncových zariadení. Táto trieda je vhodná pre aplikácie, kde je k dispozícii nepretržitý a neobmedzený zdroj napájania. U zariadení, ktoré sú napájané z batérie je možné dočasne prepnúť medzi triedami A a C napríklad z dôvodu bezdrôtovej aktualizácie firmvéru.



Obrázok 8 Pribeh komunikácie – Trieda A [64]

1.6.2 Zabezpečenie a pripojenie k sieti

Nasadenie IoT aplikácie nie je len záležitosťou výberu správneho komunikačného protokolu, ale vyžaduje aj využitie osvedčených postupov implementácie a dodržiavanie bezpečnostných priemyselných štandardov. LoRaWAN bola navrhnutá so zabezpečením ako základným aspektom poskytujúcim bezpečnostné vlastnosti, ktoré vyhovujú potrebám vysoko škálovateľných nízkoenergetických aplikácií IoT. Sieť používa dve bezpečnostné vrstvy:

- aplikačnú,
- sieťovú.

Zabezpečenie na aplikačnej vrstve má na starosti, aby nižšie vrstvy nemali prístup k užívateľským dátam. Sieťová bezpečnostná vrstva zabezpečuje autenticitu uzla v sieti. Využíva sa pritom jedinečný IEEE EUI-64 identifikátor a AES šifrovanie. Hoci už boli

vydané novšie verzie tohto protokolu, veľa zariadení stále využíva verziu 1.0.2. V tejto verzii sú definované 4 identifikačné kľúče:

- DevEUI – Predstavuje jedinečný 64 bitový identifikátor zariadenia. Podľa tohto identifikátora rozlišuje sieťový server jednotlivé koncové zariadenia.
- AppEUI – Reprezentuje unikátny 64 bitový identifikátor aplikácie.
- AppKey – Predstavuje 128 bitový aplikačný kľúč využívaný pri AES šifrovaní. Tento kľúč sa používa pri OTAA (Over The Air Activation) pripojení zariadenia do siete. Je uložený v nešifrovanom tvare priamo v zariadení a slúži na odvodenie relačných šifrovacích kľúčov (NwkSkey, AppSkey).
- DevAddr – Je 32 bitová adresa koncového zariadenia v rámci siete pridelená sieťovým serverom.

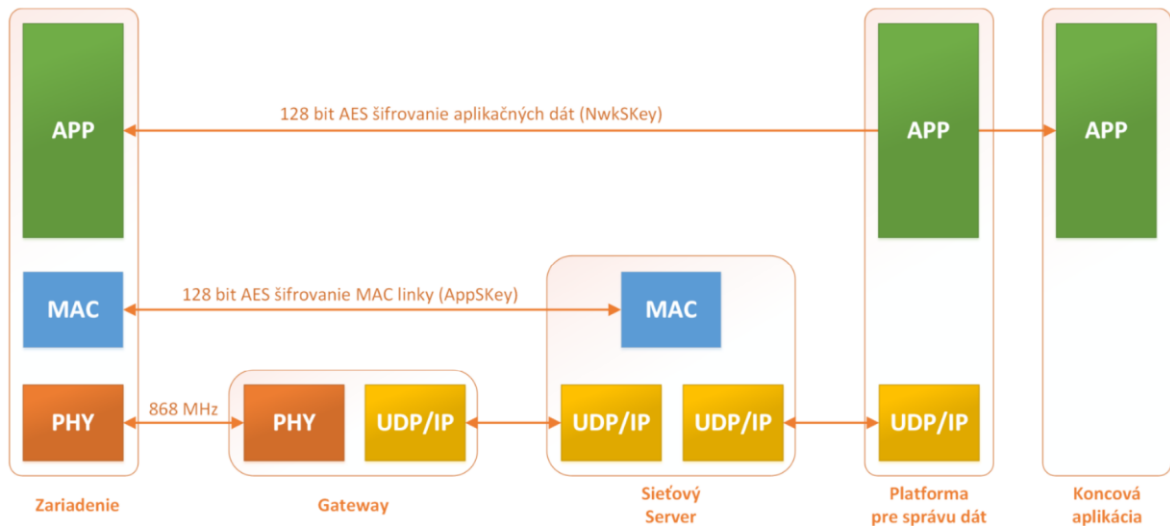
Po úspešnom pripojení zariadenia k sieti sú vygenerované 2 relačné šifrovacie kľúče, ktoré sú špecifické pre každé koncové zariadenie:

- NwkSKey – Predstavuje sieťový šifrovací kľúč. Tento kľúč sa používa na overenie integrity každej správy pomocou jej kódu integrity (MIC) medzi uzlom a sieťovým serverom.
- AppSKey – Reprezentuje aplikačný šifrovací kľúč a je využívaný koncovým zariadením a aplikačným serverom na šifrovanie užitočných dát.

Pripojenie koncových zariadení do siete a ich aktiváciu je možné uskutočniť dvomi rôznymi metódami. Prvá metóda sa nazýva skratkou ABP (Activation By Personalization). Pri tejto forme aktivácie koncového zariadenia je nutné do zariadenia zapísať priamo šifrovacie kľúče a DevAddr. Tieto informácie je potrebné zadať aj do sieťového a aplikačného servera. Tento spôsob pripojenia (aktivácie) sa však neodporúča z dôvodu bezpečnosti a náchylnosti k útoku pretože šifrovacie kľúče musia byť uložené priamo v zariadení.

Druhým a odporúčaným spôsobom pripojenia (aktivácie) k sieti je metóda zvaná OTAA (Over The Air Activation). Na koncovom zariadení je potrebné mať uložené 3 identifikačné kľúče: DevEUI, AppEUI a AppKey. Zariadenie sa pripojí do siete výmenou správ Join-request a Join-accept so sieťovým serverom. Ten po synchronizácii so zariadením vygeneruje relačné šifrovacie kľúče. Tieto kľúče sú vždy nanovo vygenerované pri každom pripojení do siete (aktivácii). Aplikačný šifrovací kľúč spoločne s DevAddr je zaslaný aplikačnému serveru v zašifrovanej forme.

Počas procesu pripájania k sieti sa medzi koncovým zariadením a sieťou využíva vzájomná autentifikácia. Tá zabezpečuje, že len overené zariadenia sa môžu pripojiť do siete. Jednotlivé správy v sieti sú šifrované na dvoch úrovniach, majú overený pôvod a chránenú integritu. Šifrovanie využíva štandardizované a overené kryptografické algoritmy AES. Celý proces šifrovania a zabezpečenia správ v LoRaWAN sa nachádza na obrázku č. 9, [66][67][68].



Obrázok 9 Zabezpečenie správ v LoRaWAN [64]


1.6.3 Spotreba energie

Ako už bolo spomenuté v predchádzajúcich kapitolách, komunikačný protokol LoRaWAN je určený pre IoT aplikácie, ktoré vyžadujú nízku spotrebu energie z dôvodu obmedzených energetických zdrojov koncových zariadení v sieti.

Zariadenie je väčšinu času v režime spánku s nízkou spotrebou energie (rádovo desiatky μA až maximálne niekoľko mA). Najväčšia spotreba elektrickej energie vo väčšine aplikácií využívajúcich túto technológiu nastáva v procese komunikácie (rádovo až desiatky mA) – zaslania nameraných dát (uplink), prípadne príjem správy (downlink). Ak využívame zariadenia triedy A, ktoré sú energeticky najúspornejšie, tak prijímač musí zostať aktívny po dobu dĺžky trvania dvoch časových okien, ktoré sú určené na príjem správy a až následne môže prejsť do režimu spánku s nízkou spotrebou.

Spotreba energie počas prenosu závisí od vysielačieho výkonu a dĺžky vysielačieho výkonu samotnej správy. Dĺžka vysielačieho výkonu závisí od veľkosti správy (počet bajtov), faktoru rozšírenia, šírky pásma a kódovacej rýchlosti. Obrázok č. 10 znázorňuje dĺžku vysielačieho výkonu

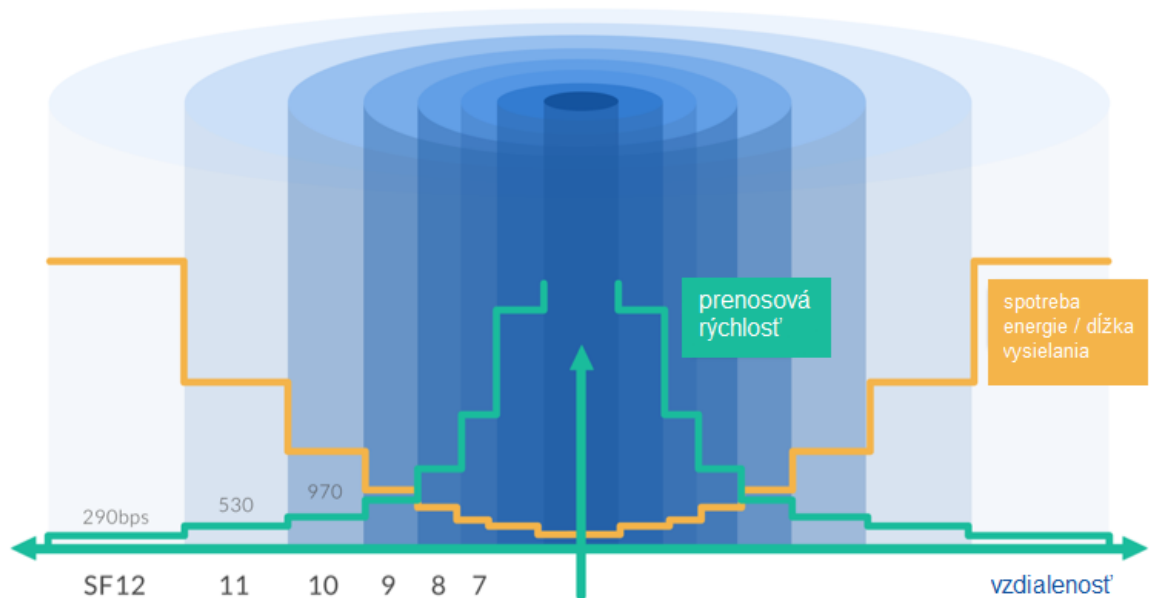
správy v sekundách v závislosti od faktoru rozšírenia pri šírke pásma 125 kHz a kódovacej rýchlosti 4/5 [69].



Obrázok 10 Graf závislosti dĺžky vysielania a veľkosti správy pri rôznom nastavení SF [69]

Adaptívna prenosová rýchlosť (Adaptive Data Rate - ADR) je mechanizmus na optimalizáciu prenosových rýchlostí, vysielacieho času a spotreby energie v sieti. Na obrázku č. 11 je zobrazený vplyv mechanizmu ADR, keď sa v sieti nachádza len jeden prístupový bod (brána) a uvažujeme zjednodušený model vo voľnom priestore. Z obrázka vyplýva, že vzdialenejšie uzly v sieti, ktoré používajú vyšší faktor rozšírenia potrebujú na odoslanie správy dlhší vysielací čas, čo má za následok vyššiu spotrebu energie oproti zariadeniam, ktoré sa nachádzajú bližšie k prístupovému bodu a používajú nižší faktor rozšírenia a môžu komunikovať na vyšších prenosových rýchlostiach. V skutočnosti je obraz poklesu signálu v prostredí omnoho komplikovanejší a závisí od konkrétneho prostredia a okolitého rušenia, ktoré sa v ňom nachádza. Dôležitým faktom ale ostáva, že na rovnakom komunikačnom kanáli je možné prijímať správy s rôznymi prenosovými rýchlosťami (rôzny SF) súčasne [68].

Ak chceme predĺžiť životnosť jednotlivých uzlov v sieti a teda znížiť celkovú spotrebu energie, je potrebné znížiť aj objem a frekvenciu prenášaných dát. To zároveň zabráni zahlteniu siete a kolíziám počas prenosu, ktoré majú negatívny efekt na spotrebu energie jednotlivých koncových zariadení v sieti. Vo výsledku to môže zvýšiť kapacitu celej siete a počet koncových uzlov, ktoré sa v nej nachádzajú.



Obrázok 11 Vplyv ADR na prenos správy [69]

2 Neurónová sieť

Neurónové siete sa v dnešnej dobe najmä vplyvom rýchleho rozvoja výpočtovej techniky využívajú čoraz častejšie nie len v experimentálnych úlohách, ale aj v praktických riešeniach rôznych problémov každodenného života [32], [33], [34]. Aplikácie úlohy typu spracovania informácií, klasifikácie vzorov [35] alebo situácií [36], [37], predikčné úlohy, optimalizačné problémy nachádzajú svoje uplatnenie v rôznych aplikáciách v oblasti priemyslu, finančníctve, monitoringu prostredia [38], [39], telekomunikáciách [40], zdravotníctve, vojenskej technike a inde. Využitie strojového učenia založeného na neurónových sieťach vo WSN sieťach je ďalším logickým krokom v snahe o efektívne využívanie dostupných hardvérových prostriedkov WSN modulov. Existuje viacero aplikácií implementovaných do WSN prostredia [41], či už sa jedná o zníženie spotreby senzorického zariadenia [42], [43], alebo je prioritou rýchlosť výpočtu [44], [45], [46]. Podrobný popis využitia neurónových sietí v prostredí WSN sa nachádza v kapitole 3.1.

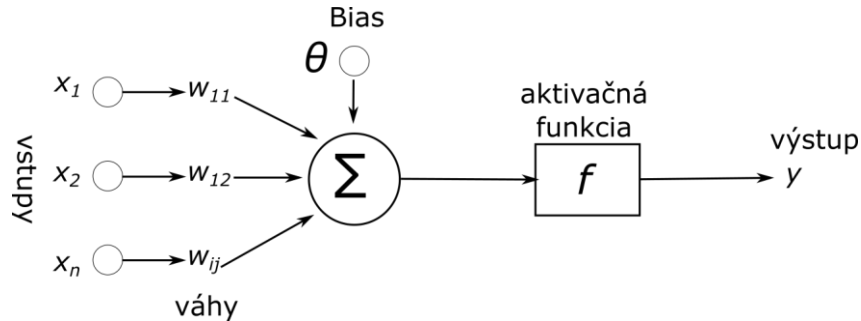
2.1 Využitie neurónových sietí

Možnosť aplikácie neurónových sietí vychádza z ich niektorých základných vlastností. Jednou z nich je skutočnosť, že neurónová sieť predstavuje univerzálny aproximátor funkcie [47], [48], [49]. Nakoľko veľké množstvo súčasných problémov je reprezentovaných ako nám neznáme funkcie, tak využitie neurónových sietí bude v najbližšej dobe ešte rozmanitejšie [50], [51]. Určitou brzdou vo vývoji neurónových sietí sú vysoké nároky na výpočtovú techniku. Tá však veľmi rýchlo napreduje s rozvojom vysokovýkonných výpočtových systémov. Vo všeobecnosti môžeme neurónové siete využiť pre nasledovné oblasti problémov [48]:

- klasifikácie do tried, klasifikácia situácií,
- problémy aproximácie funkcií,
- riešenie predikčných problémov,
- transformácia signálov,
- problémy riadenia procesov,
- asociačné problémy a simulácia pamäte.

2.2 Základné prvky neurónovej siete

Fundamentálnym prvkom a procesnou jednotkou v neurónovej sieti je neurón [52]. Štruktúra neurónu sa nachádza na obrázku č. 12.




Obrázok 12 Všeobecná štruktúra neurónu [47]

Neurón sa skladá z viacerých častí [48]:

- vstup do neurónu (dendrit) x_n , ďalej v texte označené ako in_i ,
- prah neurónu (excitácie) – reprezentovaný hodnotou θ ,
- aktivačná funkcia neurónu f ,
- výstup neurónu y , ďalej v texte označené ako o_{ij} ,
- synaptické váhy w_{ij} , ktoré sú na synaptických prepojeniach. Tieto spojenia majú svoj smer a spájajú jednotlivé neuróny do požadovanej siete.

Na základe obrázku č. 13, podľa toku signálu po synapsii rozoznávame neuróny:

- predsynaptické (zdrojové – pred synapsiou),
- postsynaptické (cieľové – po synapsii).



Obrázok 13 Typy neurónov [48]

Synaptické váhy sa označujú symbolom w_{ij} , kde i označuje postsynaptický neurón a j označuje predsynaptický neurón. Táto synapsia tým pádom vychádza z neurónu j a cieľi k neurónu i .

Vstup do neurónu je funkciou jednotlivých vstupov prichádzajúcich od predsynaptických neurónov. Vo väčšine prípadov je to súčet týchto vstupov uvažovaných

s určitými váhami. Vstup do i -teho neurónu, ktorý má N predsynaptických neurónov, môže byť vyjadrený v nasledujúcom tvare [48]:

$$in_i = \sum_{j=1}^N w_{ij} ou_j + \theta_i \quad (2.1)$$

kde w_{ij} sú synaptické váhy, ou_j sú výstupy z neurónov s ktorými je prepojený a θ_i je prah neurónu i . Rovnica 2.1 môže byť vyjadrená v tomto tvare:

$$in_i = \sum_{j=0}^N w_{ij} ou_j \quad (2.2)$$

kde $w_{i0} = \theta_i$ a zároveň $ou_0 = 1$ alebo -1 . Prah excitácie predstavuje vstup do neurónu z vonkajšieho sveta, teda nie z iných neurónov. To znamená, že v prípade, ak nie sú žiadne vstupy do daného neurónu i z ostatných neurónov $j = 1, 2, \dots, N$, potom vstup do neurónu je reprezentovaný len prahom θ_i . Takéto neuróny nazývame tiež sigma neuróny [48].

Neurónová sieť predstavuje dynamický systém, to znamená, že to je systém, ktorý je závislý na čase. Môžeme hovoriť o stave neurónu v čase t , resp. v čase $t+1$. Aktivačná funkcia neurónu je funkciou vstupu do neurónu $in_i(t)$. Z toho vyplýva, že stav neurónu i je definovaný premennou x_i v tvare:

$$x_i = f(in_i) \quad (2.3)$$

Funkcia f sa nazýva aktivačnou funkciou neurónu. Známe sú aktivačné funkcie rôznych tvarov. Uvádzame stručný prehľad tých najznámejších funkcií. Jedná sa o aktivačné funkcie, ktoré sú závislé len na vstupe [48].

- Lineárna funkcia

$$x_i = f(in_i) = in_i \quad (2.4)$$

- Funkcia signum

$$x_i = f(in_i) = \begin{cases} 1, & \text{ak } in_i \geq 0 \\ 0, & \text{ak } in_i < 0 \end{cases} \quad (2.5)$$

Neuróny s takouto aktivačnou funkciou sa nazývajú tiež McCulloch-Pittsove neuróny.

- ReLU funkcia:

$$x_i = f(in_i) = \begin{cases} in_i, & \text{ak } in_i > 0 \\ 0, & \text{ak } in_i \leq 0 \end{cases} \quad (2.6)$$

- Po častiach lineárna funkcia:

$$x_i = f(in_i) = \begin{cases} 1, & \text{ak } in_i \geq \frac{1}{2} \\ in_i, & \text{ak } in_i \in \left(\frac{-1}{2}, \frac{1}{2}\right) \\ 0, & \text{ak } in_i \leq \frac{-1}{2} \end{cases} \quad (2.7)$$

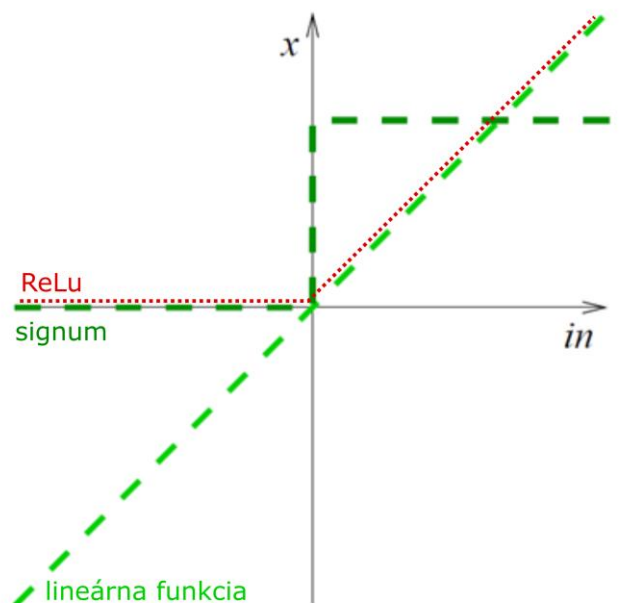
- Sigmoidálna funkcia:

$$x_i = f(in_i) = \frac{1}{1 + e^{-\alpha in_i}} \quad (2.8)$$

kde α predstavuje parameter strmosti sigmoidy.

Okrem vyššie spomenutých existuje ešte množstvo ďalších aktivačných funkcií.

Príklady niektorých aktivačných funkcií sú uvedené aj na obrázku č. 14.



Obrázok 14 Príklady aktivačnej funkcie neurónu [48]

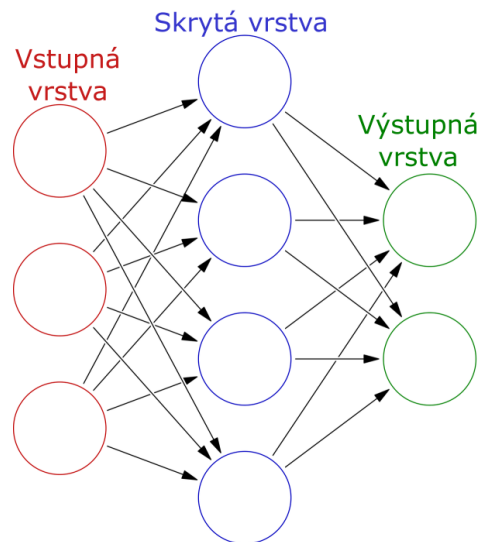
Medzi najdôležitejšie časti neurónovej siete patria jednotlivé prepojenia medzi neurónmi. Na týchto orientovaných prepojeniach sa nachádzajú aj tzv. synaptické váhy. Tie ovplyvňujú vstupy do neurónov, čo má vplyv na celú sieť. Váhy môžeme vo všeobecnosti rozdeliť na:

- excitačné – kladné,
- inhibičné – záporné.

Synaptické váhy medzi neurónmi i, j označujeme $w_{i,j}$. Práve zmena týchto váh $\Delta w_{i,j}$ predstavuje najdôležitejší moment pri učení neurónovej siete [48].

2.3 Topológia neurónovej siete

Vo všeobecnosti môžeme popísať štruktúru neurónovej siete ľubovoľným orientovaným grafom pomocou vrcholov tvoriacich neuróny, a orientovaných hrán, ktoré by reprezentovali prepojenia medzi vrcholmi. Nakoľko sa však vlastnosti takýchto sietí ťažko analyzujú, tak dôraz sa kladie na siete s pravidelnými štruktúrami. Jednou z nich je aj viacvrstvová štruktúra, ktorá sa nachádza na obrázku č. 15.



Obrázok 15 Príklad viacvrstvovej doprednej neurónovej siete


V takýchto typoch neurónových sietí sú vrstvy pomenované. Rozlišujeme nasledujúce základné vrstvy [48]:

- Vstupná vrstva, v ktorej neuróny dostávajú vstup len z okolitého sveta a výstup zvyčajne pokračuje k ďalším neurónom.
- Skrytá vrstva, v ktorej neuróny dostávajú vstup z ostatných neurónov alebo aj z prahových prepojení a ich výstupy pokračujú ďalej do neurónovej siete.
- Výstupná vrstva je podobná tej skrytej, avšak výstup z tejto vrstvy vyúsťuje do externého sveta a predstavuje výstup celej siete.

