

**ŽILINSKÁ UNIVERZITA V ŽILINE**

---

**AUTOREFERÁT  
DIZERTAČNEJ PRÁCE**

---

**Žilina apríl 2021**

**Ing. Lukáš Formanek**

**Žilinská univerzita v Žiline**  
**Fakulta riadenia a informatiky**

**Ing. Lukáš Fornamek**

Autoreferát dizertačnej práce

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

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

v študijnom odbore:  
**informatika**

Žilina apríl 2021

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

**Predkladateľ:** Ing. Lukáš Formanek  
Katedra technickej kybernetiky  
Fakulta riadenia a informatiky  
Žilinská univerzita v Žiline

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

**Oponent:** doc. Ing. Juraj Ždánsky, PhD.  
Katedra riadiacich a informačných systémov  
Fakulta elektrotechniky a informačných technológií  
Žilinská univerzita v Žiline

**Oponent:** prof. Ing. Ivan Sekaj, PhD.  
Ústav robotiky a kybernetiky  
Fakulta elektrotechniky a informatiky  
Slovenská technická univerzita v Bratislave

**Autoreferát bol rozoslaný dňa: .....**

Obhajoba dizertačnej práce sa koná dňa 18.08.2021 o 12:30 h. pred komisiou pre obhajobu dizertačnej práce schválenou pracovnou skupinou odborovej komisie v študijnom odbore **informatika v študijnom programe aplikovaná informatika**, vymenovanou dekanom Fakulty riadenia a informatiky Žilinskej univerzity v Žiline dňa .....

**prof. Ing. Karol Matiaško, PhD.**  
predseda pracovnej skupiny odborovej komisie  
v študijnom odbore **informatika**  
v študijnom programe **aplikovaná informatika**

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

## Abstrakt

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

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.

## 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.

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]. 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.

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 navrhnutej 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. 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 územia 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, aplikácie IoT v súvislosti s monitorovaním a ovládaním mŕtinových polí, detekciu nukleárnych, biologických a chemických útokov a mnohé ďalšie [14].

Monitorovanie prostredia patrí dnes snáď medzi najčastejšie aplikácie bezdrôtových sietí senzorov [15]. Ako najčastejšie aplikácie je možné uviesť monitorovanie pohybu ťažiacov [16], [17], monitorovanie a ochrana lesa pred požiarimi, nepovoleným výrubom, pytlíkmi, varovné systémy pred záplavami a ďalšími prírodnými katastrofami [18], [19], sledovanie zmien mikroklimy, 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.

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].

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 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. 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), polom programovateľných hradíel (FPGA), zákazníckym 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.

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.

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.

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.

### **1.3 Spotreba energie WSN**

Hlavné obmedzenia vo WSN predstavujú v súčasnosti zdroje energie. 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 zobúdz 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.

#### **1.3.1 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. Pri vysoko-energetických moduloch, môže spotreba senzora prevýšiť aj spotrebu energie potrebnú na komunikáciu modulu, ktorá býva zvyčajne energeticky najnáročnejšia.

