



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

FACULTY OF INFORMATION TECHNOLOGY

ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

**PREDIKTIVNÍ ŘÍZENÍ OHŘEVU TUV A VYTÁPĚNÍ PO-
MOCÍ METOD STROJOVÉHO UČENÍ**

PREDICTIVE CONTROL OF DHW AND HOUSEHOLD HEATING USING MACHINE LEARNING

METHODS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. DÁVID NECPÁL

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. ZDENĚK MATERNA, Ph.D.

BRNO 2023

Zadání diplomové práce



144725

Ústav: Ústav počítačové grafiky a multimédií (UPGM)
Student: **Necpál Dávid, Bc.**
Program: Informační technologie a umělá inteligence
Specializace: Kybernetická bezpečnost
Název: **Prediktivní řízení ohřevu TUV a vytápění pomocí metod strojového učení**
Kategorie: Umělá inteligence
Akademický rok: 2022/23

Zadání:

1. Proveďte rešerši existujících řešení pro řízení ohřevu TUV a vytápění domácností.
2. Navrhněte hardwarovou i softwarovou část vlastního řešení využívajícího historická data a predikci k řízení ohřevu TUV a vytápění.
3. Realizujte navržené řešení.
4. Ověřte funkčnost řešení dlouhodobým testem na alespoň jedné testovací instalaci.
5. Vyhodnoťte efektivitu řízení (energetickou úsporu) a získejte zpětnou vazbu od obyvatel domácnosti (úroveň komfortu).
6. Vytvořte video prezentující vaši práci, její cíle a výsledky.

Literatura:

- Zhang, Zhiang, and Khee Poh Lam. "Practical implementation and evaluation of deep reinforcement learning control for a radiant heating system." *Proceedings of the 5th Conference on Systems for Built Environments*. 2018.
- Katić, Katarina, et al. "Neural network based predictive control of personalized heating systems." *Energy and Buildings* 174 (2018): 199-213.
- Tweed, Christopher, et al. "Thermal comfort practices in the home and their impact on energy consumption." *Architectural Engineering and Design Management* 10.1-2 (2014): 1-24.
- Karjalainen, Sami. "Gender differences in thermal comfort and use of thermostats in everyday thermal environments." *Building and environment* 42.4 (2007): 1594-1603.
- Schieweck, Alexandra, et al. "Smart homes and the control of indoor air quality." *Renewable and Sustainable Energy Reviews* 94 (2018): 705-718.

Při obhajobě semestrální části projektu je požadováno:

- Body 1 a 2.

Podrobné závazné pokyny pro vypracování práce viz <https://www.fit.vut.cz/study/theses/>

Vedoucí práce: **Materna Zdeněk, Ing., Ph.D.**
Vedoucí ústavu: Černocký Jan, prof. Dr. Ing.
Datum zadání: 1.11.2022
Termín pro odevzdání: 31.7.2023
Datum schválení: 31.10.2022

Abstrakt

Práca sa venuje vytvoreniu systému pre riadenie ohrevu teplej úžitkovej vody (TÚV) a vykurovania. Systém využíva metódy strojového učenia na predikovanie dát do budúcnosti – učenie a predikovanie opakujúcich sa rutín osôb v domácnosti, predikovanie spotreby teplej úžitkovej vody a vývoj teploty v domácnosti. Práca je rozdelená na dve časti, kde prvá časť je riadenie ohrevu teplej úžitkovej vody, druhá časť je riadenie vykurovania domácnosti. Obe časti systému využívajú vytvorené hardvérové zariadenia, ktoré realizujú zber dát a samotné ovládanie daných činností. Zariadenia zbierajú teploty vody z elektrického bojleru, teploty vzduchu z miestností domácnosti a informáciu o prítomnosti osôb v domácnosti. Namerané dáta sa využívajú pre tvorbu modelu na predikciu dát, ktoré sú využité pre finálne rozhodnutie, či je potrebné ohrev TÚV alebo vykurovanie domácnosti realizovať. Prvý podsystém pre ohrev TÚV dosahuje úsporu energie 20 až 24 %, druhý podsystém pre vykurovanie domácnosti 18 až 30 %. Prínosom vytvoreného systému je možnosť prediktívneho automatického riadenia ohrevu teplej úžitkovej vody a vykurovania, čo vedie ku zníženiu spotreby energie potrebnej pre spomenuté činnosti, ako aj možnému zvýšeniu komfortu v domácnosti.