Vzhľadom spomenutú klasifikáciu vrstiev rozlišujeme aj samotné neuróny na vstupné, skryté a výstupné, ktoré patria príslušným vrstvám. Pri návrhu štruktúry neurónovej siete rozdeľujeme topológiu siete do dvoch základných skupín:

- Dopredné neurónové siete – signál sa šíri po orientovaných synaptických prepojeniach len jedným smerom a to dopredu, ako je uvedené na obrázku č. 15.

- Rekurentné neurónové siete – nie je možné priamo rozdeliť jednotlivé vrstvy na vstupné a výstupné. Niektoré neuróny predstavujú vstupné aj výstupné typy zároveň, ako je uvedené na obrázku č. 16. k jednému vstupu môže prislúchať viacero výstupov, a to v závislosti od časového kontextu. Inými slovami, o výstupe siete rozhoduje nielen momentálny vstup siete, ale aj doterajšia história predkladaných vzorov. Špeciálny prípadom sú tzv. čiastočne rekurentné neurónové siete, v ktorých je stanovená určitá požiadavka na štruktúru a na prepojenia v sieti. Príkladom sú vrstvomé čiastočne rekurentné siete, ktoré pripúšťajú šírenie signálu oboma smermi [48].



Obrázok 16 Príklad rekurentnej neurónovej siete [48]

Samotný signál v neurónovej sieti sa môže šíriť viacerými spôsobmi ako napríklad [48]:

- synchronne – všetky neuróny menia svoj stav do taktu (pomocou synchronizačných hodín),
- sekvenčne – neuróny menia svoj stav postupne pri šírení signálu,
- blok-sekvenčne – aktivujú sa len skupiny neurónov a to podľa vopred určenej stratégie,
- asynchronne – neuróny menia svoje stavy nezávisle na sebe.

2.4 Perceptrón

Perceptrón predstavuje najjednoduchší model doprednej neurónovej siete tvorenej jedným neurónom. Ten prijíma vstupné signály $\mathbf{x}=(x_1, x_2, \dots, x_{n+1})$ cez synaptické váhy,

ktoré tvoria váhový vektor $\mathbf{w} = (w_1, w_2, \dots, w_{n+1})$. Vstupný vektor \mathbf{x} sa nazýva vzor alebo obrazec. Jednotlivé zložky vstupného vektora môžu nadobúdať reálne alebo binárne hodnoty. Ako príklad môžeme uviesť obrázok písmena, ktorý je zakódovaný ako vektor (pole) hodnôt. Zložky váhového vektora sú reprezentované reálnymi číslami. Výstup z perceptrónu o môžeme definovať nasledovným vzťahom [53]:


$$o = f(\mathbf{w} \cdot \mathbf{x}) = f\left(\sum_{j=1}^{n+1} w_j x_j\right) = f\left(\sum_{j=1}^n w_j x_j - \theta\right) \quad (2.9)$$

Funkcia f sa nazýva aktivačná funkcia perceptrónu. Jej vstup je tvorený skalárnym (zložkovým) súčinom váhového a vstupného vektora $(\mathbf{w} \cdot \mathbf{x})$. V danom zápise predpokladáme, že tento model neurónu má $n+1$ vstupov. Hodnota vstupu $x_{n+1} = -1$ a váha $w_{n+1} = \theta$. Táto hodnota reprezentuje prah excitácie perceptrónu.

Nasledujúcim vzťahom môžeme definovať rovnicu nadroviny v n -rozmernom priestore :

$$\sum_{j=1}^n w_j x_j - \theta = 0 \quad (2.10)$$

Napríklad v 2-rozmernom priestore je to rovnica priamky: $w_1 x_1 + w_2 x_2 - \theta = 0$. Váhy perceptrónu sú zároveň koeficienty deliacej priamky (nadroviny), ktorá rozdeľuje priestor vzorov na dva podpriestory [53].



Obrázok 17 Logické funkcie AND, OR a XOR [47]

Perceptrón má teda schopnosť klasifikovať, t.j. zatried'ovať vzory do dvoch tried, ktoré sú lineárne oddelené deliacou hranicou vyjadrenou rovnicou 2.10. Z toho vyplýva, že dokáže riešiť len tzv. lineárne separovateľné problémy. Medzi takéto problémy patria napríklad logické funkcie AND alebo OR. Ako vidieť na obrázku č. 17, tak funkcia XOR nie je

lineárne separovateľná. Bolo dokázané, že je možné natréňovať perceptrón pomocou vzorov tak, že jeho synaptické váhy budú zodpovedať koeficientom deliacej nadroviny, ak táto existuje [47].

2.5 Dopredná viacvrstvová sieť ako univerzálny aproximátor funkcie

Umelá neurónová sieť so skrytou vrstvou funguje ako univerzálny aproximátor mnohorozmerných funkcií. Taktiež dokáže riešiť aj nelineárne problémy klasifikácie. Nech existuje dopredá NS s jedným výstupným neurónom a jednou skrytou vrstvou. Majme tréningovú množinu dimenzie I , ktorá je tvorená vstupnými vektormi $\mathbf{A}_{train} = \{\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^p, \dots, \mathbf{x}^P\}$.

$$\text{Pre } \forall \varepsilon > 0 \exists \text{ taká funkcia } G(\mathbf{x}) = f \left(\sum_{j=1}^J w_j f \left(\sum_{i=1}^I v_{ji} x_i \right) \right) \quad (2.11)$$

kde w_j je váha synapsy medzi j -tým skrytým neurónom a výstupným neurónom, v_{ji} je váha synapsy medzi i -tým vstupom a j -tým skrytým neurónom. Funkcia $f(z)$ predstavuje diferencovateľnú aktivačnú funkciu. Pre ľubovoľnú spojité funkciu $F: \mathfrak{R}^n \rightarrow (0, 1)$, ktorá je definovaná nad konečnou množinou \mathbf{A}_{train} , pričom platí [53]:

$$\sum_{p=1}^P |F(\mathbf{x}^p) - G(\mathbf{x}^p)| < \varepsilon \quad (2.12)$$

Z uvedeného vzťahu môžeme povedať, že funkcia G aproximuje funkciu F nad tréningovou množinou s presnosťou ε . Z toho vyplýva, že existuje taká dvojvrstvová neurónová sieť, ktorá aproximuje F pre \mathbf{A}_{train} . Nasledujúca rovnica vyjadruje sumu štvorcov chýb, ktorú sa snažíme učením neurónovej siete minimalizovať. Definuje účelovú funkciu, ktorá sa nazýva aj chybová funkcia a má nasledovný tvar:

$$E_p = \frac{1}{2} \sum_{k=1}^K (d_{pk} - o_{pk})^2 \quad (2.13)$$


kde $\mathbf{o} = (o_1, o_2, \dots, o_k, \dots, o_K)$ predstavuje výstupný vektor a $\mathbf{d} = (d_1, d_2, \dots, d_k, \dots, d_K)$ požadovaný výstup siete. Počet výstupných neurónov je $k=1, \dots, K$. Cieľom je, aby sa po naučení NS skutočný výstup siete rovnal požadovanému výstupu, resp. aby sa mu priblížil čo najviac, a to pre všetky vzory $p=1, 2, \dots, P$ z \mathbf{A}_{train} , kde p je index vzoru. E_p reprezentuje sumu štvorcov chýb na všetkých výstupných neurónoch. Učenie spočíva v modifikovaní váh tak, aby sa minimalizovala chyba E_p [53].

Trénovaním siete upravujeme váhy, ktoré predstavujú zároveň koeficienty funkcie G , ktorú neurónová sieť aproximuje pomocou daných bodov trénovacej množiny. Táto skutočnosť je zobrazená na obrázku č. 18. Cieľom je extrapolácia funkčných hodnôt mimo A_{train} čiže predikcia funkčných hodnôt pre vstupné vektory, ktoré sieť nikdy nevidela. Táto schopnosť neurónovej siete sa nazýva aj generalizácia alebo zovšeobecňovanie.

Aby sme túto schopnosť siete mohli otestovať, je potrebné si rozdeliť dáta ktoré máme k dispozícii na trénovaciu (A_{train}) a testovaciu (A_{test}) množinu. Toto rozdelenie je zobrazené na obrázku č. 18 ako plné a prázdne krúžky. Testovacia množina sa nazýva aj validačná množina. Pomocou A_{train} sú modifikované váhy a pomocou A_{test} zisťujeme chybu zovšeobecňovania. Pracujeme s kumulovanou chybou E , ktorá je definovaná nasledovne [53]:

$$E = \sum_{p=1}^P E_p \quad (2.14)$$

Dôležité je správne rozdelenie dát na trénovaciu a testovaciu množinu. Trénovacia množina (A_{train}) by mala rovnomerne pokrývať daný interval. Zistilo sa, že v priebehu trénovania kumulovaná chyba E_{train} stále klesá, zatiaľ čo E_{test} začne od určitého momentu rásť. Táto skutočnosť je zobrazená na obrázku č. 18. Tento jav sa nazýva preučenie neurónovej siete alebo pretrénovanie či premodelovanie dát.



Obrázok 18 Aproximácia funkcie pomocou NS a vývoj chyby počas trénovania [53]

Ak nepoznáme dopredu ε môžeme na zastavenie učenia využiť metódu nazvanú skoré alebo tiež optimálne zastavenie. Táto metóda pozostáva z 3 krokov [53]:

1. Rozdelenie dát na dve neprekrývajúce sa podmnožiny A_{train} a A_{test} . Napríklad náhodne vyberieme 80% vzorov do trénovacej množiny a 20% do testovacej.

2. Po každom tréningovom cykle je vypočítaná kumulovaná chyba zvlášť na tréningových a zvlášť na testovacích dátach.
3. Učenie sa zastaví práve vtedy, keď E_{test} začne rásť.

Pre každý typ úlohy možno všeobecne povedať, že viacvrstvomá dopredná neurónová sieť sa učí asociovať vstupné vektory \mathbf{x}^p s výstupnými vektormi \mathbf{d}^p . Skryté neuróny pritom vykonávajú extrakciu príznakov. Nevýhoda neurónových sietí ako detektorov príznakov je, že zvyčajne vieme len veľmi ťažko, na základe aktivít skrytých neurónov, určiť aké príznaky sieť vlastne extrahovala [53].

2.6 Učenie neurónovej siete

Prístupy k učeniu neurónových sietí môžeme rozdeliť do dvoch veľkých skupín [52], [54], [55]:

1. **Kontrolované učenie** – učenie s učiteľom, ktoré môžeme ďalej rozdeliť:
 - Štruktúrne učenie – rozoznávame dve skupiny metód:
 - autoasociačné – neurónová sieť sa musí adaptovať tak, aby to čo je na vstupe NS bolo zároveň aj na výstupe. Takéto siete majú význam napr. pri simuláciách pamäte.
 - heteroasociačné – neurónová sieť sa učí rozpoznávať vstupy a zatrieďovať ich na základe odpovede učiteľa v priebehu učenia. To znamená, že NS sa učí k príslušnému vstupu \mathbf{x} priradiť výstup \mathbf{o} .
 - Temporálne učenie – predstavuje v podstate heteroasociatívne učenie, ale na vstup musí prísť za čas $t > 0$ sekvencia vstupov a až potom sa tejto sekvencii ako celku priradí jeden výstup. Ako príklad môžeme uviesť sekvenciu ťahov v šachu v čase, ktorá vedie k výhre. Ďalší príklad je, že len určitý časový vývoj ekonomických a iných parametrov môže znamenať vzrast cien akcií na burze a podobne.
2. **Nekontrolované učenie** – učenie bez učiteľa.

Zmeny synaptických váh sú pri kontrolovanom učení ovplyvnené prítomnosťou učiteľa v celom procese učenia. To znamená, že neurónovej sieti musíme poskytnúť v procese učenia vstup a k nemu prislúchajúci výstup. V prípade kontrolovaného učenia je možné prístupy k učeniu rozdeliť do 3 skupín [48]:

- učenie na základe opravy chyby – error correction learning,
- stochastické učenie – stochastic learning,
- učenie na základe hodnotenia činnosti – reinforcement learning.

Existujú aj ďalšie metódy kontrolovaného učenia, ktoré predstavujú kombinovaný prístup z vyššie uvedených metód. Nakoľko v práci predpokladáme najmä využitie metód kontrolovaného učenia, rozhodli sme sa ďalej popísať len princípy týchto prístupov.

2.6.1 Učenie na základe opravy chyby

Pri učení na základe korekcie chyby môžeme zmenu synaptických váh reprezentovať ako funkciu premennej e_i , kde e_i predstavuje rozdiel medzi očakávaným stavom neurónu i (ev_i) a vypočítaným stavom tohto neurónu (x_i) v procese učenia [48]:

$$e_i = ev_i - x_i \quad (2.15)$$

Potom môžeme vyjadriť všeobecný vzorec pre výpočet zmeny váh pre spojenie medzi výstupným neurónom i a do neho vstupujúcim neurónom j v nasledujúcom tvare:

$$\Delta w_{ij} = \eta x_j e_i \quad (2.16)$$

kde η predstavuje parameter učenia, zvyčajne malé číslo z intervalu $(0,1)$ a x_j je stav neurónu j . V prípade viacvrstvovej siete sa pri výpočte jednotlivých zmien váh použije rekurentný vzorec pre zmenu váh, ktorý sa odvíja od výstupu neurónovej siete a smeruje späť do siete. Tento spôsob sa nazýva algoritmus spätného šírenia chyby a je často používaný [48].

2.6.2 Stochastické učenie

Pri stochastickom učení sú zmeny synaptických váh založené na stochastických prístupoch. V prvom kroku sa navrhne stochastická zmena váh a vypočíta sa energia NS. Ak zmena priniesla zníženie energie, tak návrh zmeny sa prijme. Ak zmena nepriniesla spomínaný efekt, tak sa návrh zamietne. Ako príklad môžeme uviesť Boltzmanov stroj a jeho modifikácie [48].

2.6.3 Učenie na základe hodnotenia činnosti

Učenie na základe hodnotenia činnosti má podobný charakter ako učenie podľa korekcie chyby. Rozdiel spočíva v tom, že sa zhodnocuje stav výstupu celej výstupnej vrstvy pomocou určitej skalárnej veličiny. Všeobecný tvar rovnice učenia môžeme potom vyjadriť [48]:

$$\Delta w_{ij} = \eta (r - \theta_i) e_{ij} \quad (2.17)$$

kde r je skalárna hodnota úspešnosti celej neurónovej siete odvodená z výstupnej vrstvy, θ_i je prahový koeficient úpravy neurónu i a e_{ij} je koeficient rozhodnutia. Tento koeficient predstavuje zmenu pravdepodobnosti minimálnej chyby podľa synaptickej váhy, ktorý sa vo všeobecnosti vypočíta nasledovne:

$$e_{ij} = \frac{\partial \ln g_i}{\partial w_{ij}} \quad (2.18)$$

kde g_i je pravdepodobnosť, že očakávaný výstup sa bude rovnať vypočítanému výstupu ev_{ij} , teda minimálnej chybe:

$$g_i = P(x_i = ev_i | \mathbf{W}_i, \mathbf{A}) \quad (2.19)$$

kde ev_i je očakávaná hodnota výstupného neurónu i , x_i je vypočítaná hodnota neurónu, \mathbf{W}_i je vektor synaptických váh, ktoré vstupujú do neurónu i a \mathbf{A} je vektor hodnôt aktivačných stavov neurónov, ktorých váhy vstupujú do neurónu i [48].

3 Využitie neurónovej siete v prostredí WSN

Táto práca je zameraná na odhad nameraných parametrov vo WSN sieti pomocou neurónovej siete. To znamená, že na základe hodnôt nameraných v celej WSN sieti chceme rekonštruovať hodnotu v bode, kde nebola v danom čase meraná. Aby bolo možné túto úlohu riešiť, je nutné, aby existovala priestorovo-časová závislosť medzi hodnotami meranými v jednotlivých bodoch siete. Úlohou neurónovej siete bude čo najpresnejšie odhaliť túto priestorovo-časovú závislosť. V tejto kapitole bude bližšie popísaná problematika predikcie hodnôt.

Neurónové siete sú často používané na predpovedanie časových radov. Aj keď existujú aj iné techniky umelej inteligencie, ktoré je možné použiť na predikciu hodnôt (napr. SVM – Support Vector Machines [70]), v súčasnosti sú najviac používané práve neurónové siete.

Predikovanie budúcich hodnôt časových radov je jednou z najčastejších oblastí použitia neurónových sietí. Používa sa v oblasti finančníctva (odhad vývoja kurzov na burze [71], [72]), obchodu (predpovedanie správania zákazníkov [73]), dopravy (odhad dopravných tokov [74]), životného prostredia (odhad prietoku vody v rieke [75]), zásobovania (predikovanie spotreby energie [76]), techniky (predpovedanie poruchy zariadenia [77]) a mnohých ďalších.

Nasledujúce časti práce sú venované aplikáciám neurónových sietí v prostredí WSN a teoretickým východiskám, ktoré boli využité pri realizácii experimentov.

3.1 Aplikácie neurónových sietí v prostredí WSN

Bezdrôtové senzorické siete sú charakteristické svojou priestorovou rozľahlosťou. Prostredie, v ktorom je WSN implementovaná, má často dynamický charakter s meniacimi sa podmienkami. Návrh a efektívna prevádzka takýchto sietí je komplexná úloha a vyžaduje optimalizáciu rôznych parametrov a voľbu správnych rozhodnutí. Pri riešení tejto zložitej úlohy sa v súčasnosti stále viac využívajú prostriedky umelej inteligencie. Hoci je možné využiť rôzne techniky umelej inteligencie (napr. Support Vector Machines – SVM, Decision tree learning, genetické algoritmy a iné), vzhľadom na svoju pozoruhodnú univerzálnosť sa do popredia dostávajú hlavne neurónové siete. Zvlášť vhodné je použiť neurónové siete na úlohy spojené s klasifikáciou, rozpoznávaním vzorov

a optimalizáciou. V [78] je uvedený prehľad často používaných modelov neurónových sietí aj s ich aplikáciami vo WSN. Autori tiež identifikovali viaceré problémy a výzvy pri implementovaní neurónových sietí do WSN.

3.1.1 Lokalizácia

V mnohých aplikáciách (starostlivosť o zdravie, monitorovanie prostredia, poľnohospodárstvo a pod.) je požadovaná čo najpresnejšia lokalizácia a prípadne aj sledovanie uzla WSN siete, či už v interiéri alebo exteriéri. Neurónové siete môžu zvýšiť presnosť odhadu pozície koncového zariadenia alebo umožňujú dosiahnuť dobré výsledky aj v nízko nákladových riešeniach [79], [80].

Zaujímavá aplikácia NS na lokalizáciu pacientov v interiéri je uvedená v [81]. Lokalizácia je založená na vytvorení mapy intenzity signálu (RSS) pre prázdne prostredie a vyhodnocovaní zmien RSS v prítomnosti osoby. V tomto prípade tak nie je potrebné, aby monitorovaná osoba musela nosiť akékoľvek zariadenie.

3.1.2 Úspora energie

Jednou z najdôležitejších vlastností dobrej WSN siete je energetická efektívnosť, hlavne pri napájaní uzlov siete batériami. Veľkosť koncového zariadenia je často obmedzená a preto nie je možné používať veľkokapacitné batérie. Na druhej strane, výmena batérií je často komplikovaná, niekedy až nemožná a prípadne aj ekonomicky neefektívna. Z hľadiska funkčnosti celej bezdrôtovej siete je preto veľmi dôležité efektívne hospodárenie s dostupnou energiou. Najviac energeticky náročným procesom je zvyčajne komunikácia v rámci siete. Energiu je možné šetriť predovšetkým znížením objemu prenášaných dát. To je možné realizovať viacerými spôsobmi – kompresiou (resp. znížením dimenzionality) dát priamo v uzle [82], znížením frekvencie vzorkovania a posielania dát, agregovaním dát a elimináciou redundantných dát [83]. Využiť je možné aj fúziu dát [46].

Z hľadiska funkčnosti celej siete je tiež dôležité rovnomerné zaťaženie jednotlivých koncových zariadení pri úlohách spojených s komunikáciou. V tejto oblasti sa skúmajú hlavne vhodné metódy klastrovania uzlov a adaptívneho smerovania dát. V [84] je uvedený prehľad hlavných aplikácií neurónových sietí na šetrenie energie v prostredí WSN.

3.1.3 Spoľahlivosť, bezpečnosť a kvalita WSN

S neustále narastajúcim počtom aplikácií WSN a IoT sietí sa zvyšuje aj riziko ich zneužitia. Prvé aplikácie WSN sietí prenášali zvyčajne dáta nezabezpečeným spôsobom. To je už v súčasnosti považované za bezpečnostné riziko a citlivé dáta sú pred ich poslaním šifrované. V [85] je popísaný spôsob šifrovania dát pomocou chaotickej neurónovej siete. Prehľad možností zabezpečenia IoT a WSN sietí pomocou techník strojového učenia je uvedený v [86].

WSN sieť môže obsahovať veľké množstvo zariadení. S počtom uzlov rastie aj pravdepodobnosť nesprávnej funkcie niektorého z nich. Viaceré aplikácie neurónových sietí sú zamerané práve na detekciu anomálií vo WSN sieťach. Pod anomáliou sa rozumejú dáta, ktoré nezodpovedajú vzorom, aké vykazuje väčšina siete (prípadne samotný uzol v minulosti). Vznik anomálie môže znamenať nielen nesprávnu funkčnosť uzla, ale aj náhlu zmenu prostredia či dokonca bezpečnostný útok. V [87] je na detekciu anomálií použitá neurónová sieť s funkciou autoenkodéra, pričom využíva učenie bez učiteľa. V [88] je neurónová sieť použitá na detekciu a izoláciu chybného uzla. Bezdrôtová sieť modelovaná pomocou rekurentnej neurónovej siete a slúžiaca na detekciu chybných uzlov je popísaná v [89].

Bezpečnosť prenosu dát ako aj spoľahlivosť siete sú ukazovateľmi kvality siete. Možnosti zvýšenia kvality služieb (QoS) v sieťach WSN pomocou neurónových sietí sú popísané v prehľadovom článku [90].

3.1.4 Ďalšie aplikácie

Častou oblasťou aplikácií WSN sietí je monitorovanie životného prostredia. Rast počtu aplikácií súvisí aj so zmenou klímy. V niektorých oblastiach sa zmena klímy prejavuje výkyvmi v množstve zrážok, čo môže viesť k nečakaným záplavám. V [91] a [92] je popísané použitie neurónových sietí a strojového učenia na predpovedanie záplav.

Zaujímavá aplikácia je popísaná v [93]. Autori v nej popisujú automatickú klasifikáciu kvákania žiab pomocou konvolučnej neurónovej siete. Zmeny v správaní žiab slúžia biológom ako indikácia "ekologického stresu".

Neurónové siete je možné využiť aj na predpovedanie poruchy zariadenia. Včasným identifikovaním problémového miesta v zariadení je možné minimalizovať negatívne ekonomické dopady a prípadne aj predísť úrazom. V [94] je WSN v spojení s konvolučnou NS použitá na detekciu poškodenia štruktúry monitorovaného objektu.