#### **1.3.2 Komunikačný podsystem**

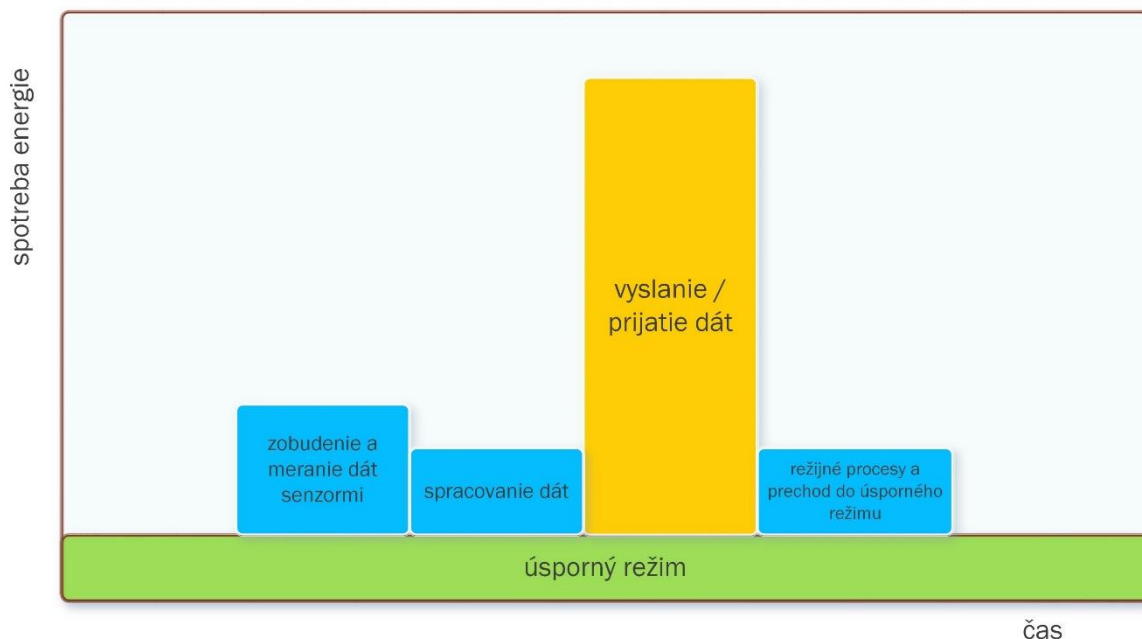
Komunikácia v rámci bezdrôtovej siete má zvyčajne najvyššiu spotrebu z celého WSN systému. Spotreba energie pri vysielaní požadovaných správ je oproti ostatným procesom, ktoré prebiehajú v rámci jedného WSN modulu spravidla najvýraznejšia, čo je ilustrované na obrázku č. 1. Množstvo energie potrebnej 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 1 Vplyv komunikácie na energetickú náročnosť modulu**

## 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]. Aplikčné 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 .

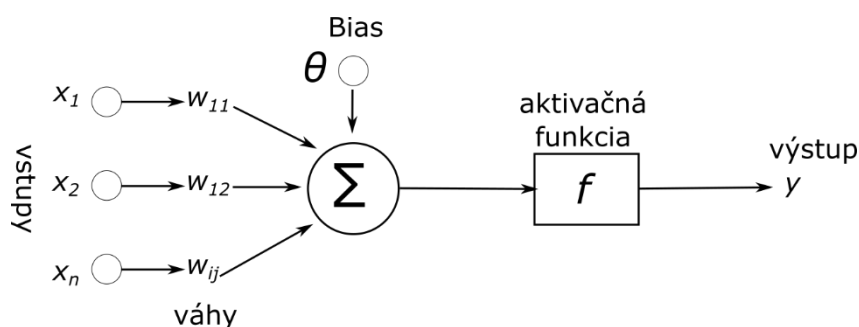
## 2.1 Využitie neurónových sietí

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. 2.



**Obrázok 2 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  $\theta$ ,
- 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.

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.

### 2.3 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  $l$ , ktorá je tvorená vstupnými vektormi  $\mathbf{A}_{train} = \{\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^p, \dots, \mathbf{x}^P\}$ .

$$\text{Pre } \forall \varepsilon > 0 \exists \text{ taká funkcia } G(\mathbf{x}) = f\left(\sum_{j=1}^J w_j f\left(\sum_{i=1}^l v_{ji} x_i\right)\right) \quad (2.1)$$

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 spojitú funkciu  $F: \mathfrak{R}^n \rightarrow (0,1)$ , ktorá je definovaná nad konečnou množinou  $\mathbf{A}_{train}$ , pričom platí [53]:

$$\sum_{p=1}^P |F(\mathbf{x}^p) - G(\mathbf{x}^p)| < \varepsilon \quad (2.2)$$

Z uvedeného vzťahu môžeme povedať, že funkcia  $G$  aproximuje funkciu  $F$  nad tréningovou množinou s presnosťou  $\varepsilon$ . 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:

$$E_p = \frac{1}{2} \sum_{k=1}^K (d_{pk} - o_{pk})^2 \quad (2.3)$$


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].