Existuje viacero aplikácií s využitím neurónových sietí, napr. detekcia poruchy vo WSN s využitím NS [95], alebo FPGA implementácia NS pre detekciu požiaru v lese [96].

3.2 Teoretické východiská experimentov

Náplňou tejto práce je odhad nemeraných parametrov monitorovaného systému pomocou neurónovej siete. Medzi hlavné dôvody, prečo odhadovať parametre monitorovaného systému namiesto ich priameho merania, patrí:

- Zníženie energetickej náročnosti koncového zariadenia WSN. Vo väčšine prípadov je pri zbere dát pomocou WSN siete energeticky najnáročnejšou časťou bezdrôtový prenos dát do centrálného prvku siete, prípadne cloudu. Ak sa podarí pomocou umelej inteligencie dosiahnuť zníženie frekvencie vzorkovania daného parametra pri zachovaní požadovanej kvality (presnosti), automaticky dochádza k úspore energie. Ešte výraznejšiu úsporu je možné dosiahnuť v prípade energeticky náročných snímačov, ako sú napr. snímače plynov (NOX, CO₂, plyn a pod.). Viaceré typy snímačov vyžadujú dlhodobé zohrievanie snímacích elementov na vyššiu teplotu a to predstavuje veľkú záťaž na napájací podsystem uzla siete. Rovnako ako v predchádzajúcom prípade sa prípadné predĺženie periódy vzorkovania priaznivo odrazí na životnosti monitorovacieho systému.
- Umiestnenie snímača v konkrétnom mieste nemusí byť z dlhodobého hľadiska možné alebo je ekonomicky neúnosné. Napríklad pravidelná výmena batérií v danom zariadení je príliš nebezpečná/drahá. Teda je možné krátkodobé meranie v danom bode, ale z dlhodobého hľadiska je výhodnejšie hodnotu požadovaného parametra len odhadovať. Na odhad nemeranej hodnoty na základe hodnôt okolitých snímačov môže byť použitá neurónová sieť.

V tejto práci sme sa rozhodli venovať sa podrobnejšiemu rozpracovaniu prvej možnosti, teda šetreniu energie a zvýšeniu životnosti celej WSN siete na základe zníženia vzorkovacej frekvencie, s akou sú snímané parametre prostredia.

Vo viacerých aplikáciách (poľnohospodárstvo, ochrana životného prostredia, monitorovanie pohybu osôb/vozidiel atď.) je WSN sieť implementovaná na geograficky veľkej ploche. Z dôvodu vyššej robustnosti siete, ako aj kvôli obmedzenému dosahu komunikačných modulov, bývajú uzly siete rozložené v danom priestore relatívne husto.

To znamená, že monitorované parametre prostredia môžu byť vzorkované častejšie, než je nutné na základe vzorkovacieho teorému. Je potrebné si uvedomiť, že podobné pravidlá, aké platia pre vzorkovanie signálov v čase, platia aj pre vzorkovanie v priestore. Tak, ako je napríklad pri riadení vykurovania miestnosti zbytočné merať teplotu každú sekundu, je tiež zbytočné merať ju na desiatich rôznych miestach v tej istej miestnosti.

3.2.1 Implementácia neurónových sietí do WSN

Implementácia neurónových sietí do prostredia WSN je možná tromi základnými spôsobmi:

- Bezdrôtová senzorická sieť slúži len na zber dát a neurónová sieť je použitá v centrálnom prvku, resp. v cloude. V tomto prípade sa jedná o rozšírenie klasickej WSN. Neurónová sieť je použitá na analýzu a vyhodnotenie dát, pričom vlastnosti WSN ostávajú nezmenené. Použitie NS môže nepriamo ovplyvniť štruktúru WSN napríklad vtedy, ak neurónovej sieti stačí na dosiahnutie požadovanej kvality menšie množstvo dát z WSN – či už znížením frekvencie vzorkovania alebo zmenšením počtu koncových zariadení.
- Neurónová sieť je implementovaná priamo v uzle WSN siete. Tento spôsob implementácie neurónovej siete je v súlade s princípmi spracovania dát „na hrane“ (Edge Computing). Údaje získavané zariadením z okolia sú spracovávané priamo na mieste vzniku a do centra sú prenášané len relevantné výsledky. To umožňuje podstatne znížiť objem prenášaných dát a tým dosiahnuť úsporu energie. Na druhej strane, spracovanie údajov priamo v uzle predstavuje zvýšenú spotrebu energie. Okrem toho, WSN modul musí mať dostatočné prostriedky na implementáciu neurónovej siete, čo môže ovplyvniť náklady na realizáciu celej WSN siete. Tvorca siete teda musí robiť kompromisy a vhodne nastaviť pomer medzi úrovňou spracovania dát v uzle a množstvom prenášaných dát.
- Neurónová sieť je zabudovaná do bezdrôtovej senzorickej siete – každý uzol predstavuje jeden alebo viac neurónov. Tento spôsob spojenia NS a WSN je najmenej používaný, pretože kladie zvýšené požiadavky na komunikáciu medzi uzlami v sieti (neurónmi) a nie je vhodný pri napájaní batériami (resp. výraznejšie prispieva ku skráteniu životnosti siete).

Samozrejme sú možné aj kombinácie uvedených základných spôsobov. Napríklad v [87] je NS použitá v každom uzle na detekciu anomálií. Okrem toho, koncové zariadenie

posiela v pravidelných intervaloch dáta (vstupy a výstupy NS) do centra, kde sa realizuje tréning neurónovej siete na základe dát zo všetkých uzlov. V prípade potreby sú aktualizované parametre NS distribuované do jednotlivých koncových zariadení. Neurónová sieť je teda implementovaná priamo v uzloch WSN a zároveň aj v cloude.

3.2.2 Časovo-priestorová optimalizácia vzorkovania parametrov systému

Hlavná myšlienka spočíva vo využití predpokladaného „nadvzorkovania“ monitorovaného parametra tak v čase ako aj v priestore. Naším cieľom je odskúšať rôzne prístupy k zníženiu frekvencie vzorkovania v čase aj v priestore tak, aby bola zachovaná požadovaná presnosť snímania daného parametra prostredia, pričom na odhad nemeraných hodnôt bude použitá neurónová sieť.

Podobne, ako bolo uvedené v predchádzajúcej podkapitole, aj teraz máme k dispozícii dve hlavné možnosti využitia neurónovej siete:

- Prvky siete sú rozdelené do skupín. V jednom čase sníma parametre prostredia len jedna skupina prvkov a ostatné prvky „spia“. Neurónová sieť je použitá v centrálnom prvku siete (prípadne v cloude) na výpočet nemeraných hodnôt. V tomto prípade sa teda jedná o deterministický spôsob rozdelenia prvkov na tie, ktoré snímajú a tie, ktoré spia. Spôsobov rozdelenia prvkov do skupín je viacero, pričom v najjednoduchšom prípade to budú dve rovnako veľké skupiny. Môžeme mať ale aj niekoľko približne rovnako veľkých skupín, pričom v každom kroku meria (alebo spí) len jedna z nich. Všetko závisí od vlastností snímaných parametrov v konkrétnom prípade a od úrovne „nadvzorkovania“. Úspora energie je úmerná pomeru počtu prvkov v spiacej a meracej skupine.
- Prenos dát na základe odchýlky od odhadu. V tomto prípade je neurónová sieť implementovaná v každom uzle a slúži na predikciu nasledujúcej hodnoty. Dané zariadenie súčasne aj sníma danú hodnotu. Ak je rozdiel medzi odhadom a skutočnosťou väčší než stanovená prahová hodnota, modul pošle namerané dáta do centra. Údaje z tých uzlov, ktoré nič nevysielajú, sú v centre dopočítané rovnakou neurónovou sieťou ako je použitá v danom koncovom zariadení (každý modul má vlastnú neurónovú sieť). Počet prvkov, ktoré v danom okamihu snímajú monitorovanú veličinu, má stochastický charakter. Miera úspory energie závisí od kvality predikcie v jednotlivých prvkoch siete.

Keďže v praxi zvyčajne nepoznáme presnú mieru „nadvzorkovania“ a teda nemôžeme analyticky vyjadriť závislosť chyby snímania na počte vynechaných meraní/prvkov, je potrebné overiť funkčnosť navrhnutej metódy pomocou simulácie a experimentov.

3.2.3 Rastúce a posuvné okno

Pri predpovedaní budúcich hodnôt radu sa stretávame s problémom správnej veľkosti okna. Pod pojmom „okno“ sa myslí počet minulých hodnôt, ktoré sú použité na predikciu. Inými slovami, ako ďaleko do minulosti neurónová sieť „vidí“. V podstate existujú len dve možnosti – buď berieme do úvahy všetky doteraz namerané údaje (rastúce okno) alebo počítame s pevným počtom minulých hodnôt (posuvné okno).

Pri použití rastúceho okna na tréning neurónovej siete používame všetky dostupné údaje. Na prvý pohľad sa zdá, že tento spôsob bude určite najlepší, pretože nezahadzujeme žiadnu informáciu. Záleží to ale aj od vlastností monitorovaného systému/procesu. Ak sú parametre systému stabilné, teda sa s časom výraznejšie nemenia, bude tento spôsob dávať najlepšie výsledky. Neurónová sieť sa naučí modelovať daný systém. Ak sa ale parametre systému menia, staré namerané hodnoty môžu byť kontraproduktívne – zodpovedajú systému, ktorý už nie je aktuálny. Napríklad pri odhade teploty v nejakom mieste zrejme nebudú hrať veľkú úlohu údaje 100 rokov staré, keďže v posledných desaťročiach sme svedkami klimatickej zmeny. Z teórie neurónových sietí síce vieme, že neurónová sieť dokáže aproximovať ľubovoľnú funkciu, a teda si určite dokáže poradiť aj so zmenami parametrov systému, ale len za cenu zvýšenej zložitosti siete. Okrem toho, bez ohľadu na stabilitu parametrov systému, zložitosť siete sa stále zvyšuje vplyvom rastúceho okna. V prípade, že je k dispozícii obmedzený výkon neurónovej siete, nie je vhodné použiť rastúce okno.

Pri použití posuvného okna je na tréning neurónovej siete ako aj na predikciu hodnôt použitý pevný počet minulých hodnôt. Zložitosť siete sa teda časom nemení. Čo sa týka dĺžky okna, platí to isté, čo pre rastúce okno. V prípade nestacionárneho systému, ak je dĺžka okna príliš veľká, staré hodnoty skôr škodia (riziko chybného modelu). Na druhej strane príliš krátke okno zvyšuje pravdepodobnosť, že odhad parametrov systému bude príliš ovplyvnený aktuálnymi náhodnými fluktuáciami v nameraných hodnotách (riziko chybných parametrov). Pevná dĺžka okna má tiež výhodu v tom, že jednotlivé výstupy modelu sú porovnateľné. Ak sa napríklad postupom času znižuje chyba predikcie, dá sa to interpretovať ako znižovanie nestálosti (nestability) daného procesu. V prípade

rastúceho okna by bolo ťažšie odlíšiť mieru vplyvu dĺžky okna na zlepšenie odhadu od eventuálneho zlepšenia stability monitorovaného procesu.

Správna voľba veľkosti okna je veľmi dôležitá, najmä ak sme obmedzení dostupným výpočtovým výkonom a teda veľkosťou neurónovej siete, ktorú môžeme implementovať. To je prípad aj WSN sietí, kedy je k dispozícii spravidla len veľmi obmedzený výpočtový výkon.

Žiaľ, na voľbu veľkosti okna neexistujú univerzálne pravidlá. Najčastejšie sa používajú heuristiky [97]. Napríklad je možné pre rôzne veľkosti okna vypočítať odhad parametrov modelu a potom vyhodnotiť, či sú zmeny parametrov výrazné alebo nie (Chow test, Tsay test). Veľkosť okna zvolíme čo najväčšie (s ohľadom na dostupný výkon), pričom požadujeme, aby boli parametre modelu stabilné.

3.2.4 Frekvencia vzorkovania

V teórii spracovania číslicových signálov je dobre známy vzťah (Shannon-Nyquistov vzorkovací teorém [98]), ktorý definuje minimálnu potrebnú vzorkovaciu frekvenciu pre frekvenčne obmedzené signály. Vzorkovanie signálu vyššou frekvenciou neprináša žiadne nové informácie. Aj pri aplikovaní neurónovej siete na hodnoty snímané pomocou WSN je potrebné zvoliť správnu frekvenciu vzorkovania. Príliš časté vzorkovanie je neefektívne, pretože zbytočne zvyšuje zložitosť neurónovej siete. Na druhej strane podvzorkovanie procesu znemožňuje neurónovej sieti odhaliť skryté závislosti a vytvoriť dostatočne presný model systému. Keďže zvyčajne nepoznáme presne dynamiku monitorovaného procesu a nemôžeme použiť explicitný vzťah na voľbu frekvencie vzorkovania, je potrebné použiť heuristický prístup. V [99] je pre rôzne hodnoty frekvencie vzorkovania vypočítaná špeciálna hodnota (tzv. „mutual information“), pričom sa hľadá jej prvé minimum. „Mutual information“ predstavuje ekvivalent korelačnej funkcie pre nelineárne procesy. Minimum funkcie predstavuje frekvenciu, pri ktorej sú snímané hodnoty minimálne korelované a teda neobsahujú žiadnu zbytočnú informáciu.

Je zrejmé, že veľkosť okna a frekvencia vzorkovania sa navzájom ovplyvňujú, najmä ak sme obmedzení maximálnym počtom hodnôt, ktoré môžu vstupovať do neurónovej siete. Voľba obidvoch parametrov je preto často vecou kompromisu a hľadania najlepšej kombinácie.

4 Simulačné experimenty

Hlavným cieľom simulačných experimentov je overiť možnosti šetrenia energie vo WSN sieťach prostredníctvom vynechávania meraní a ich dopočítania pomocou neurónovej siete. Keďže neexistujú univerzálne pravidlá na voľbu vhodnej štruktúry a veľkosti neurónovej siete na riešenie problémov predikcie hodnôt, je potrebné experimentálne zistiť, aký vplyv na kvalitu predikcie má typ neurónovej siete a jej veľkosť.

Rozhodli sme sa otestovať dva typy neurónových sietí – plne prepojenú doprednú neurónovú sieť (označovanú ako MLP – Multilayer Perceptron) a rekurentnú neurónovú sieť typu LSTM (Long short-term memory), ktorá by mala byť vhodná na predikcie časových radov. Všetky simulačné experimenty boli realizované pomocou TensorFlow a Keras frameworku v prostredí Google Colab.

4.1 Použité datasety

Základným predpokladom vierohodnej simulácie sú kvalitné vstupné dáta - dataset. V ideálnom prípade sa jedná o reálne snímané dáta. V našom prípade potrebujeme dáta z niekoľkých desiatok snímačov s relatívne krátkou periódou vzorkovania, pričom snímanie by malo prebiehať čo najdlhší čas. Na internete je dostupných veľa rôznych datasetov, avšak takmer žiadny nevyhovoval našim požiadavkám. Jediný dataset s reálnymi dátami, ktorý približne vyhovuje našim požiadavkám, obsahuje hodinové záznamy teploty z 23 staníc umiestnených na Kilimandžare [100]. Teploty boli snímané počas obdobia troch rokov, od augusta 2012 do septembra 2015. Dataset obsahuje 25 meraných teplôt, pretože v dvoch staniaciach boli teploty merané na dvoch miestach. Po bližšej analýze datasetu sme zistili, že na viacerých miestach sú chýbajúce údaje. Po odstránení nekompletných záznamov sme získali 12875 meraní s 24 teplotami. Pri hodinovej perióde vzorkovania to predstavuje 536 dní záznamov. Tento dataset síce vyhovuje našim požiadavkám, ale pochádza zo značne extrémneho prostredia. Je otázne, nakoľko by sa dali výsledky zovšeobecniť na bežné klimatické podmienky.

Podarilo sa nám nájsť aj druhý dataset, ktorý obsahuje údaje o teplote v celej Veľkej Británii - UKCP18 [101]. V tomto prípade sa ale nejedná o reálne dáta ale o simuláciu teplôt pre tri obdobia: 1981-2000, 2021-2040 a 2061-2080. Perióda vzorkovania je 1 hodina a priestorové rozlíšenie je 5 km. Rozhodli sme sa pre simulačné

experimenty využiť dáta z obdobia 1981-2000, keďže predpokladáme, že najpresnejšie zodpovedajú reálnym teplotám. K dispozícii tak máme dataset s 172800 záznamami. Z celého datasetu, ktorý pokrýva plochu celej Veľkej Británie, sme vybrali územie o rozmeroch 50 x 50 km v centrálnej časti Anglicka. Táto plocha predstavuje pri priestorovom rozlíšení 5 km maticu 11 x 11 hodnôt. V simulačných experimentoch, pokiaľ nebude uvedené ináč, platia nasledovné nastavenia:

- dataset UKCP18, 20 rokov záznamov,
- rozdelenie datasetu na tréningovú a testovaciu množinu v pomere 80:20,
- aktivačná funkcia typu „relu“,
- optimalizačný model „adam“,
- optimalizácia podľa strednej štvorcovej odchýlky,
- počet epoch: 100,
- veľkosť dávky: 256.

Všetky simulácie boli realizované 5 krát a výsledná chyba bola vypočítaná ako priemer chýb v jednotlivých simuláciách.

4.2 Vplyv veľkosti neurónovej siete

V prvom kroku sme sa zamerali na zistenie vplyvu veľkosti neurónovej siete typu MLP na presnosť predikcie. Ako vzorový príklad pre predikciu sme vybrali najhorší možný scenár, kedy odhadujeme teplotu v strede vybraného územia na základe teplôt v ôsmich bodoch na hraniciach územia (v rohoch a v strede strán štvorca), teda v najvzdialenejších bodoch. V tabuľke č. 2 je zobrazená priemerná a minimálna hodnota strednej kvadratickej odchýlky (MSE) pre rôzny počet skrytých vrstiev a rôzny počet neurónov v každej vrstve.

Tabuľka 2 MSE (priemer a minimum) pre rôznu veľkosť neurónovej siete

Počet neurónov vo vrstve	Počet skrytých vrstiev				
	1	2	3	4	5
4	0,133 (0,129)	0,134 (0,127)	0,123 (0,121)	0,131 (0,125)	0,136 (0,125)
8	0,126 (0,120)	0,117 (0,115)	0,119 (0,115)	0,118 (0,114)	0,119 (0,116)
16	0,120 (0,117)	0,115 (0,111)	0,112 (0,110)	0,112 (0,110)	0,116 (0,111)
24	0,115 (0,113)	0,112 (0,110)	0,112 (0,109)	0,112 (0,109)	0,114 (0,111)

Výsledky simulácií ukázali, že väčší vplyv na presnosť odhadu má počet neurónov v jednej vrstve, než počet skrytých vrstiev. Pridávanie skrytých vrstiev môže mať dokonca aj nepriaznivý vplyv na výsledky. Je to zrejmé z porovnania výsledkov pre 4 a 5 skrytých vrstiev. Zväčšenie počtu skrytých vrstiev viedlo k zhoršeniu odhadov. Môže to byť spôsobené tým, že na naučenie hlbších sietí je potrebná rozsiahlejšia množina dát, než akú máme k dispozícii.


Na základe týchto výsledkov budeme v ďalších experimentoch používať predovšetkým siete s tromi skrytými vrstvami a počtom neurónov minimálne 8.

4.3 Vplyv typu vstupných dát

Okrem veľkosti neurónovej siete a veľkosti tréningového datasetu má vplyv na presnosť predikcie aj typ vstupných dát. Napríklad, či sú k dispozícii len aktuálne dáta alebo aj minulé. Uskutočnili sme simulácie pre odhad teploty v jednom mieste na základe teplôt v desiatich, náhodne vybraných bodoch, pričom sme menili typ vstupných dát:

1. Len súčasné hodnoty.
2. Súčasné a minulé hodnoty vo všetkých bodoch.
3. Súčasné hodnoty a jedna minulé v odhadovanom bode.
4. Súčasné hodnoty a 5 minulých v odhadovanom bode.

Aby malo porovnanie väčšiu vypovedaciu hodnotu, výber bodov bol vo všetkých prípadoch rovnaký. Výber bodov je zobrazený na obrázku č. 19, kde 'o' označuje miesta, v ktorých sú merané hodnoty a '+' označuje miesto odhadu.



Obrázok 19 Náhodný výber bodov na testovanie

Na rozdiel od predošlých simulácií sme odskúšali aj neurónové siete s rôznym počtom neurónov v skrytých vrstvách. Dosiahnuté výsledky (MSE – priemer a minimum) sú uvedené v tabuľke č. 3.

Tabuľka 3 MSE (priemer a minimum) pre rôzny typ vstupných dát a rôzne modely NS

Typ vstupných dát	Model neurónovej siete			
	8,8,8,1	16,16,16,1	24,16,8,1	100,50,50,1
1	0,202 (0,200)	0,200 (0,198)	0,196 (0,191)	0,195 (0,190)
2	0,079 (0,078)	0,079 (0,077)	0,080 (0,076)	0,080 (0,078)
3	0,144 (0,140)	0,142 (0,138)	0,140 (0,136)	0,135 (0,133)
4	0,104 (0,102)	0,103 (0,098)	0,099 (0,096)	0,102 (0,100)

Výsledky simulácií priniesli dva hlavné poznatky. Po prvé, ak máme k dispozícii minulé hodnoty, presnosť predikcie je výrazne vyššia. Znalosť minulej hodnoty v odhadovanom mieste umožnila znížiť chybu odhadu o jednu tretinu, znalosť minulých hodnôt vo všetkých bodoch znížila chybu o viac než polovicu. Predpokladáme, že pridávaním ďalších minulých hodnôt by sa presnosť odhadu ešte zvýšila. Po druhé, na počte neurónov v skrytých vrstvách až tak veľmi nezáleží. Zložitejšia sieť umožňuje dosiahnuť lepšie výsledky hlavne v prípade menšieho počtu vstupných údajov (typ dát 1 a 3). Avšak aj vtedy sú rozdiely medzi najjednoduchšou a najzložitejšou sieťou len v jednotkách percent (3,6 % pre typ dát 1 a 6,7 % pre typ dát 3).

4.4 Predikcia časových radov

Ďalšia skupina simulácií bola zameraná na presnosť predikcie časového radu. V tomto prípade má neurónová sieť k dispozícii len údaje z jedného bodu. Okrem MLP neurónovej siete sme tentoraz otestovali aj rekurentnú sieť typu LSTM, ktorá je určená práve na úlohy takéhoto typu. Okrem rôznych typov neurónových sietí sme testovali aj rôznu dĺžku okna, čiže počet hodnôt z minulosti, na základe ktorých je robený odhad súčasnej hodnoty.

Počas simulácií boli výsledky pre LSTM sieť dosť nevyrovnané. Preto sú v tabuľke č. 4 uvedené priemerné hodnoty len troch najlepších výsledkov. Táto nevyrovnanosť je zrejme spôsobená podstatne väčšou zložitou LSTM sietí, čo ukazuje aj počet parametrov jednotlivých typov neurónových sietí. Veľkosť tréningovej množiny je zrejme nedostatočná na natréningovanie takej zložitej siete.

Tabuľka 4 MSE (priemer a minimum) pre rôznu dĺžku okna a rôzne modely NS

Dĺžka okna	Typ neurónovej siete			
	MLP 24,16,8,1	MLP 100,50,50,1	LSTM 24,1	LSTM 100,1
10	0,184 (0,182)	0,186 (0,183)	0,176 (0,165)	0,174 (0,164)
12	0,180 (0,173)	0,186 (0,177)	0,160 (0,158)	0,174 (0,169)
14	0,173 (0,170)	0,189 (0,180)	0,180 (0,173)	0,165 (0,148)
16	0,174 (0,162)	0,173 (0,165)	0,170 (0,152)	0,186 (0,150)
18	0,175 (0,163)	0,180 (0,164)	0,172 (0,165)	0,166 (0,158)
20	0,167 (0,160)	0,168 (0,164)	0,178 (0,175)	0,180 (0,160)
22	0,163 (0,162)	0,170 (0,164)	0,194 (0,190)	0,164 (0,146)
24	0,165 (0,155)	0,169 (0,159)	0,181 (0,145)	0,156 (0,126)
26	0,167 (0,153)	0,168 (0,159)	0,173 (0,154)	0,136 (0,131)
28	0,160 (0,152)	0,164 (0,156)	0,164 (0,144)	0,132 (0,129)
30	0,155 (0,151)	0,167 (0,156)	0,175 (0,150)	0,264 (0,187)
Počet parametrov	1289	10751	2521	40901


Výsledky simulácii ukázali, že LSTM sieť dokáže vo väčšine prípadov dosiahnuť mierne lepšie výsledky pri predpovedaní budúcich hodnôt. Ak však uvažujeme s použitím neurónovej siete priamo v uzle WSN, vzhľadom na obmedzenia výpočtového výkonu bude výhodnejšie použiť jednoduchšiu, klasickú MLP sieť. Vplyv dĺžky okna na presnosť odhadu je možné pozorovať len pre MLP sieť, pričom platí, že väčšie okno umožňuje dosiahnuť lepšie výsledky. Je zaujímavé, že MLP sieť s menším počtom neurónov dosahuje menšiu chybu dohadu než zložitejšia sieť. Tento paradoxný výsledok je zrejme spôsobený obmedzenou veľkosťou tréningovej množiny.

4.5 Simulácia možností šetrenia energie

V tejto časti budú prezentované výsledky simulácií zameraných na overenie možností šetrenia energie vo WSN sieti. Testovali sme obidva spôsoby šetrenia popísané v kapitole 3.2.2 - „Časovo-priestorová optimalizácia vzorkovania parametrov systému“.

4.5.1 Rozdelenie uzlov siete do skupín

Rozmiestnenie meracích modulov v reálnom prostredí bolo simulované náhodným výberom 20 bodov z matice 11x11 bodov (pozri kapitolu „Dataset“). Testovali sme rôzny pomer snímaných a počítaných hodnôt, pričom sme vyhodnocovali strednú štvorcovú odchýlku. Na obrázku č. 20 je znázornené rozdelenie vybraných bodov na dve rovnako veľké skupiny, t.j. pomer 10:10.



Obrázok 20 Rozdelenie 20 bodov na 2 rovnaké skupiny

Uskutočnili sme viaceré simulácie s rôznym pomerom snímaných a počítaných hodnôt ($m:n$) a pre rôzne veľké MLP neurónové siete. Výsledky sú uvedené v tabuľke č. 5.

Tabuľka 5 MSE pre rôzny počet snímaných a počítaných hodnôt - dataset UKCP18

Rozdelenie bodov snímané : počítané ($m : n$)	Typ neurónovej siete				
	MLP 8,8,8,n	MLP 16,16,16,n	MLP 24,16,8,n	MLP 50,30,20,n	MLP 100,50,50,n
16:4	0,057	0,056	0,054	0,052	0,051
15:5	0,084	0,08	0,079	0,08	0,078
13:7	0,079	0,074	0,074	0,071	0,071
10:10	0,082	0,07	0,072	0,068	0,067
7:13	0,119	0,107	0,11	0,104	0,103
5:15	0,146	0,143	0,144	0,141	0,143
4:16	0,167	0,162	0,165	0,165	0,162

Podobne ako v predošlých simuláciách sa ukázalo, že veľkosť neurónovej siete nemá výrazný vplyv na presnosť predikcie. Aj najmenšia testovaná sieť, len s ôsmymi neurónmi v každej vrstve, je schopná dosiahnuť porovnateľné výsledky ako sieť s osemnásobne väčším celkovým počtom neurónov. Tento výsledok je možné vysvetliť buď nízkou zložitou modelu klímy alebo, čo je pravdepodobnejšie, rovinným charakterom krajiny v uvažovanom mieste, čo môže spôsobiť veľkú koreláciu hodnôt v jednotlivých bodoch snímania.

V danom prípade je možné výrazné šetrenie energie, pretože aj pri pomere snímaných a počítaných hodnôt 1:4 je smerodajná odchýlka menej než $0,41\text{ }^{\circ}\text{C}$ ($\sqrt{0,167}$).

To znamená, že ak nám stačí presnosť snímania teploty na úrovni 0,5 °C, môžeme v jednom čase snímať teplotu jednou pätinou snímačov a teploty v zvyšných miestach dopočítať. Množinu bodov, v ktorých sú teploty snímané, je možné cyklicky meniť. Spotreba energie každého bodu siete tak klesne na 1/5 (úspora je 80 %), čo sa dá interpretovať aj ako päťnásobné predĺženie výdrže batérie.

Podobné simulácie sme uskutočnili aj s datasetom s reálne nameranými teplotami na Kilimandžare [100]. Vynechali sme neurónovú sieť MLP 24,16,8,n, ktorá dosahuje prakticky rovnaké výsledky ako sieť MLP 16,16,16,n. Výsledky simulácií sú uvedené v tabuľke č. 6.

Tabuľka 6 MSE pre rôzny počet snímaných a počítaných hodnôt - dataset Kilimandžáro

Rozdelenie bodov snímané : počítané (m : n)	Typ neurónovej siete			
	MLP 8,8,8,n	MLP 16,16,16,n	MLP 50,30,20,n	MLP 100,50,50,n
8:16	1,83	1,62	1,56	1,53
12:12	1,98	1,45	1,25	1,24
16:8	1,58	1,19	1,06	1,03
18:6	1,32	1,15	1,07	1,07
20:4	0,95	0,83	0,82	0,8

Simulácie s reálnymi dátami z extrémneho vysokohorského prostredia ukázali podstatne vyššiu úroveň chyby predikcie. V tomto prípade je zrejma vyššia úspešnosť neurónových sietí s väčším počtom neurónov. Zvyšovanie zložitosti siete ale prináša výsledky len do určitej hranice. Napríklad sieť MLP 100,50,50,n poskytuje len nepatrne lepšie výsledky než sieť s polovičným počtom neurónov (a približne tretinovým počtom parametrov) MLP 50,30,20,n.

Čo sa týka možností šetrenia energie, situácia je oveľa horšia než v predchádzajúcom prípade. Ak bude požadovaná stredná hodnota chyby odhadu na úrovni 1 °C, môžeme si dovoliť vynechať len 1/5 meraní, čo predstavuje úsporu 20 % energie.

4.5.2 Prenos dát na základe odchýlky odhadu

V tomto prípade simulujeme realizáciu neurónovej siete v každom bode snímania teploty. Úlohou neurónovej siete je predpovedať ďalšiu nameranú hodnotu. Ak je rozdiel predpovedanej a skutočnej hodnoty menší než vopred určená prahová hodnota, nameraná hodnota sa nebude prenášať do centra. Pre dataset UKCP18 sme na tréningovanie použili dáta z 19 rokov záznamov a 1 rok bol použitý na testovanie. Na predikciu bola použitá sieť

MLP 24,16,8,1, do ktorej vstupovalo 20 minulých hodnôt. Prahovú hodnotu sme zvolili na úrovni 0,5 °C. V tabuľke č. 7 je uvedený počet prekročení prahovej hodnoty v každom mieste snímania. Celkový počet testovaných hodnôt bol 8640.

Tabuľka 7 Počet prekročení prahovej hodnoty 0,5 °C - dataset UKCP18

Modul	1	2	3	4	5	6	7	8	9	10
Počet	1411	1598	1832	1797	1352	1682	1499	1498	1743	1613
Modul	11	12	13	14	15	16	17	18	19	20
Počet	1783	1564	1922	1489	2068	1918	1438	2033	1860	1430

Priemerný počet prekročení prahu je 1677, čo predstavuje 19,4 % všetkých hodnôt. V najhoršom prípade bol počet 2068 (23,9 %) a v najlepšom 1411 (16,3 %). Pre danú prahovú hodnotu by sme teda ušetrili energiu za 80 % prenosov, ktoré nie je potrebné uskutočniť, pričom energiu by šetrili všetky zariadenia (moduly) pomerne rovnomerne. Na rozdiel od predchádzajúceho príkladu (rozdelenie modulov do skupín) by bola reálna úspora energie nižšia. V tomto prípade totiž musíme merať hodnotu v každom okamihu vzorkovania a šetríme len na prenose. Okrem toho sa časť energie spotrebuje na výpočet odhadu pomocou neurónovej siete.

Podobný simulačný experiment sme uskutočnili aj pre dataset Kilimandžáro. Z celkového počtu 12846 záznamov bolo na tréningovanie použitých 10346 a na testovanie 2500 záznamov. Vzhľadom na menšiu veľkosť tréningovej množiny bola veľkosť dávky nastavená na 32. Na predikciu bola použitá rovnaká sieť (MLP 24,16,8,1), ale vstupovalo do nej až 28 minulých hodnôt. V tabuľke č. 8 je uvedený počet prekročení dvoch prahových hodnôt: 0,5 °C a 1 °C.

Tabuľka 8 Počet prekročení prahových hodnôt 0,5 °C a 1 °C - dataset Kilimandžáro

Modul	1	2	3	4	5	6	7	8	9	10	11	12
Prah 0,5 °C	1262	1030	1200	327	397	788	1312	1353	1392	1235	1354	1185
Prah 1 °C	577	402	525	29	72	198	589	682	680	563	646	526
Modul	13	14	15	16	17	18	19	20	21	22	23	24
Prah 0,5 °C	1181	1244	1323	1333	1222	1458	1131	1400	1391	1337	1123	1374
Prah 1 °C	506	588	639	669	521	790	471	689	701	639	333	540

Pre prahovú hodnotu 0,5 °C je priemerný počet prekročení 1181 (47,2 %) a pre 1 °C je to 524 (21 %). Na rozdiel od datasetu UKCP18 je zrejmy výrazný rozdiel v počte prekročení prahu v jednotlivých moduloch. Pre prahovú hodnotu 1 °C je v najlepšom prípade (modul 4) len 29 nepresných odhadov (1,2 %) a v najhoršom prípade (modul 18) je to až 790 nepresných odhadov (31,6 %). Tomu zodpovedá aj značne nerovnomerné rozloženie ušetrenej energie, čo sa prejaví v nerovnakej životnosti meracích zariadení (modulov).

4.5.3 Porovnanie spôsobov šetrenia energie

Výsledky predošlých simulácií umožňujú porovnať úspešnosť obidvoch spôsobov šetrenia energie. V tabuľke č. 9 je uvedené množstvo energie v percentách, ktorú je možné ušetriť. Pripomíname, že hodnota ušetrenej energie v prípade predikcie budúcej hodnoty nie je úplne presná. Reálna hodnota je nižšia a závisí od použitých technických prostriedkov (spotreba snímača, výpočtový výkon atď.).

Tabuľka 9 Približná veľkosť ušetrenej energie

Dataset	Presnosť	Rozdelenie do skupín	Predikcia hodnoty
UKCP18	0,5 °C	80 %	80 %
Kilimandžáro	1 °C	20 %	80 %

Pre dataset UKCP18 sú obidva spôsoby šetrenia energie prakticky rovnocenné. Časovo-priestorová závislosť teplôt v bodoch merania je pomerne vysoká, čo sa prejavilo na veľkých možnostiach úspory energie – v obidvoch prípadoch je to až 80 %. Samozrejme, veľkosť ušetrenej energie priamo závisí na požadovanej presnosti snímania teploty.

V prípade datasetu Kilimandžáro je situácia iná. Priestorová závislosť medzi bodmi siete nie je taká výrazná a umožňuje ušetriť len cca 20 % energie, pri presnosti 1 °C. Pravdepodobne je to spôsobené vysokohorským prostredím – teplota na vrchole kopca až tak nesúvisí s teplotou v údolí. V prípade predikcie budúcej hodnoty je situácia podstatne lepšia – dosiahli sme úsporu až 80 %. V porovnaní s datasetom UKCP18 je ale úspora menej rovnomerne rozložená medzi jednotlivé uzly (moduly) siete.

5 Reálne experimenty

V tejto časti práce sa nachádzajú dosiahnuté výsledky na základe vykonaných experimentov na nami nameraných reálnych dátach. Vychádzajúc z predošlých simulačných experimentov a vzhľadom na hardvérové obmedzenia počas riešenia tejto práce sme sa rozhodli pre monitoring vonkajšieho prostredia a to konkrétne teploty vzduchu a intenzity osvetlenia. Zostavili sme jednoduché koncové zariadenia (moduly), ktoré v pravidelných intervaloch merajú okolitú teplotu vzduchu a intenzitu osvetlenia. Následne tieto informácie zasielajú centrálnemu prvku v sieti – prístupovému bodu (gateway), kde sú dáta ukladané a ďalej spracovávané. Zvolili sme minútový interval vzorkovania, pretože pri práci s neuronovými sieťami všeobecne platí pravidlo, že čím je väčší trénovací dataset, tým lepšie sú výsledky. Taktiež bola vykonaná analýza a vyhodnotenie možností šetrenia energie pre porovnanie s experimentami v predchádzajúcej kapitole.

Cieľom bolo dosiahnuť odhad meranej teploty v danom bode senzorickej siete na základe meraní v ostatných bodoch s čo možno najmenšou chybou. Nakoľko predpokladáme závislosť teploty aj od intenzity okolitého osvetlenia, rozhodli sme sa merať aj túto veličinu, ktorá by mala prispieť k presnejším výsledkom. Pri práci na tejto úlohe sme postupne navrhli a vytvorili dve WSN. Prvá verzia bezdrôtovej senzorickej siete pozostávala zo štyroch modulov a bola nasadená v teréne približne mesiac. Na základe tejto siete bola vyvinutá kvalitnejšia a robustnejšia sieť, kde boli odstránené nedostatky v komunikácii a pridané ďalšie dva senzoricke moduly. Druhá WSN bola do terénu nasadená v apríli 2020. Namerané dáta boli však použiteľné až po dlhodobom sledovaní a odladení siete, od augusta 2020.

V oboch experimentoch boli použité totožné snímacie prvky. Na meranie teploty sme použili teplotný snímač DS18B20 s nastaviteľným rozlíšením 9 až 12 bitov. Tento snímač komunikuje s hlavnou riadiacou jednotkou prostredníctvom 1 vodičovej zbernice, ktorá vyžaduje prepojenie len jednej dátovej linky a potenciálu zeme. Dokáže byť napájaný priamo z tohto dátového vodiča, čo eliminuje potrebu externého napájania. Na meranie intenzity okolitého osvetlenia je použitý fotorezistor PGM5506. Spojitá analógová hodnota je prevedená do digitálnej formy za pomoci ADC prevodníka daného mikrokontroléra. V našom prípade túto hodnotu charakterizujeme 16-bitovým kladným celým číslom z intervalu $\langle 0,65535 \rangle$. Čím je toto číslo menšie, tým je intenzita okolitého osvetlenia

vyššia. Vo všetkých prípadoch boli snímače umiestnené približne 2 metre nad zemským povrchom.

Plocha pokrytá senzorickými modulmi v prvom experimente činila cca 1,9 km² a v druhom prípade cca 7,2 km². Rozmiestnenie senzorov a plocha pokrytia pri jednotlivých experimentoch je znázornené na obrázku č. 21.

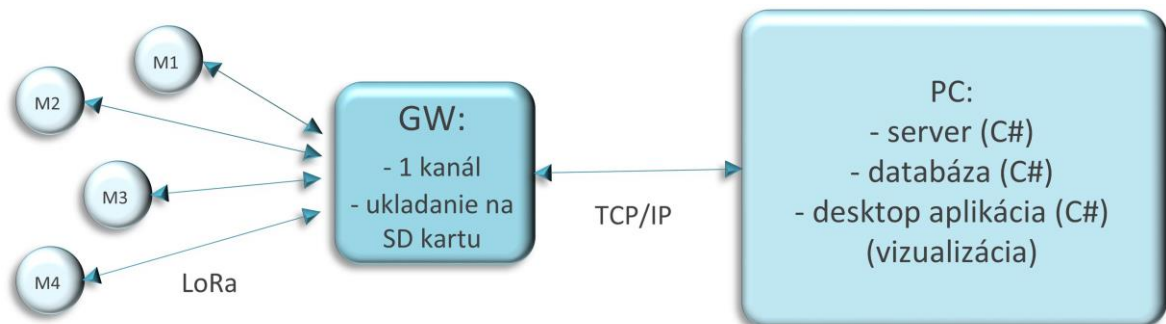


Obrázok 21 Plocha pokrytá WSN siet'ami

5.1 Experiment č. 1

Primárnym účelom návrhu tohto riešenia bolo zber a uchovávanie nameraných dát od senzorov a ich vizualizácia u používateľa v počítači. Namerané dáta boli použité na tréning a testovanie neurónovej siete, ktorá odhadovala teplotu v danom mieste WSN na základe meraní vo zvyšných bodoch. Na bezdrôtovú komunikáciu sú využité rádiové moduly LoRa RFM95W, ktoré využívajú voľné ISM pásmo o frekvencii 868 MHz. Štyri


koncové zariadenia majú za úlohu v pravidelných intervaloch zmerať okolitú teplotu, intenzitu osvetlenia a napäťovú úroveň batérií. Následne túto informáciu odošlú prístupovému bodu s využitím LoRa technológie a s využitím nami navrhutej siete a komunikačného protokolu. Ten následne prijaté dáta preposiela pomocou WiFi rozhrania serveru, ktorý ukladá správy do databázy a sprostredkúva ich klientskej aplikácii. Táto klientska aplikácia už predstavuje grafické rozhranie pre koncového používateľa. Bloková schéma návrhu WSN siete sa nachádza na obrázku č. 22.



Obrázok 22 Architektúra navrhutej WSN (1. model)

5.1.1 Hardvérové vybavenie


Na skonštruovanie prototypu koncového zariadenia sme použili vývojovú dosku, na ktorej sa nachádza 32-bitový mikrokontrolér s jadrom ARM Cortex-M3 (STM32F103C8T6). Pre bezdrôtovú komunikáciu s využitím LoRa technológie je použitý rádiový modul RFM95W, ktorý komunikuje v bezlicenčnom ISM pásme na frekvencii 868 MHz. Zariadenie je zobrazené na obrázku č. 23.



Obrázok 23 Snímacie zariadenie

Toto zariadenie obsahuje taktiež spínací regulátor napätia, ktorého vstupné napätie sa môže pohybovať v rozsahu 4,75 V až 23 V. Môže byť napájané zo siete pomocou adaptéra, alebo pomocou batérií. V našom prípade využívame na napájanie dve lítium-iónové batérie typu 18650 v sériovom zapojení. Nominálne napätie jednej batérie je 3,7 V.

Hlavná riadiaca jednotka centrálného uzla v sieti je tvorená mikrokontrolérom s jadrom ARM Cortex-M4 (STM32F401RET6). Ako hlavnú komunikačnú jednotku využívajúcu LoRa technológiu sme zvolili taktiež rádiový modul s označením RFM95W, ktorý pracuje vo voľnom ISM pásme o frekvencii 868 MHz. Tento modul komunikuje s hlavnou riadiacou jednotkou celého zariadenia pomocou SPI zbernice a pomocou vstupno-výstupných vývodov. Navrhnutá a osadená doska plošných spojov tohto zariadenia sa nachádza na obrázku č. 24.



Obrázok 24 Prístupový bod

Pre bezdrôtovú komunikáciu so serverom je využitý nízkonákladový WiFi modul ESP8266-01. S riadiacou jednotkou komunikuje prostredníctvom UART komunikačného rozhrania. Zariadenie obsahuje taktiež aj Bluetooth komunikačné rozhranie, ktoré je tvorené modulom HC-05. Toto rozhranie je určené pre bezdrôtovú konfiguráciu zariadenia. Pomocou neho možno napríklad bezdrôtovo nastaviť názov a heslo WiFi siete alebo IP adresu servera, na ktorý sa pripája tento prístupový bod. Posledná časť zariadenia je tvorená prevodníkom FT232RL, ktorý konvertuje USB na UART komunikačné rozhranie.

Táto časť môže byť využitá pre programovanie hlavnej riadiacej jednotky alebo na vývojové účely.

5.1.2 Zostavenie datasetu

Na zostavenie datasetu sme použili štyri vyššie popísané senzorické moduly. Dáta v podobe vonkajšej teploty a intenzity osvetlenia okolitého prostredia sme získavali v minútových intervaloch. Sensory boli rozmiestnené v prímestských častiach Žiliny. Poloha jednotlivých modulov je zobrazená na obrázku č. 25.




Obrázok 25 Mapa rozmiestnenia jednotlivých senzorických modulov

Ako hlavný cieľ experimentu sme si stanovili odhad teploty v mieste modulu č. 4 na základe meraní vo zvyšných 3 bodoch bezdrôtovej senzorickej siete. Na tejto úlohe sme otestovali a porovnali využitie štyroch rôznych modelov doprednej plne prepojenej neurónovej siete. Ukážka nameraných dát sa nachádza na obrázku č. 26. Pri tomto experimente sme využili dáta, ktoré boli namerané počas 8 dní. Dáta z prvých siedmich dní boli použité na tréning neurónovej siete. Dáta z posledného dňa slúžili na verifikáciu.

Celkovo bol vytvorený dataset s počtom 11520 záznamov. Každý záznam bol tvorený časom, kedy sa meranie uskutočnilo a ôsmimi hodnotami z merania (každý senzorický modul meral teplotu a intenzitu osvetlenia). V ďalšom kroku bolo potrebné vykonať predspracovanie a normalizáciu dát. Program bol písaný v skriptovacom jazyku Python s využitím TensorFlow a Keras frameworku [56]. Tréning neurónovej siete prebehlo na notebooku s využitím CPU (Intel(R) Core(TM) i5-5200U CPU @ 2.20GHz).

Vstup do neurónovej siete bol tvorený šiestimi hodnotami, ktoré predstavovali merania (teplota a intenzita osvetlenia) z prvých troch senzoričných modulov v danom čase. Výstup zo siete reprezentuje teplotu štvrtého senzoričného modulu v tom istom čase.



Obrázok 26 Ukážka nameraných dát

5.1.3 Výsledky experimentu

V priebehu tohto experimentu sme sa zamerali na plne prepojené dopredné neurónové siete s využitím algoritmu spätného šírenia chýb v priebehu učenia. Nameraná hodnota v bode č. 4 zároveň reprezentuje odpoveď učiteľa počas fázy tréningu neurónovej siete. Porovnali sme 4 rôzne modely neurónových sietí. Prvý model predstavuje sieť tvorenú len jedným neurónom. To znamená, že výstup je tvorený len lineárnou kombináciou vstupov (lineárna regresia). Na základe predchádzajúcich experimentov a malého počtu vstupov (6), ďalšie modely obsahujú jednu, dve alebo tri skryté vrstvy, kde je každá skrytá vrstva tvorená ôsmimi neurónmi.