Tréningom siete upravujeme váhy, ktoré predstavujú zároveň koeficienty funkcie  $G$ , ktorú neurónová sieť aproximuje pomocou daných bodov tréningovej množiny. Táto skutočnosť je zobrazená na obrázku č. 3. Cieľom je extrapolácia funkčných hodnôt mimo  $\mathbf{A}_{train}$  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 tréningovú ( $\mathbf{A}_{train}$ ) a testovaciu ( $\mathbf{A}_{test}$ ) množinu. Toto rozdelenie je zobrazené na obrázku č. 3 ako plné a prázdne krúžky. Testovacia množina sa nazýva aj validačná množina. Pomocou  $\mathbf{A}_{train}$  sú modifikované váhy a pomocou  $\mathbf{A}_{test}$  zisťujeme chybu zovšeobecňovania. Pracujeme s kumulovanou chybou  $E$ , ktorá je definovaná nasledovne [53]:

$$E = \sum_{p=1}^P E_p \quad (2.4)$$

Dôležité je správne rozdelenie dát na tréningovú a testovaciu množinu. Tréningová množina ( $A_{train}$ ) by mala rovnomerne pokrývať daný interval. Zistilo sa, že v priebehu tréningu kumulovaná chyba  $E_{train}$  stále klesá, zatiaľ čo  $E_{test}$  začne od určitého momentu rásť. Táto skutočnosť je zobrazená na obrázku č. 3. Tento jav sa nazýva preučenie neurónovej siete alebo pretrénovanie či premodelovanie dát.



**Obrázok 3 Aproximácia funkcie pomocou NS a vývoj chyby počas tréningu [53]**

Ak nepoznáme dopredu  $\epsilon$  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 tréningovej 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 viacvrstvá dopredná neurónová sieť sa učí asociovať vstupné vektory  $x^p$  s výstupnými vektormi  $d^p$ . 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].

### 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.

Predikovanie budúcich hodnôt časových radov je jednou z najčastejších oblastí použitia neurónových sietí. Používa sa v oblasti finančnictva (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. Pri riešení tejto zložitej úlohy sa v súčasnosti stále viac využívajú prostriedky umelej inteligencie. 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.

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.

Jednou z najdôležitejších vlastností dobrej WSN siete je energetická efektívnosť, hlavne pri napájaní uzlov siete batériami. 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.

### 3.2 Teoretické východiská experimentov

Náplňou tejto práce je odhad nameraných 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. 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, CO<sub>2</sub>, plyn a pod.).
- **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.

### 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.
- Neurónová sieť je implementovaná priamo v uzle WSN siete.
- Neurónová sieť je zabudovaná do bezdrôtovej senzorickej siete – každý uzol predstavuje jeden alebo viac neurónov.

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. 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). 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 navrhutej 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).

### 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.

## 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 datasey

Základným predpokladom vierohodnej simulácie sú kvalitné vstupné dáta - dataset. V našom prípade potrebujeme dáta z niekoľkých desiatok snímačov s relatívne krátkou periódou vzorkovania, pričom snímanie by malo prebiehať čo najdlhší čas. Jediný dataset s reálnymi dátami, ktorý približne vyhovuje našim požiadavkám, obsahuje hodinové záznamy teploty z 23 staníc umiestnených na Kilimandžáre [100]. Teploty boli snímané počas obdobia troch rokov. 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.

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. 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. Perióda vzorkovania je 1 hodina a priestorové rozlíšenie je 5 km. Vybrali sme územie

o rozmeroch 50 x 50 km v centrálnej časti Anglicka, z ktorého sme získali maticu 11x11 hodnôt.

## 4.2 Vplyv typu vstupných dát

Okrem veľkosti neurónovej siete a veľkosti tréningového datasetu má vplyv na presnosť predikcie aj typ vstupných dát. 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. 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. Po druhé, na počte neurónov v skrytých vrstvách až tak veľmi nezáleží. 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).

**Tabuľka 1 MSE (priemer a minimum) pre rôzny typ vstupných dát a rôzne modely NS – dataset UKCP18**

Typ vstupných dát	Model neurónovej siete (MLP)			
	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)

## 4.3 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. 2 uvedené priemerné hodnoty len troch najlepších výsledkov. Táto nevyrovnanosť je zrejme spôsobená podstatne väčšou zložitosťou LSTM sietí, čo ukazuje aj počet parametrov jednotlivých typov neurónových sietí.

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.



**Tabuľka 2 MSE (priemer a minimum) pre rôznu dĺžku okna a rôzne modely NS- dataset UKCP18**

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

#### 4.4 Simulácia možností šetrenia energie

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

##### 4.4.1 Rozdelenie uzlov siete do skupín

Rozmiestnenie meracích modulov v reálnom prostredí bolo simulované náhodným výberom 20 bodov z matice 11x11 bodov (pozri kapitolu 4.1 „Použité datasety“). Testovali sme rôzny pomer snímaných a počítaných hodnôt, pričom sme vyhodnocovali strednú štvorcovú odchýlku. 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. 3.