Pre všetky modely boli zvolené rovnaké konštantné parametre a rýchlosť učenia. Ako aktivačná funkcia bola využitá funkcia ReLU. Tréning každého modelu prebehlo v rovnakom počte tréningových epoch. Pre každý model neurónovej siete bola vypočítaná priemerná absolútna chyba (MAE), smerodajná odchýlka (σ) a stredná kvadratická chyba (RMSE) podľa vzťahov 5.1 až 5.4. Chybu i -tej predikcie (e_i) môžeme určiť ako rozdiel medzi požadovanou (y_i) hodnotou a predikovanou hodnotou (\bar{y}_i). Číslo N predstavuje počet prvkov v danom súbore. Porovnanie výsledkov a jednotlivých chýb je uvedené v tabuľke č. 10.

$$e_i = y_i - \bar{y}_i \quad (5.1)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |e_i| \quad (5.2)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (e_i - \bar{e})^2}, \text{ kde } \bar{e} = \frac{1}{N} \sum_{i=1}^N e_i \quad (5.3)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N e_i^2} \quad (5.4)$$

Tabuľka 10 Porovnanie chýb výstupov jednotlivých modelov NS

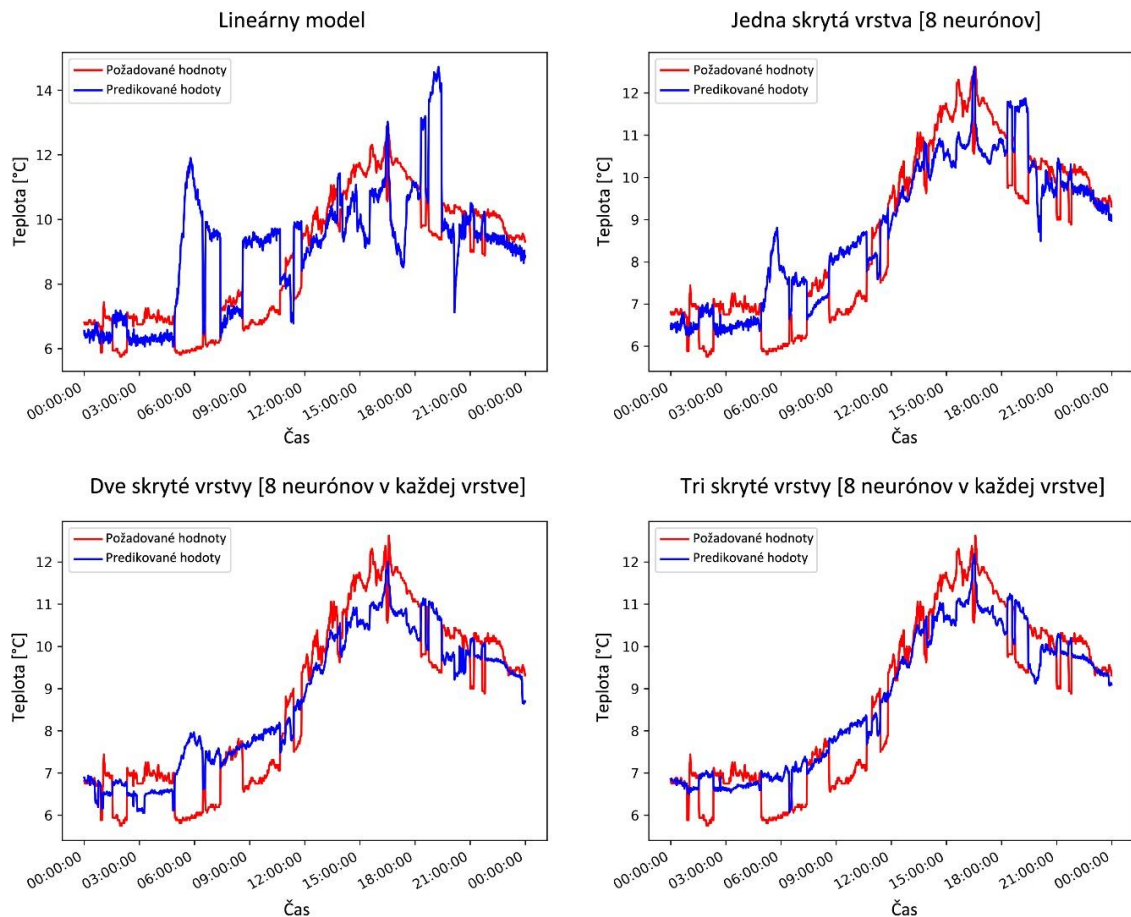
Model NS.	Priemerná Absolútna chyba, [°C]	Smerodajná odchýlka (σ), [°C]	Stredná kvadratická chyba, [°C]
1.	1,451	1,945	1,984
2.	0,838	1,023	1,030
3.	0,718	0,844	0,844
4.	0,633	0,755	0,757

Grafické porovnanie výsledkov jednotlivých neurónových sietí je zobrazené na obrázku č. 27. Červenou krivkou je znázornená skutočne nameraná teplota okolia senzorickým modulom č. 4. Modrou krivkou je znázornený výstup z neurónovej siete a teda predikovaná hodnota. Táto hodnota bola vypočítaná len na základe aktuálnych meraní vo zvyšných troch bodoch našej bezdrôtovej senzorickej siete.

Na základe výsledkov predikcie neurónovej siete a vypočítaných chýb pre jednotlivé štruktúry NS možno vidieť, že pridaním skrytých vrstiev sme dosiahli menšiu chybu predikcie. Pridanie ďalšej vrstvy už neprineslo pozitívny efekt na presnosť predikcie. Pridanie časovej informácie na vstup siete by mohlo mať do budúcnosti kladný vplyv, rovnako ako aj pridanie ďalších vstupov, ktoré by predstavovali predchádzajúce merania, tzv. časové okno. Vhodná metóda predspracovania meranej veličiny by mohla taktiež prispieť k menšej chybe pri odhade.

Vytvorená sieť bola určená na jednoduché a pomerne rýchle overenie funkčnosti takéhoto riešenia a použitia neurónovej siete pre skúmanú problematiku. Táto WSN sieť však nespĺňala požadovanú kvalitu. Nakoľko celá sieť využívala len jeden komunikačný kanál, tak často dochádzalo ku kolíziám počas prenosu, aj z dôvodu potvrdzovania každej správy. Nami navrhnutý komunikačný protokol nad technológiou LoRa nefungoval spoľahlivo, čo malo tiež za následok vysokú spotrebu energie. Taktiež sme chceli zostaviť omnoho väčší dataset nameraných hodnôt a preto bolo potrebné mať spoľahlivú a funkčnú WSN. Cieľom bolo aj rozšírenie siete o ďalšie zariadenia a pokrytie aj vzdialenejších

miest v rámci dosahu danej komunikačnej technológie. Preto sme sa rozhodli navrhnúť a zrealizovať robustné riešenie WSN siete s využitím už dostupného komunikačného protokolu LoRaWAN.



Obrázok 27 Grafické znázornenie výsledkov

5.2 Experiment č. 2

Na základe poznatkov z prvého experimentu bol vyvinutý nový prototyp WSN siete, kde bol kladený dôraz najmä na spoľahlivú komunikáciu a meranie daných fyzikálnych veličín v požadovaných časových intervaloch. Bloková schéma návrhu druhej WSN siete sa nachádza na obrázku č. 28.

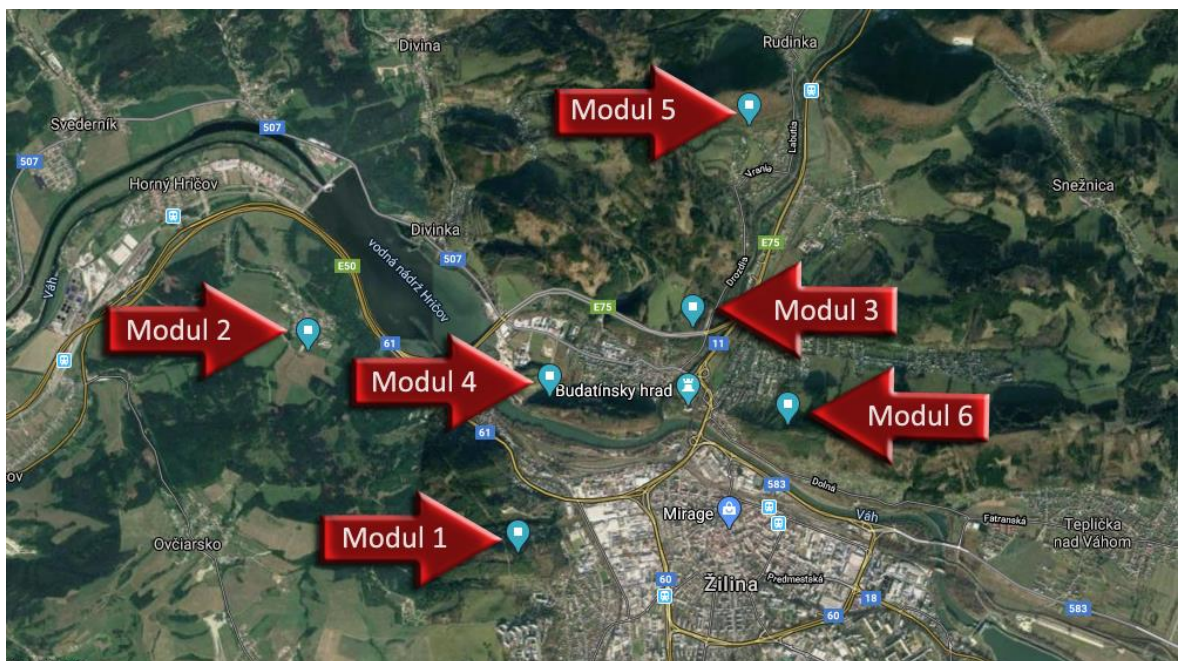
V tomto experimente bol využitý LoRaWAN komunikačný protokol, ktorý je bližšie špecifikovaný v predchádzajúcich kapitolách. Sieť sme rozšírili o ďalšie dve koncové zariadenia a umiestnili ich tak, aby sme pokryli väčšie územie. Taktiež sme navrhli a implementovali koncovú aplikáciu pre ukladanie nameraných dát a webové rozhranie pre vizualizáciu v reálnom čase. Sieť je v teréne nasadená od apríla 2020.

Jednotlivé moduly merali v pravidelných minútových intervaloch teplotu a intenzitu okolitého osvetlenia a zasielali namerané dáta na server, kde boli vizualizované v reálnom čase a ukladané do databázy a súboru.



Obrázok 28 Architektúra WSN siete (2. model)

Cieľom experimentu je navrhnúť univerzálny model neurónovej siete, ktorý na základe vstupu vie odhadnúť teplotu v ľubovoľnom uzle sensorickej siete. Na rozdiel od prvého experimentu, kde neurónová sieť predpovedala meranú veličinu len v jednom, dopredu určenom bode. Rozmiestnenie jednotlivých koncových zariadení sa nachádza na obrázku č. 29.




Obrázok 29 Mapa rozmiestnenia sensorických modulov

5.2.1 Hardvérové vybavenie

Ako centrálny bod siete bol použitý jednodoskový počítač Raspberry Pi 3 s nastavbovým modulom RAK2245, ktorý slúži ako LoRaWAN prístupový bod

(Gateway). Podporuje osem kanálov a je dostupný pre všetky frekvenčné pásma LoRaWAN. V našom prípade využívame voľné ISM pásmo o frekvencii 868 MHz. Tento modul obsahuje v sebe čip SX1301 od firmy Semtech, ktorý je schopný prijímať pakety z mnohých rozptýlených bodov siete. Zároveň celé zariadenie zobrazené na obrázku č. 30, spoločne s Raspberry Pi slúži aj ako sieťový a aplikačný server.



Obrázok 30 WSN prístupový bod a server

Koncové zariadenia boli založené na návrhu plošného spoja prístupového bodu z prvej WSN siete. Zariadenie bolo obohatené o periférie (senzory), pomocou ktorých je možné merať požadované veličiny z okolitého prostredia (teplotu vzduchu a intenzitu osvetlenia) a aktuálny stav napätia batérií. Modul nasadený v teréne je možné vidieť na obrázku č. 31. Komunikačný modul bol vymenený za typ RAK811, ktorý oproti pôvodnému riešeniu implementuje aj LoRaWAN komunikačný protokol. Tento modul komunikuje s hlavnou riadiacou jednotkou cez UART komunikačné rozhranie a je ovládaný pomocou špeciálnych AT príkazov. Podporuje všetky 3 triedy (A,B,C) komunikačného protokolu. V našom prípade využívame triedu A. Pomocou tohto modulu je možná komunikácia s LoRaWAN prístupovým bodom, ktorý je popísaný vyššie.



Obrázok 31 Ukážka senzorickeho modulu v teréne

Taktiež sme zmerali približnú spotrebu energie použitého komunikačného modulu RAK811 v rôznych prevádzkových režimoch pri napájacom napätí 3,3 V. Namerané hodnoty sú uvedené v tabuľke č. 11.

Tabuľka 11 Spotreba energie komunikačného modulu RAK811

Prevádzkový režim modulu RAK811	Prúdový odber [mA]
Pracovný	6
Režim spánku	0,14
Vysielanie (+14 dBm)	57
Príjem	22

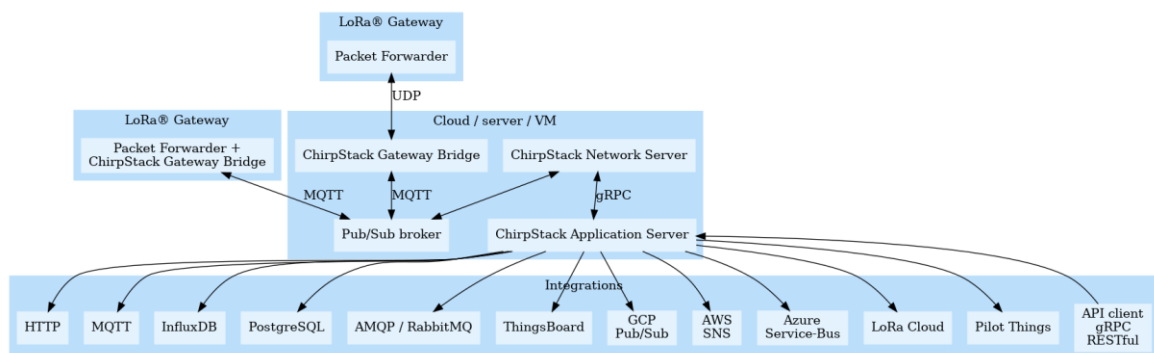
5.2.2 Softvérové vybavenie

ChirpStack [102], predtým známy pod pojmom LoRa Server, je otvorený softvér a ponúka komponenty pre sieť LoRaWAN. ChirpStack architektúra spolu s LoRaWAN sieťou poskytujú modulárne riešenie, ktoré je možné okamžite nasadiť do prevádzky. Tento systém ponúka aj užívateľsky prístupné webové rozhranie pre konfiguráciu zariadení a rôzne API rozhrania, pre integráciu do vlastných projektov. Modulárna architektúra umožňuje toto riešenie integrovať aj v rámci existujúcich infraštruktúr. Všetky

komponenty spadajú pod MIT licenciu a môžu byť použité aj na komerčné účely. ChirpStack ponúka viaceré moduly, ktorými sú:

- ChirpStack Gateway Bridge: riadi komunikáciu medzi LoRaWAN zbernými bodmi.
- ChirpStack Network Server: je implementácia LoRaWAN sieťového servera.
- ChirpStack Application Server: je implementácia LoRaWAN aplikačného servera.
- ChirpStack Gateway OS: je operačný systém založený na Linuxe určený pre Raspberry Pi na ktorom sa spúšťa ChirpStack systém.

Na obrázku č. 32 je zobrazená modulárna architektúra jednotlivých častí ChirpStack systému, ktorá je spustená na Raspberry Pi. LoRaWAN zariadenia (v našom prípade moduly nasadené v teréne) sú zariadenia, ktoré posielajú dáta cez LoRa Gateway až k sieťovému serveru ChirpStack Network Server. ChirpStack Gateway Bridge zvyčajne počúva na 8 alebo viacerých kanáloch naraz a preposiela prijaté dáta na ChirpStack sieťový server. Tento server riadi stav siete a je schopný prijímať žiadosti zariadení o pripojenie do siete. Tiež sa stará o elimináciu duplicitných správ, ak nejakú správu prijímú viaceré prístupové body. Prijaté správy ďalej preposiela na ChirpStack aplikačný server. Komunikácia funguje aj opačným smerom, ak aplikačný server potrebuje poslať dáta zariadeniam, sieťový server ich zaradí do fronty a ďalej ich preposiela zberným modulom, ak už nie sú obsadené. Aplikačný server ponúka webové rozhranie a API pre manažment čo sa týka užívateľov, organizácie, aplikácií, zberných bodov a zariadení [102].

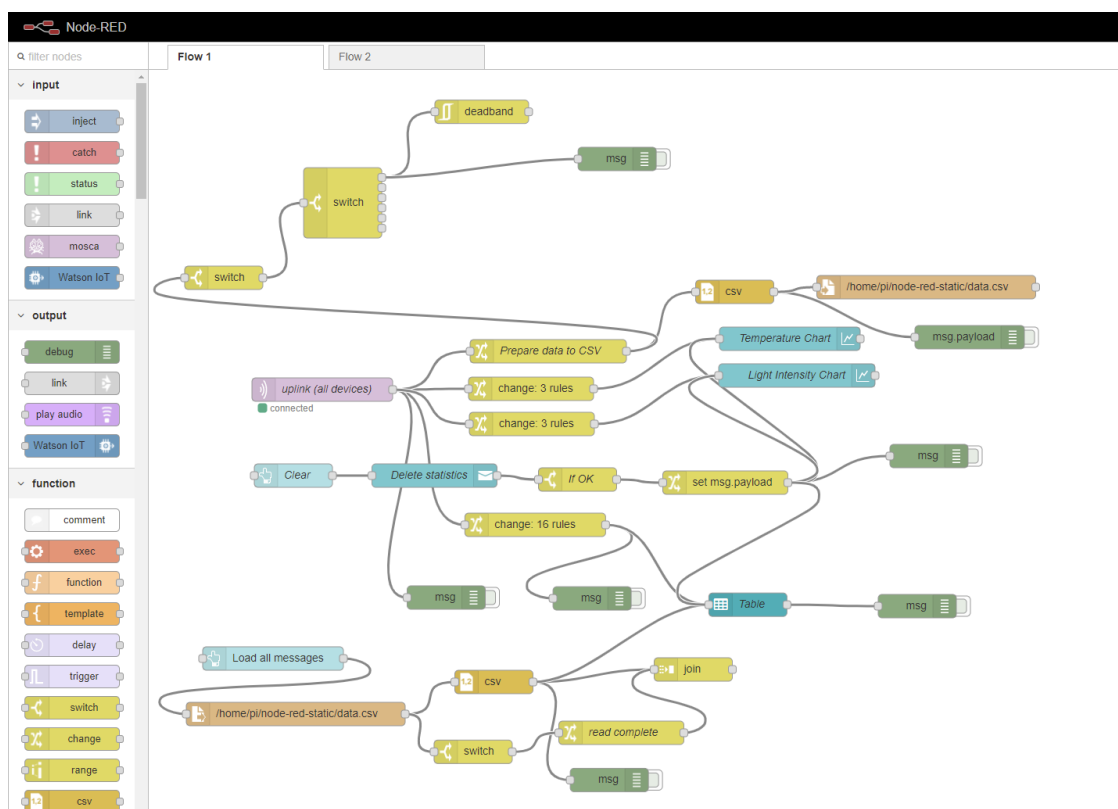


Obrázok 32 Architektúra ChirpStack systému [102]

Koncová aplikácia závisí od konkrétnej voľby užívateľa. V našom prípade bola využitá služba Node-RED [103] na zber a vizualizáciu dát a na komunikáciu s modulmi. Node-RED je založený na Node.js runtime prostredí, pričom využíva jeho udalostne

riadený, neblokujúci model. Node-RED je konfiguračný nástroj pre tokom-riadené systémy. Využitie nájde najmä v IoT aplikáciách. Vďaka tomuto softvéru je možné nadviazanie internetovej komunikácie a ovládanie rôznych IoT zariadení. Dokáže prijať správy vo formáte JSON, XML alebo aj emailové správy, ďalej je schopný tieto dáta graficky spracovať a vizualizovať v požadovanej forme.

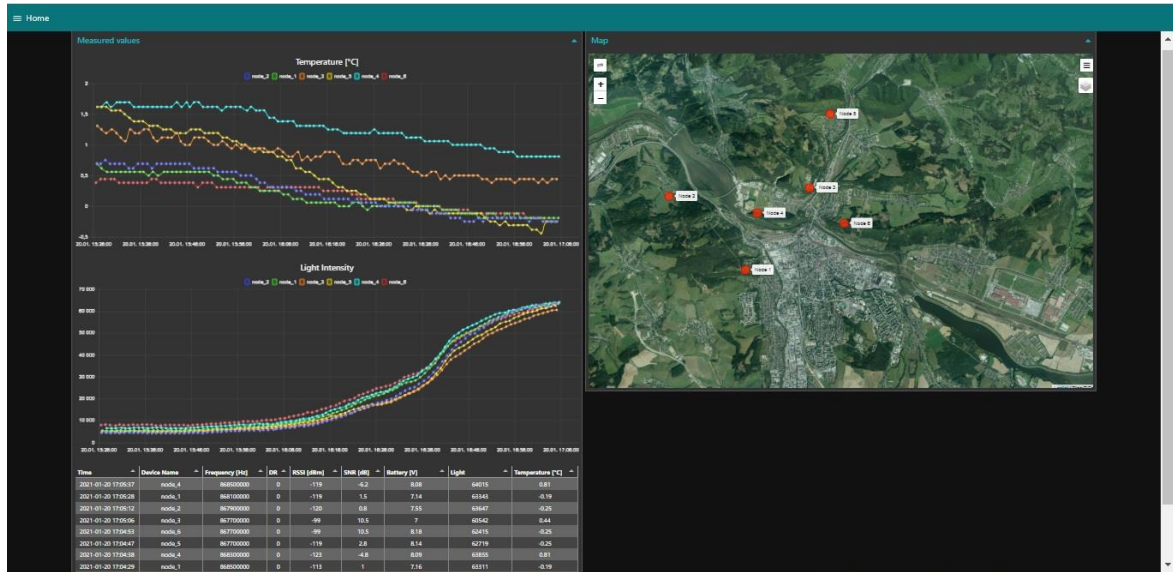
Konfigurácia funguje na princípe grafického „programovania“ pomocou blokov. K dispozícii sú bloky pre odosielanie, prijímanie, spracovanie správ, pomocou ďalších blokov je možné realizovať aj grafické ovládacie prostredie a vizualizovať dáta. Node-RED funguje ako webová aplikácia, ktorá môže byť spustená lokálne (lokálny Node-RED server), na vzdialenom serveri alebo aj v cloude. V našom prípade je Node-RED server aj aplikácia spustená na Raspberry Pi spolu so spomenutým systémom ChirpStack, s ktorým komunikuje cez MQTT komunikačný protokol. Na obrázku č. 33 je možné vidieť ukážku konfiguračného prostredia Node-RED pre experiment č. 2.



Obrázok 33 Node-RED konfiguračné prostredie

Dáta sú prístupné online po prihlásení do webovej aplikácie odkiaľ je možné dáta aj stiahnuť vo forme *.csv súboru za určité obdobie. Na obrázku č. 34 je možné vidieť webovú aplikáciu, kde sú zobrazované namerané hodnoty v reálnom čase a pozícia jednotlivých senzorov. Cez toto grafické webové užívateľské rozhranie je zároveň možné

zasielať jednotlivým koncovým zariadeniam konfiguračné správy týkajúce sa LoRaWAN technológie a nastaviť interval merania (zasielania správ).



Obrázok 34 Node-RED webová aplikácia

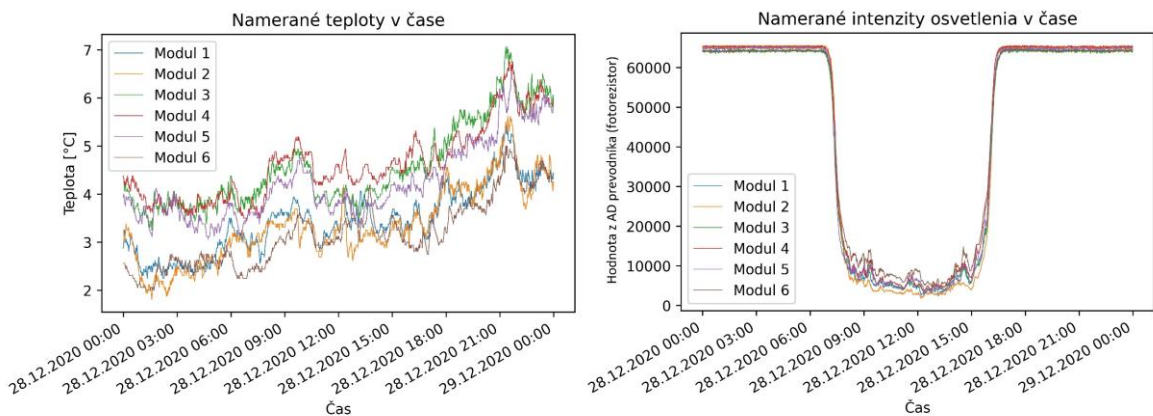
5.2.3 Zostavenie datasetu

Na získanie potrebných dát boli použité vyššie popísané koncové zariadenia, ktoré v pravidelných minútových intervaloch zasielajú namerané hodnoty okolitej teploty, intenzity osvetlenia a informáciu o napäťovej úrovni batérií. Použiteľné dáta z meraní boli uchovávané po odladení siete, od augusta 2020. Namerané hodnoty boli na serveri ukladané do *.csv súboru. Každá prijatá správa predstavuje nový záznam v súbore, kde sa okrem meraných veličín ukladajú aj informácie o prenosovom kanáli a indikátory sily prijatého signálu RSSI a SNR. Ukážka záznamov sa nachádza v tabuľke č. 12.

Tabuľka 12 Ukážka záznamu prijatého z modulu

Čas	Modul	Frekvencia [MHz]	RSSI [dBm]	SNR [dB]	Napätie batérií [V]	AD (fotorez.)	Teplota [°C]
26.12.2020 10:32:10	Modul 2	867,1	-108	7,5	7,6	1648	0,88
26.12.2020 10:32:16	Modul 5	868,1	-121	2,8	7,56	4801	-1,38
26.12.2020 10:32:22	Modul 3	868,1	-101	12,5	8,06	3632	-0,31
26.12.2020 10:32:26	Modul 4	867,1	-105	7,8	7,61	3648	0,19
26.12.2020 10:32:31	Modul 1	867,1	-114	6	7,05	2896	-0,69
26.12.2020 10:32:37	Modul 6	868,5	-119	10,2	7,54	5841	-1,75

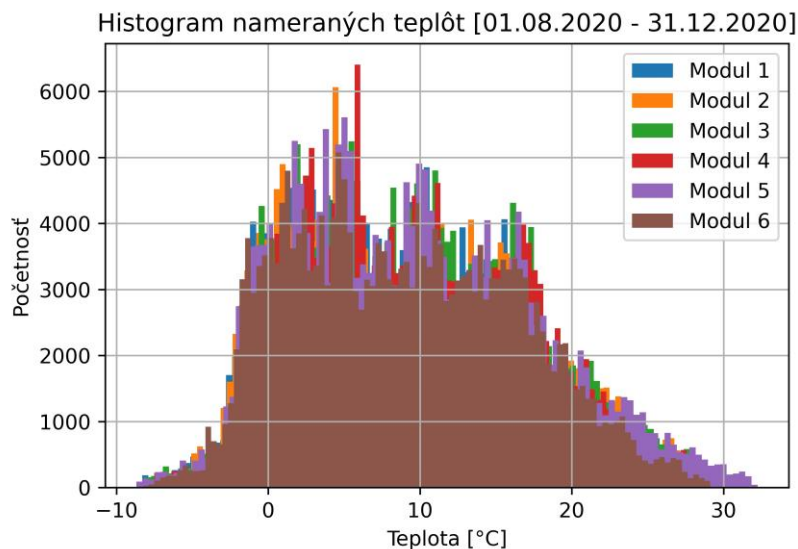
Cieľom je dosiahnuť čo najpresnejší odhad meranej veličiny (teploty) v ľubovoľnom uzle WSN na základe meraní v ostatných bodoch siete. Na to, aby sme namerané dáta mohli ľahšie analyzovať a využiť v procese tréningu a testovania neurónovej siete bolo potrebné vytvoriť upravený dataset nameraných hodnôt, kde každý riadok reprezentoval merania vykonané v danej minúte. Ukážka grafickej reprezentácie nameraných dát počas jedného vybraného dňa (28.12.2020) sa nachádza na obrázku č. 35. Z obrázka možno vyčítať aj východ alebo západ slnka a s nimi spojenú zmenu nameranej hodnoty AD prevodníkom. Čím je táto hodnota nižšia, tým je intenzita osvetlenia vyššia.



Obrázok 35 Grafická reprezentácia nameraných dát

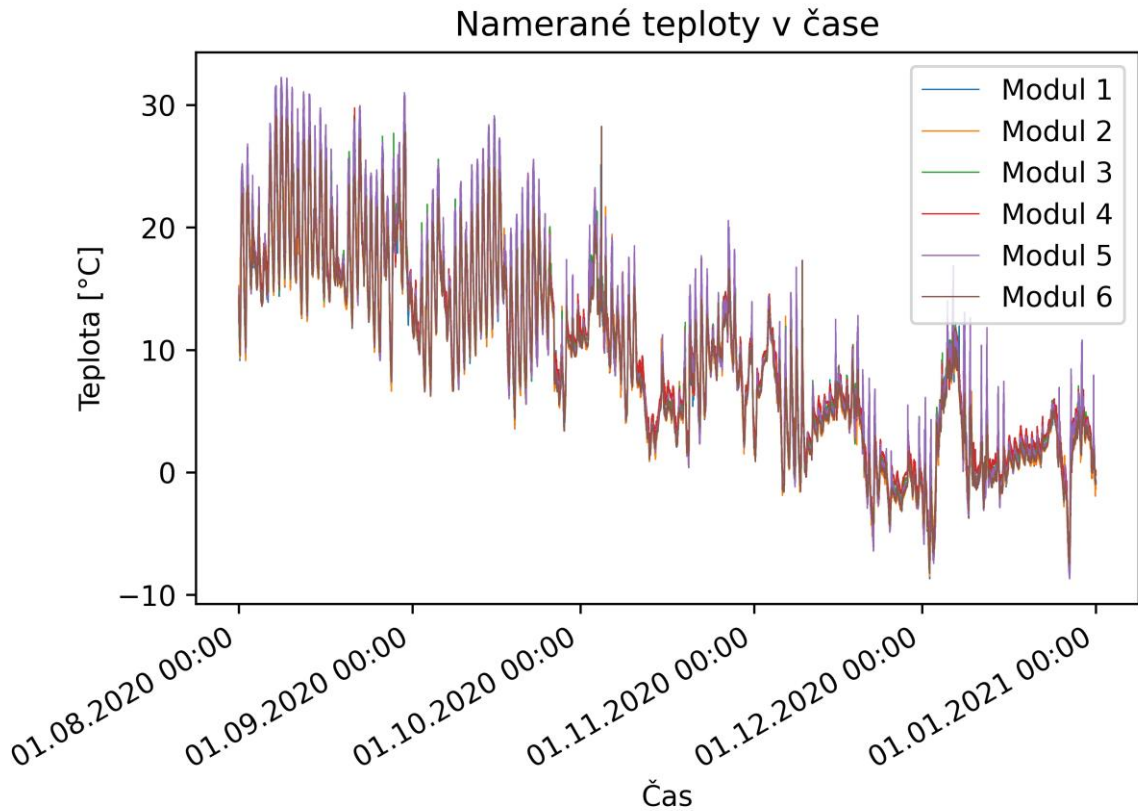
5.2.4 Dátová analýza

Táto časť je venovaná dátovej analýze a zisteniu závislostí medzi jednotlivými premennými. Na obrázku č. 36 je znázornený histogram nameraných teplôt použitého datasetu od augusta 2020 do konca roka.



Obrázok 36 Histogram nameraných dát za obdobie 08-12/2020

Na obrázku č. 37 je znázornený priebeh teplôt v rámci nášho datasetu. Z obrázka je zjavná periodicita jednotlivých dní a pokles priemernej teploty v rámci striedania ročných období.



Obrázok 37 Dataset s nameranými hodnotami teploty

Na zistenie väzby – korelácie medzi danými veličinami využijeme korelačnú analýzu. Zadefinujme si dve veličiny X a Y . Predpokladajme, že existuje medzi týmito veličinami lineárna závislosť. Nech $(x_1, y_1), \dots, (x_n, y_n)$ sú namerané hodnoty nezávislého náhodného výberu o rozsahu n systému dvoch náhodných veličín X, Y z dvojrozmerného normálneho rozdelenia a nech \bar{x} a \bar{y} sú ich výberové priemery. Pearsonov korelačný koeficient $r_{x,y}$ môžeme vypočítať podľa vzťahu [104]:

$$r_{x,y} = \frac{\overline{x \cdot y} - \bar{x} \cdot \bar{y}}{\sqrt{\overline{x^2} - (\bar{x})^2} \cdot \sqrt{\overline{y^2} - (\bar{y})^2}}, \quad (5.5)$$

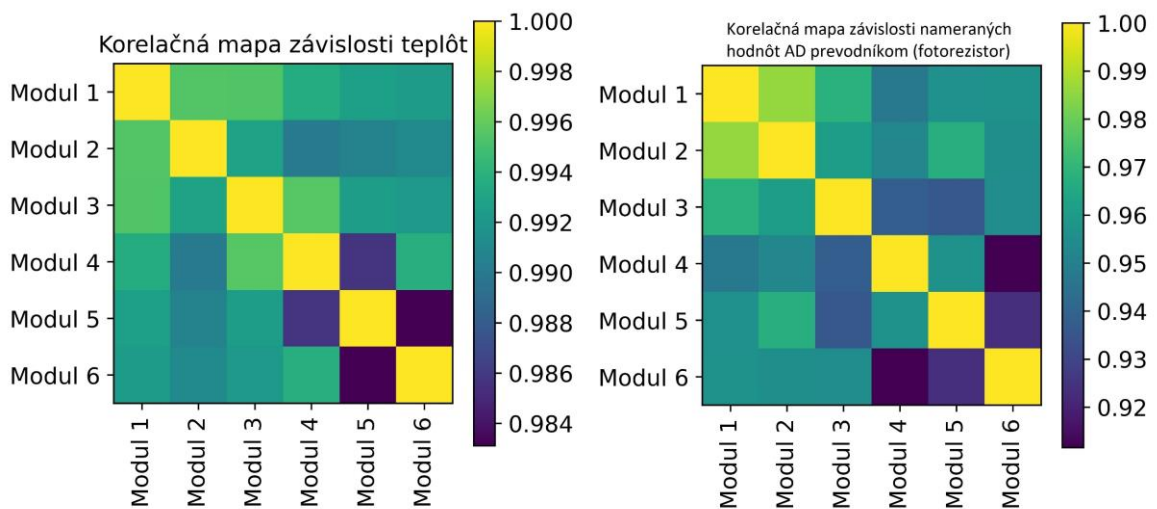
$$\text{kde } \overline{x^2} = \frac{1}{n} \sum_{i=1}^n x_i^2, \quad \overline{y^2} = \frac{1}{n} \sum_{i=1}^n y_i^2, \quad \overline{x \cdot y} = \frac{1}{n} \sum_{i=1}^n x_i \cdot y_i \quad (5.6)$$

Tento koeficient vyjadruje obojstrannú mieru lineárnej závislosti medzi veličinami X a Y , t. j. $r_{x,y} = r_{y,x} = r$. Môže nadobúdať hodnoty z intervalu $(-1; 1)$. Pomocou tohto koeficientu môžeme vyjadriť stupeň lineárnej korelačnej závislosti medzi danými

veličinami. Ak je hodnota tohto koeficientu nulová, tak lineárna závislosť medzi veličinami X a Y neexistuje. Medzi veličinami však môže existovať iná závislosť. V prípade, že absolútna hodnota Pearsonovho korelačného koeficientu nadobúda hodnotu 1 ($|r|=1$), tak závislosť veličín je presne lineárna a všetky body ležia priamo na regresnej priamke. Lineárna závislosť je tým silnejšia, čím je absolútna hodnota tohto koeficientu ($|r|$) bližšia k 1. Čím je táto hodnota bližšia k nule, tým je lineárna závislosť medzi veličinami menšia. Mieru lineárnej závislosti môžeme rozdeliť do troch základných skupín [105]:

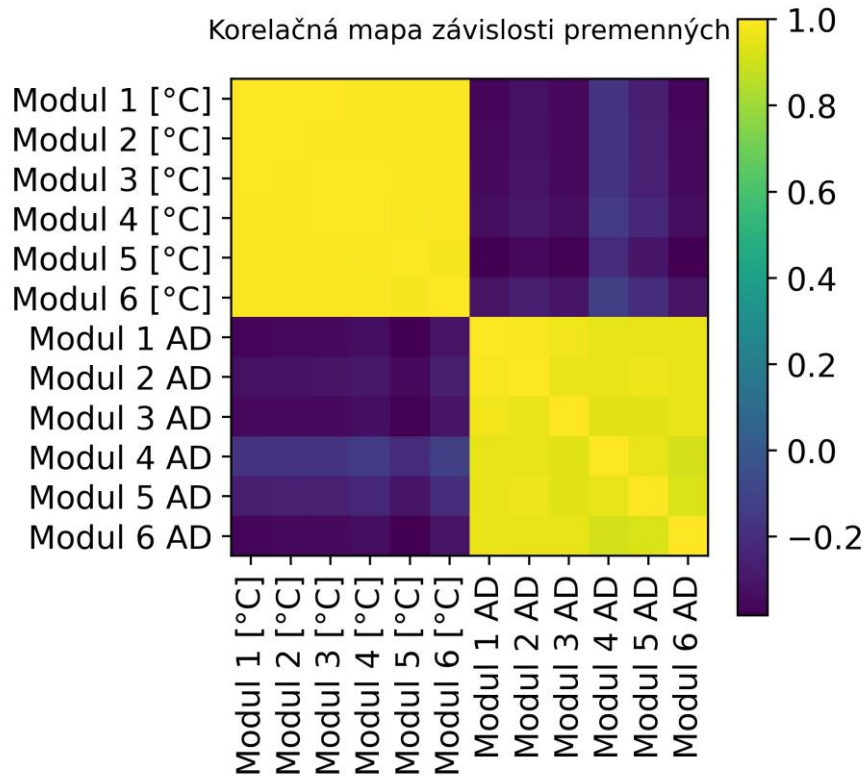
- Slabá závislosť: $0 < |r| \leq 0,3$,
- Mierna závislosť: $0,3 < |r| \leq 0,8$,
- Silná závislosť: $0,8 < |r| \leq 1$.

Aby sme zistili závislosť jednotlivých premenných, ktoré v našom prípade predstavujú merané veličiny v daných bodoch WSN, tak bolo potrebné vypočítať vyššie uvedený korelačný koeficient pre každú dvojicu bodov. Korelácia meraných veličín medzi uzlami v sieti je zobrazená na obrázku č. 38.



Obrázok 38 Korelácia meraných veličín medzi jednotlivými modulmi

Na výpočet korelácie boli použité namerané dáta zo zostaveného datasetu. Z uvedeného obrázka je zjavná pomerne silná závislosť medzi jednotlivými uzlami v sieti. Na obrázku č. 39 je zobrazená aj závislosť meraných veličín medzi sebou.



Obrázok 39 Korelácia meraných veličín

5.2.5 Vplyv typu vstupných dát

V tejto a nasledujúcej podkapitole sme sa zamerali na zostavenie univerzálneho modelu neurónovej siete, ktorý bude schopný odhadnúť teplotu v ľubovoľnom uzle WSN, len na základe meraní vo zvyšných bodoch. To znamená, že na odhad meranej veličiny v danom bode nebudú použité predchádzajúce skutočne namerané hodnoty v tomto bode. Takýto model môže byť využitý pri dlhodobom odhade napríklad v prípade kritickej úrovne batérií daného uzla, pri jeho výpadku, alebo dokonca jeho odstránení, za predpokladu, že parametre systému ostanú nezmenené.

V prvkom kroku sme rozdelili dataset na tréningovú a testovaciu množinu. Tréningovú množinu tvorili namerané dáta od augusta do decembra roku 2020. Dáta, ktoré boli namerané v decembri slúžili na testovanie a overenie výsledkov. Program bol písaný v skriptovacom jazyku Python s využitím TensorFlow a Keras frameworku v prostredí Google Colab.

Aby sme s daným datasetom mohli ďalej pracovať a použiť dáta v procese tréningu a testovania rôznych štruktúr neurónových sietí, bolo potrebné vykonať ďalšie predspracovanie dát. Nakoľko pracujeme so vstupnými hodnotami v rôznych rozsahoch (teplota a nameraná hodnota AD prevodníkom), tak je osvedčeným pravidlom

normalizovať dané hodnoty podľa príznakov. Neurónová sieť, by sa síce mohla prispôbiť týmto rôznorodým údajom, ale samotný proces učenia by bol zložitejší. Normalizácia hodnôt prebieha v dvoch krokoch. Pre každý vstupný príznak, ktorý je reprezentovaný jedným stĺpcom v datasete odpočítame od každej hodnoty priemer (\bar{x}) a následne delíme túto hodnotu smerodajnou odchýlkou (σ), podľa vzťahu: [106]

$$\hat{x}_i = \frac{x_i - \bar{x}}{\sigma} \quad (5.7)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}, \text{ kde } \bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (5.8)$$

Kde \hat{x}_i predstavuje normovanú hodnotu i -teho prvku v danom stĺpci. Toto riešenie nám zabezpečí centrovanie všetkých hodnôt okolo nuly a smerodajnú odchýlku rovnú jednej. Je dôležité, aby hodnoty (priemer a smerodajná odchýlka) pre normalizáciu testovacích dát boli vypočítané len z tréningovej množiny [106].

Taktiež je potrebné definovať vhodnú stratovú funkciu (loss function), ktorá reprezentuje mieru úspešnosti riešenej úlohy. V priebehu učenia neurónovej siete sa snažíme o minimalizáciu hodnôt tejto funkcie. Najbežnejšie stratové funkcie pre regresný problém sú priemerná absolútna chyba (MAE) a priemerná kvadratická chyba (MSE). V našom prípade sme sa rozhodli využiť MSE, ktorá predstavuje štvorec rozdielu medzi predikciou a cieľovou hodnotou.

Optimalizátor neurónovej siete určuje, ako bude sieť aktualizovaná (úpravy jednotlivých váh) na základe stratovej funkcie. Implementuje konkrétnu variantu zostupu stochastického gradientu. Vo všetkých prípadoch používame optimalizátor pod názvom Adam. Ten je rozšírením algoritmu zostupu stochastického gradientu a v poslednej dobe priniesol širšie uplatnenie pre aplikácie hlbokého učenia v počítačovom videní a spracovaní prirodzeného jazyka [106].

Pri regresnom probléme by neurónová sieť mala mať poslednú vrstvu s lineárnou aktivačnou funkciou ($f(x)=x$). Pri regresii je cieľom predikovať jednu alebo viac spojitéch veličín. Ak by sme použili napríklad sigmoidálnu aktivačnú funkciu na poslednej vrstve, tak by sa sieť mohla naučiť predikovať hodnoty medzi 0 a 1. Pri lineárnej aktivačnej funkcii sa môže neurónová sieť naučiť predikovať hodnoty v ľubovoľnom rozsahu. Nemôžeme zabudnúť na fakt, že výstup zo siete je v normalizovanom tvare. Na zistenie


skutočnej hodnoty je potrebné vykonať inverzný postup k normalizácii hodnôt, ktorý je popísaný vyššie.

Na základe predchádzajúcich experimentov a pomerne malého počtu uzlov vo WSN sme zostavili niekoľko jednoduchých modelov dopredných neurónových sietí (MLP). Vstup bol tvorený len súčasnými nameranými hodnotami vo zvyšných moduloch WSN. Ako ukážku uvádzame na porovnanie lineárny model (lineárna kombinácia vstupov) a doprednú plne prepojenú neurónovú sieť s tromi skrytými vrstvami. V každej vrstve sa nachádzalo 16 neurónov (MLP - 16,16,16,1). Na porovnanie výsledkov jednotlivých modelov sme vypočítali chyby predikcie modelu pre dané miesto WSN podľa vzťahov 5.1 až 5.4. V tabuľke č. 13 sú porovnané výsledky pre lineárny model (LM) a doprednú neurónovú sieť (NS) s tromi skrytými vrstvami.

Tabuľka 13 Porovnanie chýb predikcie jednotlivých modelov

Odhad	Priemerná absolútna chyba, [°C]		Stredná kvadratická chyba, [°C]		Smerodajná odchýlka (σ), [°C]	
	LM	NS	LM	NS	LM	NS
Modul 1	0,2459	0,3527	0,3641	0,5492	0,3590	0,5117
Modul 2	0,5265	0,4200	0,7951	0,6254	0,6806	0,6231
Modul 3	0,4563	0,4377	0,5712	0,7714	0,4803	0,7303
Modul 4	0,5450	0,4948	0,8056	0,6755	0,6475	0,6411
Modul 5	1,0567	0,5442	1,4501	0,9303	1,0052	0,9125
Modul 6	0,8884	0,6439	0,9946	0,7843	0,5563	0,5842
Priemer	0,6198	0,4822	0,8301	0,7227	0,6215	0,6672

Grafické znázornenie odhadov oboch modelov pre modul č. 5 počas vybraného dňa z testovacieho datasetu sa nachádza na obrázku č. 40. Namerané hodnoty zo všetkých modulov počas tohto dňa sú znázornené na obrázku č. 35.



Obrázok 40 Grafické znázornenie odhadu pre modul č. 5


Na základe porovnania výsledkov jednotlivých modelov možno usúdiť, že aj lineárnou kombináciou hodnôt sme dosiahli relatívne dobré výsledky. Je to spôsobené aj pomerne silnou lineárnou závislosťou meranej veličiny medzi jednotlivými uzlami vo WSN. Taktiež sme už mali k dispozícii omnoho rozsiahlejší dataset v porovnaní s experimentom č. 1. Lineárny model ale nedosahuje konzistentné výsledky. Pri odhade v niektorých uzloch WSN (modul 5, modul 6) dosahuje pomerne veľkú chybu. Z toho vyplýva, že nedokázal dostatočne zovšeobecniť daný problém pri odhade v ľubovoľnom zo šiestich bodov. Tu sa javí využitie neurónovej siete ako efektívnejšie.