**Tabuľka 3 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
<b>16:4</b>	0,057	0,056	0,054	0,052	0,051
<b>15:5</b>	0,084	0,08	0,079	0,08	0,078
<b>13:7</b>	0,079	0,074	0,074	0,071	0,071
<b>10:10</b>	0,082	0,07	0,072	0,068	0,067
<b>7:13</b>	0,119	0,107	0,11	0,104	0,103
<b>5:15</b>	0,146	0,143	0,144	0,141	0,143
<b>4:16</b>	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 snímání.

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 snímání teploty na úrovni  $0,5\text{ }^{\circ}\text{C}$ , 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 Kilimandžáro [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. 4.

**Tabuľka 4 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
<b>8:16</b>	1,83	1,62	1,56	1,53
<b>12:12</b>	1,98	1,45	1,25	1,24
<b>16:8</b>	1,58	1,19	1,06	1,03
<b>18:6</b>	1,32	1,15	1,07	1,07
<b>20:4</b>	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. Čo sa týka možnosti šetrenia energie, situácia je oveľa horšia než v predchádzajúcom prípade. Ak bude požadovaná stredná hodnota chyby odhadu na úrovni  $1\text{ }^{\circ}\text{C}$ , môžeme si dovoliť vynechať len 1/5 meraní, čo predstavuje úsporu 20 % energie.

#### 4.4.2 Prenos dát na základe odchýlky odhadu

V tomto prípade simulujeme realizáciu neurónovej siete v každom bode snímání 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.

V datasete Kilimandžáro z celkového počtu 12846 záznamov bolo na tréovanie použitých 10346 a na testovanie 2500 záznamov. Vzhľadom na menšiu veľkosť tréovacej 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. 5 je uvedený počet prekročení dvoch prahových hodnôt:  $0,5\text{ }^{\circ}\text{C}$  a  $1\text{ }^{\circ}\text{C}$ .

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

<b>Modul</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	<b>7</b>	<b>8</b>	<b>9</b>	<b>10</b>	<b>11</b>	<b>12</b>
<b>Prah 0,5 °C</b>	1262	1030	1200	327	397	788	1312	1353	1392	1235	1354	1185
<b>Prah 1 °C</b>	577	402	525	29	72	198	589	682	680	563	646	526
<b>Modul</b>	<b>13</b>	<b>14</b>	<b>15</b>	<b>16</b>	<b>17</b>	<b>18</b>	<b>19</b>	<b>20</b>	<b>21</b>	<b>22</b>	<b>23</b>	<b>24</b>
<b>Prah 0,5 °C</b>	1181	1244	1323	1333	1222	1458	1131	1400	1391	1337	1123	1374
<b>Prah 1 °C</b>	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).

#### 4.4.3 Porovnanie spôsobov šetrenia energie

Výsledky predošlých simulácií umožňujú porovnať úspešnosť obidvoch spôsobov šetrenia energie. V tabuľke č. 6 je uvedené množstvo energie v percentách, ktorú je možné ušetriť.

**Tabuľka 6 Približná veľkosť ušetrenej energie**

<b>Dataset</b>	<b>Presnosť</b>	<b>Rozdelenie do skupín</b>	<b>Predikcia hodnoty</b>
<b>UKCP18</b>	0,5 °C	80 %	80 %
<b>Kilimandžáro</b>	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 %.

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

Cieľom bolo dosiahnuť odhad meranej teploty v danom bode senzorickej siete na základe meraní v ostatných bodoch s čo možno najmenšou chybou. Taktiež bolo vykonané porovnanie spôsobov šetrenia energie. 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. Plocha pokrytá senzorickejšími modulmi v prvom experimente činila cca 1,9 km<sup>2</sup> a v druhom prípade cca 7,2 km<sup>2</sup>. Meracie moduly boli rozmiestnené v prímestských častiach Žiliny.

Na meranie teploty sme použili teplotný snímač DS18B20 s nastaviteľným rozlíšením 9 až 12 bitov. 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.


## 5.1 Experiment č. 1

Namerané dáta (8 dňový úsek) boli použité na tréning a testovanie neurónovej siete, ktorá odhadovala teplotu v dopredu určenom uzle WSN na základe meraní vo zvyšných bodoch.