V ďalšom kroku sme overili možnosť využitia tzv. časového okna na vstupe do neurónovej siete. To znamená, že vstup nepredstavujú len aktuálne namerané hodnoty, ale n posledných nameraných hodnôt vo zvyšných bodoch. Na základe prechádzajúcich experimentov, sme otestovali rôzne veľkosti siete a veľkosti okna (do dĺžky max 30 posledných hodnôt). V tabuľke č. 14 uvádzame najlepšie dosiahnuté výsledky daným modelom NS. Použili sme časové okno o veľkosti 30 a doprednú plne prepojenú sieť s tromi skrytými vrstvami. V každej skrytej vrstve sa nachádzalo 32 neurónov (MLP – 32, 32, 32, 1).

Tabuľka 14 Využitie časového okna (30) na vstupe - MLP 32, 32, 32, 1

Odhad	Priemerná absolútna chyba, [°C]	Stredná kvadratická chyba, [°C]	Smerodajná odchýlka (σ), [°C]
Modul 1	0.3192	0.4600	0.4469
Modul 2	0.4836	0.6621	0.6501
Modul 3	0.3292	0.4616	0.4546
Modul 4	0.4483	0.6315	0.6266
Modul 5	0.4986	0.8812	0.8217
Modul 6	0.4935	0.6204	0.5728
Priemer	0.4287	0.6195	0.5955

Ako možno vidieť, pridaním časového okna na vstup neurónovej siete sme dosiahli lepšie výsledky. Neurónová sieť má k dispozícii okrem aktuálnych meraní, aj najbližšiu históriu nameraných hodnôt zo zvyšných uzloch WSN. Tým, že má na vstupe k dispozícii viac informácií, ktoré ovplyvňujú výsledok sa nám podarilo zvýšiť presnosť samotného odhadu. Na obrázku č. 41 sa nachádza grafické znázornenie odhadu pre modul č. 5 počas vybraného dňa z testovacieho datasetu. Možno vidieť, že použitie časového okna na vstupe neurónovej siete malo za následok vyhladenie krivky odhadovanej teploty.




Obrázok 41 Grafické znázornenie odhadu pre modul č. 5 pri použití časového okna na vstupe

5.2.6 Využitie konvolučnej neurónovej siete

Konvolučné neurónové siete (CNN) predstavujú typ modelu hlbokého učenia, ktorý sa používa hlavne v aplikáciách počítačového videnia. Rovnaké vlastnosti vďaka ktorým CNN dosahujú dobré výsledky pri počítačovom videní a rozpoznávaní obrazu, sú vhodné aj pre spracovávanie sekvenčných dát. V tomto prípade je čas považovaný za priestorový rozmer, rovnako ako je výška alebo šírka v 2D obraze. Takéto 1D CNN môžu konkurovať rekurentným neurónovým sieťam pri riešení určitých úloh týkajúcich sa sekvenčného spracovania, obvykle pri podstatne menších výpočtových nárokoch.

Základným rozdielom medzi plne prepojenou vrstvou a konvolučnou vrstvou je fakt, že konvolučná vrstva sa učí lokálne vzory, zatiaľ čo plne prepojená vrstva sa učí globálne vzory v celom priestore vstupných príznakov. Operácia konvolúcie extrahuje z mapy vstupných príznakov rôzne oblasti, aplikuje na všetky tieto oblasti rovnakú transformáciu a vytvorí mapu výstupných príznakov. Výstupná hĺbka týchto príznakov je parametrom danej vrstvy a predstavuje počet filtrov, pomocou ktorých sa realizujú dané transformácie. Takéto 1D konvolučné vrstvy sú schopné rozpoznávať lokálne vzory v sekvenciách. Ukážka 1D konvolúcie sa nachádza na obrázku č. 42. Každý časový úsek výstupu je získaný z dočasnej oblasti vo vstupnej sekvencii [106].



Obrázok 42 Princíp 1D konvolúcie [106]

V praxi sa väčšinou po každej konvolučnej vrstve v sieti aplikuje vrstva združovania (pooling), ktorá má za úlohu zníženie počtu výstupných príznakov. Najčastejšie používané prístupy využívajú združovanie podľa maxima (max pooling) a združovanie podľa priemeru (average pooling). Využívajú sa pri tom extrahované okná zo vstupných príznakov s pevnou dĺžkou. Výstup predstavuje maximálnu alebo priemernú hodnotu z tohto okna. Takýmto spôsobom podvzorkujeme príznaky, čím zabezpečíme ich zníženie a súčasne vytvoríme hierarchiu filtrov takým spôsobom, že sa po sebe nasledujúce konvolučné vrstvy budú zameriavať na stále väčšie okná [106].

V našom prípade sme na základe predchádzajúceho experimentu ako vstup do siete zvolili rovnaké časové okno (30 posledných hodnôt). Otestovali sme viac rôznych modelov. Najlepšie výsledky sa nám podarilo dosiahnuť s nasledujúcou štruktúrou CNN. Použili sme 2 konvolučné vrstvy s 32 filtrami a veľkosťou konvolučného okna 5. Medzi týmito vrstvami sa nachádza vrstva združovania podľa maxima (max pooling) s veľkosťou okna 2. Za druhou konvolučnou vrstvou sa nachádza vrstva globálneho združovania podľa maxima (global max pooling 1D), za ktorou nasleduje plne prepojená vrstva s 32 neurónmi. Výstupná vrstva je tvorená jedným neurónom, tak ako v predchádzajúcich prípadoch. Chyby odhadu pre tento model konvolučnej neurónovej siete sa nachádzajú v tabuľke č. 15. Ako možno vidieť, dosiahli sme o trochu lepšie výsledky ako v predošlom experimente s využitím plne prepojenej doprednej neurónovej siete.

V tejto a predchádzajúcej podkapitole sme sa zamerali na návrh univerzálneho modelu neurónovej siete, ktorá bude schopná odhadnúť teplotu v ľubovoľnom uzle WSN

len na základe meraní vo zvyšných uzloch. Výhodou takejto implementácie je fakt, že nie je potrebných n (v našom prípade 6) neurónových sietí s rôznymi natrénovanými parametrami. Takýto návrh by značne komplikoval rozšíriteľnosť WSN siete o ďalšie koncové zariadenia. Ďalšia výhoda tohto návrhu spočíva v možnosti využitia odhadu v prípade výpadku ľubovoľného uzla, prípadne jeho úplného odstránenia.

Tabuľka 15 Chyby jednotlivých odhadov pri použití CNN

Odhad	Priemerná absolútna chyba, [°C]	Stredná kvadratická chyba, [°C]	Smerodajná odchýlka (σ), [°C]
Modul 1	0,2688	0,4085	0,4059
Modul 2	0,4719	0,7627	0,7423
Modul 3	0,3364	0,4613	0,4300
Modul 4	0,3751	0,4994	0,4940
Modul 5	0,4644	0,8410	0,7948
Modul 6	0,3574	0,5165	0,5157
Priemer	0,3790	0,5816	0,5638

5.3 Vyhodnotenie šetrenia energie

Možnosti šetrenia energie pre dáta z experimentu č. 2 sme hodnotili rovnako ako pre datasey UKCP18 a Kilimandžáro. Aby boli výsledky porovnateľné, museli sme namerané údaje prevzorkovať na vzorkovaciu frekvenciu 1 hodina. Pri testoch sme použili len údaje o nameranej teplote. Všetky uvedené výsledky predstavujú priemer z piatich simulácií. V prvom teste sme rozdelili moduly na dve množiny. Neurónová sieť predikovala teplotu v jednej skupine na základe nameraných hodnôt v druhej skupine. Testovali sme rôznu veľkosť jednotlivých skupín a rôznu veľkosť neurónovej siete. Výsledky sú uvedené v tabuľke č. 16.

Tabuľka 16 MSE pre rôzny počet snímaných a počítaných hodnôt

Rozdelenie bodov snímané : počítané (m : n)	Typ neurónovej siete		
	MLP 8,8,8,n	MLP 16,16,16,n	MLP 50,30,20,n
1:5	0,728	0,726	0,727
2:4	0,565	0,548	0,535
3:3	0,433	0,413	0,397
4:2	0,324	0,302	0,288
5:1	0,206	0,189	0,173

Podobne ako pri datasete Kilimandžáro je zrejmé, že chyba odhadu je menšia, ak je použitá neurónová sieť s vyšším počtom neurónov. Neplatí to len pre rozdelenie bodov v pomere 1:5, kedy dosahujú všetky siete rovnaké výsledky. Dosiahnutá presnosť je podstatne lepšia, než na Kilimandžáre a horšia než v prípade datasetu UKCP18. Porovnanie je potrebné brať s rezervou, keďže podmienky merania boli značne odlišné – líši sa počet bodov merania, ich vzájomná vzdialenosť a predovšetkým prostredie.

Ak požadujeme presnosť odhadu na úrovni 0,5 °C, môžeme si dovoliť vynechať len jedno meranie zo šiestich, čo predstavuje úsporu 20 %. Pre presnosť 1 °C bude úspora až 80 %. V oboch prípadoch na to stačí najjednoduchšia testovaná sieť MLP 8,8,8,n.

Aby bolo možné vyhodnotiť aj druhý spôsob šetrenia (vynechávanie prenosu údajov podľa chyby predikcie), musíme najskôr vyhodnotiť vplyv dĺžky okna na presnosť odhadu. V tabuľke č. 17 sú uvedené výsledky pre dve veľkosti neurónovej siete a rôzne veľkosti okna.

Tabuľka 17 MSE pre rôznu dĺžku okna a rôzne veľkosti neurónovej siete

Dĺžka okna	Typ neurónovej siete	
	MLP 8,8,8,1	MLP 24,16,8,1
10	0,248	0,403
12	0,249	0,324
14	0,236	0,293
16	0,251	0,312
18	0,272	0,298
20	0,246	0,389
22	0,255	0,319
24	0,233	0,345
26	0,232	0,369
28	0,267	0,395
30	0,207	0,442

Je zaujímavé, že menšia sieť dosiahla výrazne lepšie výsledky. Zároveň sa ukázalo, že pri nej na veľkosti okna až tak nezáleží. Výsledky väčšej siete boli viac závislé na veľkosti okna, pričom najmenšia chyba bola dosiahnutá pre veľkosť okna 14.

Z dôvodu lepšej porovnateľnosti výsledkov s datasetmi UKCP18 a Kilimandžáro sme sa rozhodli použiť rovnakú veľkosť neurónovej siete, MLP 24,16,8,1. Hodnotili sme schopnosť neurónovej siete predpovedať budúcu nameranú hodnotu. Ak je rozdiel predpovedanej a skutočnej hodnoty menší než vopred určená prahová hodnota, nameranú

hodnotu nie je potrebné prenášať do centra (šetríme energiu). V tabuľke č. 18 je uvedený počet prekročení dvoch prahových hodnôt: 0,5 °C a 1 °C. Celkový počet testovaných hodnôt bol 22000.

Tabuľka 18 Počet prekročení prahových hodnôt

Modul	1	2	3	4	5	6
Prah 0,5 °C	5029	5740	5349	5260	7021	4297
Prah 1 °C	1059	1815	1341	1134	3012	738

Pre prahovú hodnotu 0,5 °C je priemerný počet prekročení 5450, teda 24,7 %, čo predstavuje úsporu 75,3 %. Pre presnosť 1 °C bolo prekročení 1517 (6,9 %) a teda úspora je až 93,1 %. Najhoršie výsledky dosiahol pre obidve úrovne prahu modul 5 a najlepšie modul 6.

Podobne ako v prípade datasetu Kilimandžáro sa ukázalo, že podstatne viac energie je možné ušetriť na základe predpovedania budúcej hodnoty v každom module. Časová závislosť hodnôt meraných v tom istom bode je výraznejšia než priestorová závislosť medzi relatívne vzdialenými modulmi.

Záver

Hlavnou náplňou práce bola analýza vhodného typu a štruktúry neurónovej siete na odhad nemeraných parametrov prostredia, čo je využiteľné pri šetrení energie vo WSN. Z danej úlohy vyplynula potreba simulačných experimentov a taktiež overenie na WSN nasadenej do reálneho prostredia.

Bolo vykonaných viacero simulačných experimentov s využitím dostupných datasetov, ktoré obsahovali dáta simulovaných alebo reálne nameraných hodnôt teploty v danej lokalite za určité obdobie. V simuláciách boli otestované rôzne štruktúry neurónových sietí za účelom šetrenia energie v koncových zariadeniach WSN a odhadu daného parametra s určitou presnosťou.

S reálnymi experimentami bol spojený návrh bezdrôtovej senzorovej siete a vhodné rozmiestnenie jednotlivých modulov do prostredia. Vzhľadom na povahu meraných veličín (teplota, intenzita osvetlenia), energetické nároky WSN a vzdialenosť modulov od centrálného bodu v sieti bola zvolená komunikácia na báze LoRa technológie. Táto časť práce sa skladala z dvoch reálnych experimentov. Počas prvého experimentu sme overili na nameraných dátach možnosť využitia NS na riešenia zadanej úlohy. V tomto experimente sme sa zamerali na predikciu teploty len v jednom bode WSN a dáta boli získavané len pomerne krátky čas. Vzhľadom na to, že nasadená WSN disponovala nižšou spoľahlivosťou a získaný dataset nepokrýval potreby experimentu, bol navrhnutý a implementovaný druhý prototyp WSN. Druhý experiment bol spoľahlivejší a vychádzal z poznatkov prvého experimentu, komunikácia v sieti bola zabezpečená už pomocou protokolu LoRaWAN. WSN bola rozšírená z pôvodných 4 na 6 modulov a dáta boli zozbierané počas dlhšieho časového obdobia. Neurónová sieť mala v tomto prípade za úlohu odhadovať teplotu v ľubovoľnom uzle WSN, len na základe meraní v ostatných uzloch. Odhad hodnoty môže byť využitý napr. pri výpadku určitého uzla v sieti. Zamerali sme sa na čo najpresnejší odhad veličiny a zostrojenie univerzálneho modelu. V práci boli overené rôzne scenáre šetrenia energie na dostupných datasetoch aj na reálne nameraných dátach z druhého experimentu.

Návrh neurónovej siete vhodnej na odhad meranej veličiny v daných bodoch bezdrôtovej senzorickej siete, bol experimentálne overený na dostupných datasetoch aj na reálne nameraných dátach. Simulačné aj reálne experimenty boli vyhodnotené

a porovnané. Neurónová sieť by mala byť čo najjednoduchšia a zároveň efektívna pri plnení danej úlohy. Venovali sme sa najmä dopredným NS, nakoľko už pomerne jednoduchá sieť dokázala s dobrou presnosťou odhadovať požadovanú hodnotu. Otestované boli však aj iné štruktúry neurónových sietí.

Prínosmi práce sú najmä implementácia neurónovej siete, overenie vhodnosti nasadenia neurónovej siete v súvislosti so zadanou úlohou a návrh a realizácia bezdrôtovej siete senzorov, s čím súvisí zostavenie datasetu s reálne nameranými hodnotami. Ďalším z prínosov je aj overenie možnosti šetrenia energie v jednotlivých moduloch nasadených v reálnom prostredí. Vďaka využitiu NS na odhad hodnôt v danom uzle WSN v reálnom čase, je možné zmenšiť objem komunikácie modulu s centrálnym uzlom siete. V závislosti od požadovanej presnosti, môže byť úspora energie veľmi výrazná. V experimentálnej sieti sme dosiahli úsporu 75 % (presnosť 0,5 °C) a 93 % (presnosť 1 °C).

V priebehu návrhu reálnej WSN siete sme boli obmedzení hardvérovými prostriedkami, čo ovplyvnilo aj veľkosť siete, pokryté územie a typ meraných veličín. V budúcnosti je možné rozšíriť nasadenú WSN a tak pokryť väčšiu oblasť. Rozšíriteľnosť je možná za predpokladu, že bude zabezpečená časovo – priestorová závislosť medzi modulmi a meranými veličinami.

Zoznam použitej literatúry

- [1] Kurose, James F.-Ross, Keith W.: "*Počítačové sítě*", Brno: Computer Press, ISBN 978-80-251-3825-0, 2014.
- [2] Berger R. "*Introduction to Wireless Sensor Networks*", NI Technical Symposium, 2009.
- [3] D. Antolin, A. Bayo, N. Medrano, B. Calvo, S. Celma: "*WubiNet: A flexible WSN for applications in environmental monitoring*", Instrumentation and Measurement Technology Conference (I2MTC), 2012 IEEE International.
- [4] Harop, P.: "*Wireless Sensor Networks*", IDTechEx 2008.
- [5] K. Mikhaylov, J. Petaejaevaervi, T. Haenninen: "*Analysis of Capacity and Scalability of the LoRa Low Power Wide Area Network Technology*", European Wireless 2016.
- [6] Semtech Technology. [online]. Dostupné na: <https://www.semtech.com>.
- [7] Chong, C.-Y. & Kumar, S. P. (2003). "*Sensor networks: Evolution, opportunities, and challenges*", Proceedings of the IEEE 91(8): 1247–1256.
- [8] Myers, C., Oppenheim, A., Davis, R. & Dove, W. (1984). "*Knowledge-based speech analysis and enhancement*", Proc. of the International Conference on Acoustics, Speech and Signal Processing.
- [9] Ananya chatterjee, Manjusha Pandey, "*Practical Applications Of Wireless Sensor Network Based On Military, Environmental, Health And Home Applications: A Survey*", International Journal of Scientific & Engineering Research, Volume 5, Issue 1, January-2014 1043, ISSN 2229-5518.
- [10] O. M. Elfadil, "*Navigation algorithm for mobile robots using WSN*," 2013 International Conference on Computing, Electrical and Electronic Engineering (ICCEEE), Khartoum, 2013, pp. 254-259. DOI: 10.1109/ICCEEE.2013.6634000.
- [11] E. Suganya and S. Vijayashaarathi, "*Smart vehicle monitoring system for air pollution detection using WSN*," 2016 International Conference on Communication and Signal Processing (ICCSP), Melmaruvathur, 2016, pp. 0719-0722. DOI: 10.1109/ICCSP.2016.7754238.
- [12] T. O. Olasupo, "*Wireless Communication Modeling for the Deployment of Tiny IoT Devices in Rocky and Mountainous Environments*," in IEEE Sensors Letters, vol. 3, no. 7, pp. 1-4, July 2019, Art no. 6001204. DOI: 10.1109/LSSENS.2019.2918331.

- [13] C. V. Mahamuni, "A *military surveillance system based on wireless sensor networks with extended coverage life*", 2016 International Conference on Global Trends in Signal Processing, Information Computing and Communication (ICGTSPICC), Jalgaon, 2016, pp. 375-381. DOI: 10.1109/ICGTSPICC.2016.7955331.
- [14] M. P. Đurišić, Z. Tafa, G. Dimić and V. Milutinović, "A *survey of military applications of wireless sensor networks*," 2012 Mediterranean Conference on Embedded Computing (MECO), Bar, 2012, pp. 196-199.
- [15] D. C. Trancă et al., "*Industrial WSN node extension and measurement systems for air, water and environmental monitoring: IoT enabled environment monitoring using NI WSN nodes*," 2017 16th RoEduNet Conference: Networking in Education and Research (RoEduNet), Targu Mures, 2017, pp. 1-6. DOI: 10.1109/ROEDUNET.2017.8123750.
- [16] Martinez, Kirk, et al. "*Glacial environment monitoring using sensor networks*." Proceedings of the Workshop on Real-World Wireless Sensor Networks (REALWSN'05), Stockholm, Sweden. 2005.
- [17] I. Martin et al., "A *High-Resolution Sensor Network for Monitoring Glacier Dynamics*," in IEEE Sensors Journal, vol. 14, no. 11, pp. 3926-3931, Nov. 2014. DOI: 10.1109/JSEN.2014.2348534.
- [18] G. N. L. R. Teja, V. K. R. Harish, D. Nayeem Muddin Khan, R. B. Krishna, R. Singh and S. Chaudhary, "*Land Slide detection and monitoring system using wireless sensor networks (WSN)*," 2014 IEEE International Advance Computing Conference (IACC), Gurgaon, 2014, pp. 149-154. DOI: 10.1109/IAdCC.2014.6779310.
- [19] S. Molina, I. Soto and R. Carrasco, "*Detection of gases and collapses in underground mines using WSN*," 2011 IEEE International Conference on Industrial Technology, Auburn, AL, 2011, pp. 219-225. DOI: 10.1109/ICIT.2011.5754376.
- [20] S. M. Rajesh, "*Integration of Active RFID and WSN for real time low-cost data monitoring of patients in hospitals*," 2013 International Conference on Control, Automation, Robotics and Embedded Systems (CARE), Jabalpur, 2013, pp. 1-6. DOI: 10.1109/CARE.2013.6733768.
- [21] R. K. Megalingam, D. M. Kaimal and M. V. Ramesh, "*Efficient Patient Monitoring for Multiple Patients Using WSN*," 2012 International Conference on Advances in

- Mobile Network, Communication and Its Applications, Bangalore, 2012, pp. 87-90.
DOI: 10.1109/MNCApps.2012.23.
- [22] M. Wu and W. Huang, "*Health care platform with safety monitoring for long-term care institutions*," The 7th International Conference on Networked Computing and Advanced Information Management, Gyeongju, 2011, pp. 313-317.
- [23] D. Tianmin and S. Yao-yao, "*Design of the intelligent public transportation monitoring system based on WSN*," 2011 International Conference on Consumer Electronics, Communications and Networks (CECNet), XianNing, 2011, pp. 4024-4027. DOI: 10.1109/CECNET.2011.5768257.
- [24] P. Vuletić, "*Application of WSN in railway intelligent transportation system (RITS)*," 2015 23rd Telecommunications Forum Telfor (TELFOR), Belgrade, 2015, pp. 103-105. DOI: 10.1109/TELFOR.2015.7377424.
- [25] F. Losilla, A. J. García-Sánchez, F. García-Sánchez and J. García-Haro, "*On the role of wireless sensor networks in intelligent transportation systems*," 2012 14th International Conference on Transparent Optical Networks (ICTON), Coventry, 2012, pp. 1-4. DOI: 10.1109/ICTON.2012.6253846.
- [26] S. János and I. Matijevics, "*Implementation of potential field method for mobile robot navigation in greenhouse environment with WSN support*," IEEE 8th International Symposium on Intelligent Systems and Informatics, Subotica, 2010, pp. 319-323. DOI: 10.1109/SISY.2010.5647434.
- [27] H. D. Chinh, S. S. Shetty, M. Gupta and S. K. Panda, "*A wireless sensor and actuator network (WSAN) framework for personalized thermal comfort in office buildings*," 2016 IEEE International Conference on Sustainable Energy Technologies (ICSET), Hanoi, 2016, pp. 42-47. DOI: 10.1109/ICSET.2016.7811754.
- [28] S. Saadaoui, M. Tabaa, F. Monteiro, M. Chehaitly, A. Dandache and A. Oukaira, "*IWSN under an industrial wireless channel in the context of Industry 4.0*," 2017 29th International Conference on Microelectronics (ICM), Beirut, 2017, pp. 1-4. DOI: 10.1109/ICM.2017.8268861.
- [29] H. A. Salam and B. M. Khan, "*IWSN - Standards, Challenges and Future*," in IEEE Potentials, vol. 35, no. 2, pp. 9-16, March-April 2016. DOI: 10.1109/MPOT.2015.2422931.