### 5.1.1 Zostavenie datasetu

Na zostavenie datasetu sme použili štyri senzoricke moduly. Dáta v podobe vonkajšej teploty a intenzity osvetlenia okolitého prostredia sme získavali v minútových intervaloch po dobu 8 dní. Ukážka nameraných dát sa nachádza na obrázku č. 4. Celkovo bol vytvorený dataset s počtom 11520 záznamov.

Ako hlavný cieľ experimentu sme si stanovili odhad teploty v mieste modulu č. 4 na základe meraní vo zvyšných 3 bodoch bezdrôtovej senzorickej siete. Vstup do neurónovej siete bol tvorený šiestimi hodnotami, ktoré predstavovali merania (teplota a intenzita osvetlenia) z prvých troch senzorickejších modulov v danom čase. Výstup zo siete reprezentuje teplotu štvrtého senzorickejšého modulu v tom istom čase.

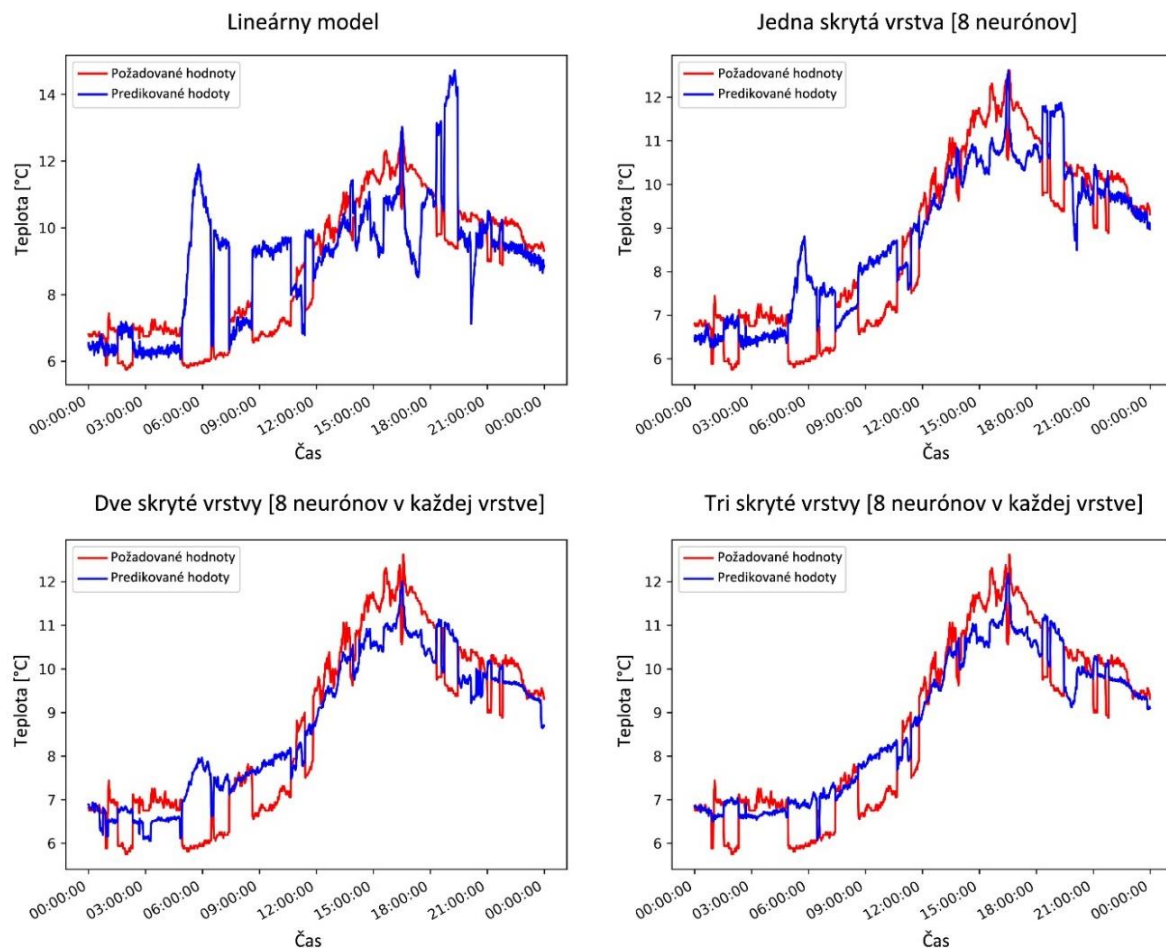


Obrázok 4 Ukážka nameraných dát

### 5.1.2 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.

Grafické porovnanie výsledkov jednotlivých neurónových sietí je zobrazené na obrázku č. 5. Červenou krivkou je znázornená skutočne nameraná teplota okolia sensorickým 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 sensorickej siete.



Obrázok 5 Grafické znázornenie výsledkov

Porovnanie výsledkov a jednotlivých chýb je uvedené v tabuľke č. 7. 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 neprinieslo pozitívny efekt na presnosť predikcie. Pridanie časovej informácie na vstup siete by mohlo mať do budúca 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.

**Tabuľka 7 Porovnanie chýb výstupov jednotlivých modelov NS**

Model NS.	Priemerná Absolútna chyba, [°C]	Smerodajná odchýlka ( $\sigma$ ), [°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

## 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. 6. 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 6 Architektúra WSN siete (2. model)**

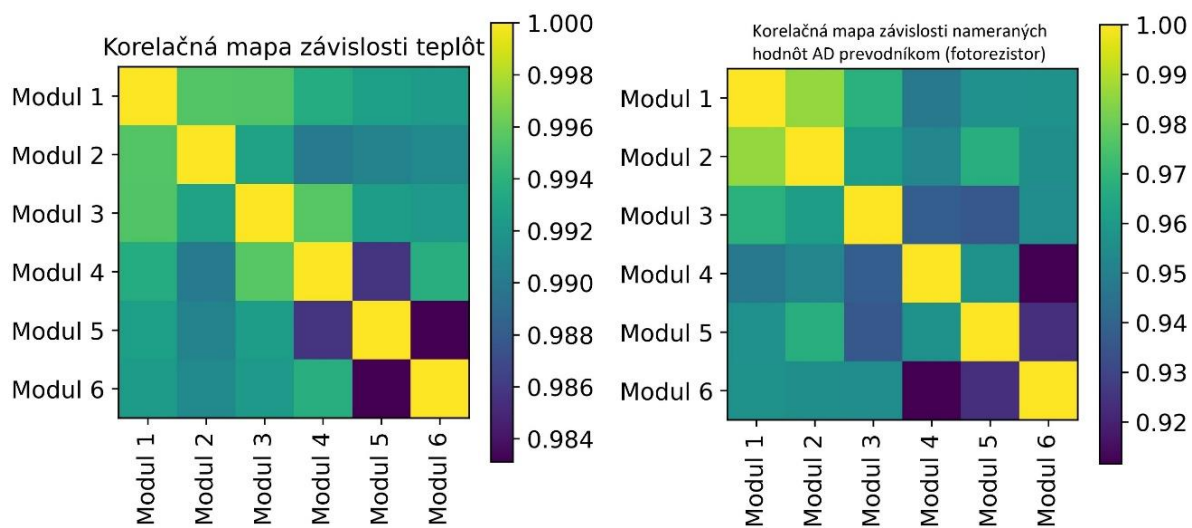
Cieľom experimentu je navrhnúť univerzálny model neurónovej siete, ktorý na základe vstupu vie odhadnúť teplotu v ľubovoľnom uzle senzorickej siete. Na rozdiel od prvého experimentu, kde neurónová sieť predpovedala meranú veličinu len v jednom, dopredu určenom bode.

### 5.2.1 Zostavenie datasetu

Na získanie potrebných dát boli použité nami navrhnuté koncové zariadenia, ktoré v pravidelných minútových intervaloch zasielajú namerané hodnoty okolitej teploty, intenzity osvetlenia a informáciu o napätovej úrovni batérií. Použiteľné dáta z meraní boli uchovávané po odladení siete, od augusta 2020 do decembra 2020.

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.

Aby sme zistili mieru lineárnej závislosti jednotlivých premenných, ktoré v našom prípade predstavujú merané veličiny v daných bodoch WSN, tak bolo potrebné vypočítať Pearsonov korelačný koeficient pre každú dvojicu bodov. Korelácia meraných veličín medzi uzlami v sieti je zobrazená na obrázku č. 7.



**Obrázok 7 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.

### 5.2.2 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 trénovaciu a testovaciu množinu. Trénovaciu množinu tvorili namerané dáta od augusta do decembra roku 2020. Dáta, ktoré boli namerané v decembri slúžili na testovanie a overenie výsledkov.