- [30] C. Ma, Y. Wang and G. Ying, "*The Pig Breeding Management System Based on RFID and WSN*," 2011 Fourth International Conference on Information and Computing, Phuket Island, 2011, pp. 30-33. DOI: 10.1109/ICIC.2011.133.
- [31] Drozdová M., Mikuš Ľ., Palúch P.: "*Komunikačné technológie I*", Žilina: Žilinská univerzita, ISBN 978-80-554-0835-4, s. 34-40, 2014.
- [32] Reetesh Chandra "*Neural Networks: Applications in the Real World*", [online] Dostupné na: <https://www.upgrad.com/blog/neural-networks-applications-in-the-real-world/>.
- [33] Juan R.Rabunal and Julian Dorad, "*Artificial Neural Networks in Real-Life Applications*", University of Coruna, Spain, Idea Group Publishing 2006, ISBN 1-59140-904-7.
- [34] D. Marček, M. Marček: "*Neurónové siete a ich aplikácie*", Žilina, 2006, ISBN 80-8070-497-X, pp. 35-43.
- [35] Y. LeCun, K. Kavukcuoglu and C. Farabet, "*Convolutional networks and applications in vision*," Proceedings of 2010 IEEE International Symposium on Circuits and Systems, Paris, 2010, pp. 253-256. DOI: 10.1109/ISCAS.2010.5537907.
- [36] Christopher M.Bishop: "*Pattern Recognition and Machine Learning (Information Science and Statistics)* ", Springer, 2006, ISBN-13: 978-0387310732 .
- [37] A. Angelova, A. Krizhevsky and V. Vanhoucke, "*Pedestrian detection with a Large-Field-Of-View deep network*," 2015 IEEE International Conference on Robotics and Automation (ICRA), Seattle, WA, 2015, pp. 704-711. DOI: 10.1109/ICRA.2015.7139256.
- [38] J.K. Roy, Dola Gupta , Sanjay Goswami, "*An improved flood warning system using WSN and Artificial Neural Network*", 2012 Annual IEEE India Conference (INDICON), DOI: 10.1109/INDCON.2012.6420720.
- [39] D.F.Lekkas, C.Onof, M.T.Lee and E.A.Ballas; "*Application of Artificial Neural networks for flood forecasting*", Global Nest: The Int. J. vol 6, no.3, pp 205-211,2004.
- [40] Dong Nguyen, Canh Nguyen, Thuan Duong-Ba, Hung Nguyen, Anh Nguyen, Tuan Tran, "*Joint network coding and machine learning for error-prone wireless broadcast*", Computing and Communication Workshop and Conference (CCWC) 2017 IEEE 7th Annual, pp. 1-7, 2017.

- [41] Mohammad Abu Alsheikh ; Shaowei Lin ; Dusit Niyato ; Hwee-Pink Tan , "Machine Learning in Wireless Sensor Networks: Algorithms, Strategies, and Applications", IEEE Communications Surveys & Tutorials , Volume: 16 , Issue: 4 , Fourthquarter 2014, DOI: 10.1109/COMST.2014.2320099 , pp. 1996 – 2018.
- [42] Siamak Aram , Luca Mesin , Eros Pasero, "Improving lifetime in wireless sensor networks using neural data prediction“, 2014 World Symposium on Computer Applications & Research (WSCAR), DOI: 10.1109/WSCAR.2014.6916791.
- [43] C. B. Vinutha, N. Nalini, B. S. Veeresh, "Energy efficient wireless sensor network using neural network based smart sampling and reliable routing protocol", 2017 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET), DOI: 10.1109/WiSPNET.2017.8300128.
- [44] G. Serpen, J. Li, L. Liu, "AI-WSN: Adaptative and Intelligent Wireless Sensor Network", Procedia Computer Science, Vol. 20, 2013, pp. 406-413.
- [45] Gursel Serpen, Jiakai Li, Linqian Liu, Zhenning Gao, "WSN-ANN: Parallel and distributed neurocomputing with wireless sensor networks“, The 2013 International Joint Conference on Neural Networks (IJCNN), DOI: 10.1109/IJCNN.2013.6706764.
- [46] Wen-Tsai Sung ; Yu-Feng Liu ; Jui-Ho Chen ; Chia-Hao Chen, "Enhance the efficient of WSN data fusion by neural networks training process", 2010 International Symposium on Computer, Communication, Control and Automation (3CA), DOI: 10.1109/3CA.2010.5533439.
- [47] Kvasnička V., Beňušková Ľ., Pospíchal J., Farkaš I., Tiňo P., Kráľ A., "Úvod do teórie neurónových sietí", Iris 1997, ISBN 8088778301.
- [48] Sinčák P., Andrejková G., "Neurónové siete Inžiniersky prístup", Univerzita P.J. Šafárika Košice, 1996.
- [49] I. Sutskever and G. E. Hinton, "Deep, Narrow Sigmoid Belief Networks Are Universal Approximators", in Neural Computation, vol. 20, no. 11, pp. 2629-2636, Nov. 2008. DOI: 10.1162/neco.2008.12-07-661.
- [50] Mohit Sewak, Md.Rezaul Karim, Pradeep Pujari, "Practical Convolutional Neural Networks: Implement advanced deep learning models using Python", Packt Publishing, 2018, ISBN 978-1-78839-230-3.
- [51] P. Langley, H. A. Simon, "Applications of machine learning and rule induction", Commun. ACM, vol. 38, no. 11, pp. 54-64, Nov. 1995.

- [52] M. A. Nielsen, "*Neural Networks and Deep Learning*", Editor, Determination Press, 2015. Online: <http://neuralnetworksanddeeplearning.com/>.
- [53] Návrat P., Beňušková Ľ., Bieliková M., Kapustník I., Kosková G., Pospíchal J., "*Umelá inteligencia*", Slovenská technická univerzita v Bratislave, 2015. ISBN 978-80-227-4344-0.
- [54] Ian Goodfellow, Yoshua Bengio, Aaron Courville, "*Deep Learning*", MIT Press, 2016, Online: <http://www.deeplearningbook.org/>.
- [55] Yann LeCun, Yoshua Bengio, Geoffrey Hinton, "*Deep learning*", Nature Publishing Group, 2015.
- [56] Panos Louridas, Christof Ebert, "*Machine Learning*", IEEE Software, vol. 33, pp. 110-115, 2016.
- [57] F. Adamo, F. Attivissimo, C. G. C. Carducci and A. M. L. Lanzolla, "*A smart sensor network for sea water quality monitoring*", IEEE Sensors J., vol. 15, no. 5, pp. 2514-2522, May 2015.
- [58] Z. G. Wan, Y. K. Tan and C. Yuen, "*Review on energy harvesting and energy management for sustainable wireless sensor networks*", 2011 IEEE 13th International Conference on Communication Technology, pp. 362-367, 2011.
- [59] F. Attivissimo, A. Di Nisio, A.M.L Lanzolla and M. Paul, "*Feasibility of a photovoltaic-thermoelectric generator: performance analysis and simulation results*", IEEE Trans. on Instr. & Meas., vol. 64, no. 5, pp. 1158-1169, May 2015.
- [60] F. Attivissimo, A. Di Nisio, C. G. C. Carducci and M. Spadavecchia, "*Fast Thermal Characterization of Thermoelectric Modules Using Infrared Camera*", IEEE Trans. on Instr. & Meas., vol. 66, no. 2, pp. 305-314, Feb. 2017.
- [61] M. Dhimi, V. Garg and N. S. Randhawa, "*Enhanced Lifetime with Less Energy Consumption in WSN using Genetic Algorithm Based Approach*," 2018 IEEE 9th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON), Vancouver, BC, 2018, pp. 865-870, DOI: 10.1109/IEMCON.2018.8614754.
- [62] M. Abderrahim, H. Hakim, H. Boujemaa and F. Touati, "*Energy-Efficient Transmission Technique based on Dijkstra Algorithm for decreasing energy consumption in WSNs*," 2019 19th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA), Sousse, Tunisia, 2019, pp. 599-604, DOI: 10.1109/STA.2019.8717210.

- [63] HOPERF ELECTRONIC, 2016. RFM95/96/97/98(W) – "Low Power Long Range Transceiver Module V1.0" [online]. 2016. Dostupné na: http://www.hoperf.com/upload/rf/RFM95_96_97_98W.pdf.
- [64] PEREŠÍNI, O., 2016. IoT, "LoRa a iné mobilné komunikačné technológie budúcnosti" [online]. 2016. Dostupné na: <http://www2.fiit.stuba.sk/~tkraj/IoT.LoRa&technologie.pdf>.
- [65] LORA ALLIANCE. "What is LoRaWAN" [online]. Dostupné na: <https://loralliance.org/sites/default/files/2018-04/what-is-lorawan.pdf>.
- [66] GEMALTO, ACTILITY a SEMTECH. "LoRaWAN Security" [online]. 2017. Dostupné na: https://loralliance.org/sites/default/files/2019-05/lorawan_security_whitepaper.pdf.
- [67] LORA ALLIANCE. "LoRaWAN Is Secure (but Implementation Matters)" [online]. Dostupné na: https://loralliance.org/resource_hub/lorawan-is-secure-but-implementation-matters/.
- [68] The Things Industries. "Dokumentácia k Things Network Stack V2". [online] Dostupné na: <https://www.thethingsnetwork.org/docs/lorawan/index.html>.
- [69] Tomić, Ivana & Bhatia, Laksh & Breza, Michael & McCann, Julie. "The Limits of LoRaWAN in Event-Triggered Wireless Networked Control Systems", 2018 UKACC 12th International Conference on Control (CONTROL), 2018, DOI: 10.1109/CONTROL.2018.8516774.
- [70] U. Thissen, R. van Brakel, A.P. de Weijer, W.J. Melssen, L.M.C. Buydens. "Using support vector machines for time series prediction", Chemometrics and Intelligent Laboratory Systems, Volume 69, Issues 1–2, 2003, pp. 35-49, ISSN 0169-7439, DOI:10.1016/S0169-7439(03)00111-4.
- [71] E.M. Azoff, "Neural network time series forecasting of financial markets (1st ed) ", Wiley, New York (1994).
- [72] Yao Qin, Dongjin Song, Haifeng Chen, Wei Cheng, Guofei Jiang, Garrison Cottrell. "A Dual-Stage Attention-Based Recurrent Neural Network for Time Series Prediction", 2017, arXiv:1704.02971.
- [73] Salehinejad, H., & Rahnamayan, S. "Customer shopping pattern prediction: A recurrent neural network approach". In 2016 IEEE Symposium Series on Computational Intelligence (SSCI), 2016 (pp. 1-6). IEEE.

- [74] Zheng, W., Lee, D. H., & Shi, Q. "*Short-term freeway traffic flow prediction: Bayesian combined neural network approach*". Journal of transportation engineering, 2006, 132(2), 114-121.
- [75] Mahmoud Zenzami. "*Flow forecasts in a non-perennial river of an arid basin using neural networks*". Journal of Applied Water Engineering and Research 4:2, pages 92-101, 2016.
- [76] Kizilaslan, R., & Karlik, B. "*Combination of neural networks forecasting for monthly natural gas consumption prediction*". International Journal on Neural and Mass - Parallel Computing and Information Systems, Neural Network World, 2009, 19(2), 191-199.
- [77] Petsche, T., Marcantonio, A., Darken, C., Hanson, S., Kuhn, G., & Santoso, N. "*A neural network autoassociator for induction motor failure prediction*". Advances in neural information processing systems, 1995, 8, 924-930.
- [78] Nauman Ahad, Junaid Qadir, Nasir Ahsan. "*Neural networks in wireless networks: Techniques, applications and guidelines*". Journal of Network and Computer Applications, Volume 68, 2016, pp. 1-27, ISSN 1084-8045, DOI: 10.1016/j.jnca.2016.04.006.
- [79] A. Payal, C. S. Rai and B. V. R. Reddy. "*Artificial Neural Networks for developing localization framework in Wireless Sensor Networks*". 2014 International Conference on Data Mining and Intelligent Computing (ICDMIC), Delhi, India, 2014, pp. 1-6, DOI: 10.1109/ICDMIC.2014.6954228.
- [80] S. R. Jondhale and R. S. Deshpande, "*Kalman Filtering Framework-Based Real Time Target Tracking in Wireless Sensor Networks Using Generalized Regression Neural Networks*". IEEE Sensors Journal, vol. 19, no. 1, pp. 224-233, 1 Jan.1, 2019, DOI: 10.1109/JSEN.2018.2873357.
- [81] Yongliang Sun, Xuzhao Zhang, Xiaocheng Wang, Xinggan Zhang. "*Device-Free Wireless Localization Using Artificial Neural Networks in Wireless Sensor Networks*". Wireless Communications and Mobile Computing, vol. 2018, Article ID 4201367, 8 pages, 2018. DOI: 10.1155/2018/4201367.
- [82] Rayoth Kumsawat, Kitti Attakitmongcol and Arthit Srikaew. "*A New Optimum Signal Compression Algorithm Based on Discrete Wavelet Transform and Neural Networks for WSN*". IAENG Transactions on Engineering Sciences, pp. 118-131, 2016, DOI: 10.1142/9789813142725_0010.

- [83] Fereshteh Khorasani and Hamid Reza Naji. "*Energy efficient data aggregation in wireless sensor networks using neural networks*". International Journal of Sensor Networks, 2017, 24:1, pp. 26-42, ISSN: 1748-1287, DOI: 10.1504/IJSNET.2017.084207.
- [84] Enami N., Moghadam R.A., Haghghat A. "*A Survey on Application of Neural Networks in Energy Conservation of Wireless Sensor Networks*". Recent Trends in Wireless and Mobile Networks. WiMo 2010. Communications in Computer and Information Science, vol 84. Springer, Berlin, Heidelberg. DOI:10.1007/978-3-642-14171-3_24.
- [85] Srivastava, Gautam et al.. "*Two-stage Data Encryption Using Chaotic Neural Networks*". Journal of Intelligent & Fuzzy Systems, vol. 38, no. 3, pp. 2561-2568, 2020, DOI: 10.3233/JIFS-179543.
- [86] M. Mamdouh, M. A. I. Elrukhsi and A. Khattab. "*Securing the Internet of Things and Wireless Sensor Networks via Machine Learning: A Survey*". 2018 International Conference on Computer and Applications (ICCA), Beirut, Lebanon, 2018, pp. 215-218, DOI: 10.1109/COMAPP.2018.8460440.
- [87] T. Luo and S. G. Nagarajan. "*Distributed Anomaly Detection Using Autoencoder Neural Networks in WSN for IoT*". 2018 IEEE International Conference on Communications (ICC), Kansas City, MO, USA, 2018, pp. 1-6, DOI: 10.1109/ICC.2018.8422402.
- [88] Swain, R.R., Khilar, P.M. "*Composite Fault Diagnosis in Wireless Sensor Networks Using Neural Networks*". Wireless Pers Commun 95, 2507–2548 (2017). DOI: 10.1007/s11277-016-3931-3.
- [89] A. I. Moustapha and R. R. Selmic, "*Wireless Sensor Network Modeling Using Modified Recurrent Neural Networks: Application to Fault Detection*". IEEE Transactions on Instrumentation and Measurement, vol. 57, no. 5, pp. 981-988, May 2008, DOI: 10.1109/TIM.2007.913803.
- [90] Mohit Mittal, Krishan Kumar. "*Quality of Services Provisioning in Wireless Sensor Networks using Artificial Neural Network: A Survey*". International Journal of Computer Applications (0975 –8887), Volume 117, No. 5, May 2015.
- [91] P. Mitra et al.. "*Flood forecasting using Internet of things and artificial neural networks*". 2016 IEEE 7th Annual Information Technology, Electronics and Mobile

- Communication Conference (IEMCON), Vancouver, BC, Canada, 2016, pp. 1-5, DOI: 10.1109/IEMCON.2016.7746363.
- [92] G. Furquim et al.. "*Combining Wireless Sensor Networks and Machine Learning for Flash Flood Nowcasting*". 2014 28th International Conference on Advanced Information Networking and Applications Workshops, Victoria, BC, Canada, 2014, pp. 67-72, DOI: 10.1109/WAINA.2014.21.
- [93] Juan Colonna, Tanel Peet, Carlos Abreu Ferreira, Alípio M. Jorge, Elsa Ferreira Gomes, and Joao Gama. "*Automatic Classification of Anuran Sounds Using Convolutional Neural Networks*". In Proceedings of the Ninth International C* Conference on Computer Science & Software Engineering (C3S2E '16), 2016, Association for Computing Machinery, New York, NY, USA, 73–78. DOI: 10.1145/2948992.2949016.
- [94] Avci O., Abdeljaber O., Kiranyaz S., Inman D. "*Convolutional Neural Networks for Real-Time and Wireless Damage Detection*". Pakzad S. (eds) Dynamics of Civil Structures, Volume 2. Conference Proceedings of the Society for Experimental Mechanics Series. Springer, Cham, 2020 DOI: 10.1007/978-3-030-12115-0_17.
- [95] John W. Barron, Azzam I. Moustapha, Rastko R. Selmic . "*Real-Time Implementation of Fault Detection in Wireless Sensor Networks Using Neural Networks*". Fifth International Conference on Information Technology: New Generations (itng 2008), DOI: 10.1109/ITNG.2008.187.
- [96] S. Anand, Keetha Manjari.R.K. "*FPGA implementation of artificial Neural Network for forest fire detection in wireless Sensor Network*". 2017 2nd International Conference on Computing and Communications Technologies (ICCCT), DOI: 10.1109/ICCCT2.2017.7972284.
- [97] Frank, R.J., Davey, N. & Hunt, S.P. "*Time Series Prediction and Neural Networks*". Journal of Intelligent and Robotic Systems 31, 91–103 (2001). DOI: 10.1023/A:1012074215150.
- [98] Shannon, C. E.. "*Communication in the presence of noise*". Proceedings of the Institute of Radio Engineers, January 1949, 37 (1): 10–21. DOI: 10.1109/jrproc.1949.232969.
- [99] Ababarnel, H. D. I., Brown, R., Sidorowich, J. L., and Tsimring, L. S.. "*The analysis of observed chaotic data in physical systems*". Rev. Modern Phys. 65(4) (1993), 1331–1392.

- [100] Pepin, N.. "*Hourly climate data from 23 stations on Kilimanjaro (East Africa) over three years - Version 1.0*". Centre for Environmental Data Analysis, 09 February 2016. DOI: 10.5285/10ca2f67-1da5-4d4f-854b-dd2895846edb.
- [101] Met Office Hadley Centre (2019). "*UKCP Local Projections on a 5km grid over the UK for 1980-2080*". Centre for Environmental Data Analysis, [online] Dostupné na :
<https://catalogue.ceda.ac.uk/uuid/e304987739e04cdc960598fa5e4439d0>.
- [102] ChirpStack. "*ChirpStack open-source LoRaWAN Network Server Stack*". [online] Dostupné na : <https://www.chirpstack.io/>.
- [103] Node-RED. "*Low-code programming for event-driven application*". [online] Dostupné na : <https://nodered.org/>.
- [104] Ostertagová, E.. "*Aplikovaná štatistika*". Equilibria, Košice, 2013, 218 s., ISBN 978-80-8143-067-1.
- [105] Ostertagová, E.. "*Pravdepodobnosť a matematická štatistika v príkladoch*". Elfa, Košice, 2005, 123 s., ISBN 80-8086-005-X.
- [106] CHOLLET, François. "*Deep learning v jazyku Python: knihovny Keras, Tensorflow*". Praha: Grada Publishing, 2019, 328 s. Knihovna programátora. ISBN 9788024731001.

Zoznam príloh

Príloha A Zoznam vlastných publikácií

Príloha B Obsah DVD

Prílohy

Príloha A: Zoznam vlastných publikácií

- [1] *Reducing number of nodes in WSN with neural network usage.* Lukáš Formanek, Ondrej Karpiš, Veronika Olešnaníková. In: The fourth international conference on Intelligent computing in data sciences [electronic]. - 1. vyd. - Danvers: Institute of Electrical and Electronics Engineers, 2020. - ISBN 978-1-7281-8084-7. - s. [1-4].
- [2] *Leaming Lorenz attractor differential equations using neural network.* Lukáš Formanek, Ondrej Karpiš. In: 5th South-East Europe Design Automation, Computer Engineering, Computer Networks and Social Media Conference [print, electronic]. - 1. vyd. - Washington: Institute of Electrical and Electronics Engineers, 2020. - ISBN 978-1-7281-6444-1. - s. 80-83.
- [3] *Dynamic system parameter identification based on the acceleration data* [electronic] / P. Šarafin, L. Formanek, M. Chochul. In: ICETA 2020 [electronic] : 18th IEEE International conference on emerging elearning technologies and applications : Information and communication technologies in learning : proceedings. - 1. vyd. - Denver: Institute of Electrical and Electronics Engineers, 2020. - ISBN 978-0-7381-2366-0. - s. [1-4] [online].
- [4] *Y robot extension module for educational and marketing purposes* [electronic] / L. Formanek, O. Karpiš. In: ICETA 2020 [electronic] : 18th IEEE International conference on emerging elearning technologies and applications : Information and communication technologies in learning : proceedings. - 1. vyd. - Denver: Institute of Electrical and Electronics Engineers, 2020. - ISBN 978-0-7381-2366-0. - s. [1-5] [online].
- [5] *Prediction of temperature in WSN using artificial intelligence.* L. Formanek, M. Chochul, O. Karpiš. In: Sensors and electronic instrumentation advances [electronic] : proceedings of the 5th international conference on sensors and electronic instrumentation advances. - 1. vyd. - Barcelona: IFSA Publishing, 2019. - ISBN 978-84-09-14413-6. - s. 126-129.

- [6] *Compressed Sensing and Acoustic Analysis for Use in Localization Tasks*. V. Olešnaníková, O. Karpiš, P. Šarařin, L. Formanek, M. Chochul. In: *Sensors and electronic instrumentation advances [electronic] : proceedings of the 5th international conference on sensors and electronic instrumentation advances*. - 1. vyd. - Barcelona: IFSA Publishing, 2019. - ISBN 978-84-09-14413-6. - s. 333-338.
- [7] *Prediction of chaotic dynamical system using artificial neural network*. Lukáš Formanek. In: *Mathematics in science and technologies : proceedings of the MIST conference 2019*. - [S.l.]: [s.n.]. - ISBN 9781794002180. - s. 22-27.
- [8] *Yrobot's extended world guide*. Juraj Miček, Michal Hodoň, Lukáš Formanek, Silvia Jurčíková, Veronika Olešnaníková, Peter Šarařin, Róbert Žalman. - 1. vyd. - Žilina : Žilinská univerzita v Žiline, 2018. - 204 s. ISBN 978-80-554-1531-4.
- [9] *Sprievodca po rozšírenom svete Yrobota*. Juraj Miček ... [et al.] : Michal Hodoň, Lukáš Formanek, Silvia Jurčíková, Veronika Olešnaníková, Peter Šarařin, Róbert Žalman. - 1. vyd. - V Žiline : EDIS-vydavateľské centrum ŽU, 2017. - 214 s., ilustr. - ISBN 978-80-554-1314-3.

Príloha B: Obsah DVD

Priložené DVD obsahuje:

- Práca v elektronickej podobe (formát PDF)
- Programové vybavenie
- Namerané dáta