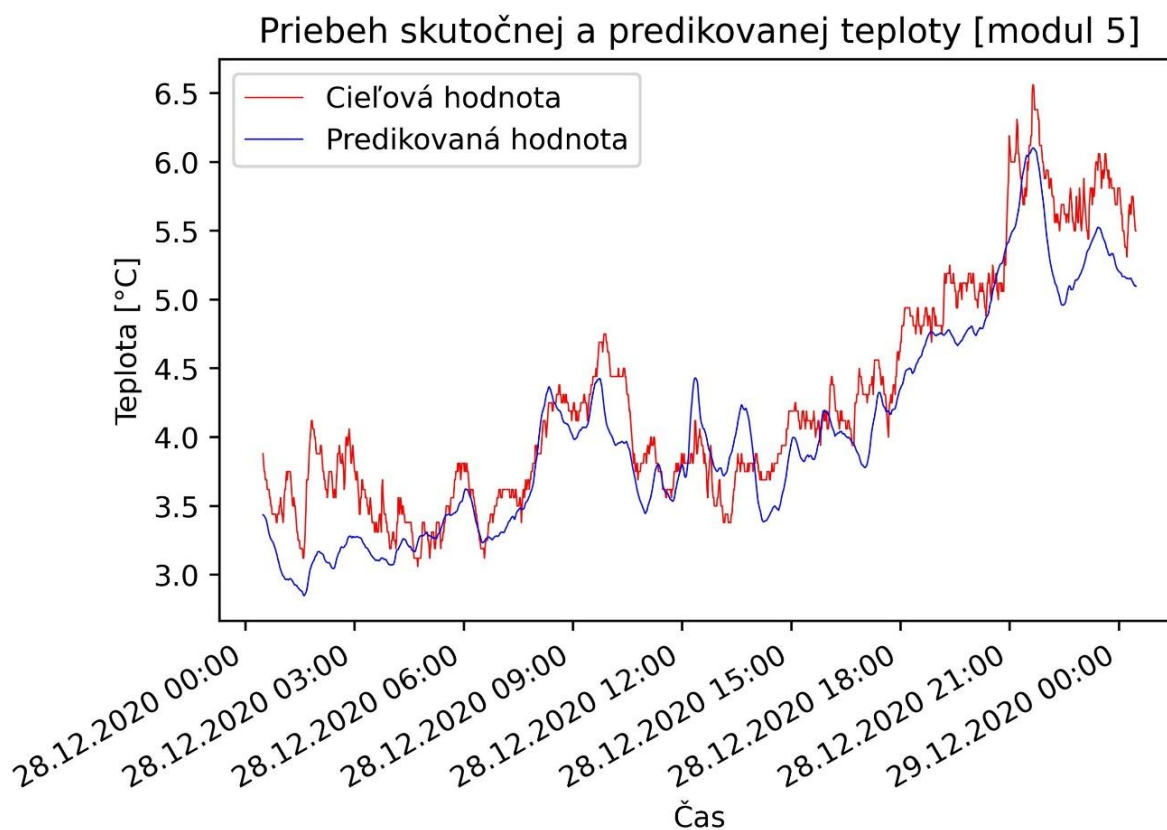
Na základe predchádzajúcich experimentov a pomerne malého počtu uzlov vo WSN sme zostavili niekoľko jednoduchých modelov dopredných neurónových sietí (MLP). Vstup bol tvorený len súčasnými nameranými hodnotami vo zvyšných moduloch WSN. Ako ukážku uvádzame na porovnanie lineárny model (lineárna kombinácia vstupov) a doprednú plne prepojenú neurónovú sieť s tromi skrytými vrstvami. V každej vrstve sa nachádzalo 16 neurónov (MLP - 16,16,16,1). V tabuľke č. 8 sú porovnané výsledky pre lineárny model (LM) a doprednú neurónovú sieť (NS) s tromi skrytými vrstvami.

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.

**Tabuľka 8 Porovnanie chýb predikcie jednotlivých modelov**

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

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. 9 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). Na obrázku č. 8 sa nachádza grafické znázornenie odhadu pre modul č. 5 počas vybraného dňa z testovacieho datasetu.



**Obrázok 8 Grafické znázornenie odhadu pre modul č. 5 pri použití časového okna na vstupe**



**Tabuľka 9 Využitie časového okna (30) na vstupe - MLP 32, 32, 32, 1**

<b>Odhad</b>	<b>Priemerná absolútna chyba, [°C]</b>	<b>Stredná kvadratická chyba, [°C]</b>	<b>Smerodajná odchýlka (<math>\sigma</math>), [°C]</b>
<b>Modul 1</b>	0,3192	0,4600	0,4469
<b>Modul 2</b>	0,4836	0,6621	0,6501
<b>Modul 3</b>	0,3292	0,4616	0,4546
<b>Modul 4</b>	0,4483	0,6315	0,6266
<b>Modul 5</b>	0,4986	0,8812	0,8217
<b>Modul 6</b>	0,4935	0,6204	0,5728
<b>Priemer</b>	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.

### 5.2.3 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 spracovanie sekvenčných dát.

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. 10. Ako možno vidieť, dosiahli sme o trochu lepšie výsledky ako v predošlom experimente s využitím plne prepojenej doprednej neurónovej siete.

**Tabuľka 10 Chyby jednotlivých odhadov pri použití CNN**

<b>Odhad</b>	<b>Priemerná absolútna chyba, [°C]</b>	<b>Stredná kvadratická chyba, [°C]</b>	<b>Smerodajná odchýlka (<math>\sigma</math>), [°C]</b>
<b>Modul 1</b>	0,2688	0,4085	0,4059
<b>Modul 2</b>	0,4719	0,7627	0,7423
<b>Modul 3</b>	0,3364	0,4613	0,4300
<b>Modul 4</b>	0,3751	0,4994	0,4940
<b>Modul 5</b>	0,4644	0,8410	0,7948
<b>Modul 6</b>	0,3574	0,5165	0,5157
<b>Priemer</b>	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 datasety 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. 11.

**Tabuľka 11 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
<b>1:5</b>	0,728	0,726	0,727
<b>2:4</b>	0,565	0,548	0,535
<b>3:3</b>	0,433	0,413	0,397
<b>4:2</b>	0,324	0,302	0,288
<b>5:1</b>	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. Dosiagnutá 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 obidvoch prípadoch na to stačí najjednoduchšia testovaná sieť MLP 8,8,8,n.

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. 12 je uvedený počet prekročení dvoch prahových hodnôt: 0,5 °C a 1 °C. Celkový počet testovaných hodnôt bol 22000.

**Tabuľka 12 Počet prekročení prahových hodnôt**

Modul	1	2	3	4	5	6
<b>Prah 0,5 °C</b>	5029	5740	5349	5260	7021	4297
<b>Prah 1 °C</b>	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 nameraných 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 reálnym experimentami bol spojený návrh bezdrôtovej senzornej 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 senzornej 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 modulech 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/LSENS.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 1*", 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/INDICON.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: Adaptive 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., Král 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 L., 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](http://www.hoperf.com/upload/rf/RFM95_96_97_98W.pdf).
- [64] PEREŠÍŇI, 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://lora-alliance.org/sites/default/files/2018-04/what-is-lorawan.pdf>.
- [66] GEMALTO, ACTILITY a SEMTECH. "*LoRaWAN Security*" [online]. 2017. Dostupné na: [https://lora-alliance.org/sites/default/files/2019-05/lorawan\\_security\\_whitepaper.pdf](https://lora-alliance.org/sites/default/files/2019-05/lorawan_security_whitepaper.pdf).
- [67] LORA ALLIANCE. "*LoRaWAN Is Secure (but Implementation Matters)*" [online]. Dostupné na: [https://lora-alliance.org/resource\\_hub/lorawan-is-secure-but-implementation-matters/](https://lora-alliance.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 Zemzami. "*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 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. Šarafín, 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. Šarafín, 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 Šarafín, Róbert Žalman. - 1. vyd. - Žilina : Žilinská univerzita v Žiline, 2018. - 204 s. ISBN 978-80-554-1531-4.
- [9] *Spríevodca po rozšírenom svete Yrobotu*. Juraj Miček ... [et al.] : Michal Hodoň, Lukáš Formanek, Silvia Jurčíková, Veronika Olešnaníková, Peter Šarafín, Róbert Žalman. - 1. vyd. - V Žiline : EDIS-vydavateľské centrum ŽU, 2017. - 214 s., ilustr. - ISBN 978-80-554-1314-3.