Abstract

The thesis is devoted to the development of a system for the control of domestic hot water (DHW) and heating. The system uses machine learning methods to predict future data – learning and predicting repetitive routines of people in the home, predicting hot water consumption and temperature trends in the home. The work is divided into two parts, where the first part is the control of domestic hot water heating, and the second part is the control of home heating. Both parts of the system use established hardware devices that implement the data collection and the actual control of the given activities. The devices collect water temperatures from the electric boiler, air temperatures from the rooms of the household and information about the presence of people in the household. The measured data is used to create a model for data prediction, which is used for the final decision on whether DHW heating or home heating should be implemented. The first subsystem for DHW heating achieves energy savings of 20 to 24 %, the second subsystem for domestic heating 18 to 30 %. The benefit of the developed system is the possibility of predictive automatic control of domestic hot water heating and heating, which leads to a reduction of energy consumption required for the above-mentioned activities, as well as a possible increase in comfort in the home.

Klíčové slová

LSTM, neurónová sieť, predikcia časových radov, dáta časových radov, InfluxDB, Shelly, inteligentná domácnosť, vykurovanie, zníženie spotreby, meranie teploty

Keywords

LSTM, neural network, time series prediction, time series data, InfluxDB, Shelly, smart home, heating, consumption reduction, temperature measuring

Citácia

NECPÁL, Dávid. *Prediktivní řízení ohřevu TUV a vytápění pomocí metod strojového učení*. Brno, 2023. Diplomová práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Ing. Zdeněk Materna, Ph.D.

Prediktivní řízení ohřevu TUV a vytápění pomocí metod strojového učení

Prehlásenie

Prehlasujem, že som túto diplomovú prácu vypracoval samostatne pod vedením pána Ing. Zdeňka Materny, Ph.D. Uviedol som všetky literárne pramene, publikácie a ďalšie zdroje, z ktorých som čerpal.

.....
Dávid Necpál
31. júla 2023

Podakovanie

Rád by som poďakoval pánovi Ing. Zdeňku Maternovi, Ph.D. za odborné vedenie, cenné rady a pomoc pri vypracovávaní tejto diplomovej práce.

Obsah

1	Úvod	2
2	Moderné technológie v domácnostiach	4
2.1	Internet vecí (IoT)	4
2.2	Domácnosť s využitím inteligentných zariadení	6
3	Analýza technológií pre ohrev teplej úžitkovej vody a vykurovania domácnosti	8
3.1	Realizácia ohrevu teplej úžitkovej vody v domácnostiach	8
3.2	Spôsoby vykurovania interiéru	12
4	Predikcia budúcnosti s využitím dát časových radov	16
4.1	Dáta časových radov a ich predikcia	16
4.2	Metódy na predikciu budúcnosti s využitím dát časových radov	17
4.3	Predikcia budúcnosti pomocou metód strojového učenia	19
5	Návrh riešenia systému na riadenie ohrevu TÚV a vykurovania	20
5.1	Riadenie ohrevu teplej úžitkovej vody	21
5.2	Riadenie vykurovania domácnosti	27
6	Implementácia systému	32
6.1	Použité technológie	32
6.2	Implementácia podsystemu pre riadenie ohrevu teplej úžitkovej vody	33
6.3	Implementácia podsystemu pre riadenie vykurovania domácnosti	39
7	Testovanie systému a výsledky	45
7.1	Testovanie riadenia ohrevu teplej úžitkovej vody	45
7.2	Testovanie vykurovania domácnosti	48
7.3	Vyhodnotenie formulára	50
8	Záver	52
	Literatúra	53

Kapitola 1

Úvod

V súčasnosti, s nástupom inteligentných domácností a technológií internetu vecí, sa naskytujú nové možnosti, ako efektívne riadiť a optimalizovať každodenné činnosti, ako napríklad ohrev teplej úžitkovej vody (ďalej ako TÚV) a vykurovanie interiéru. Inteligentné zariadenia môžu poskytnúť nové riešenia pre tieto činnosti, ktoré by zároveň mohli prispieť k zníženiu celkových nákladov. Tieto inteligentné zariadenia zbierajú a zobrazujú rôzne informácie, vykonávajú úlohy a poskytujú možnosti diaľkového ovládania a plánovania, s cieľom uľahčiť používateľom ich každodenný život.

Ohrev TÚV a vykurovanie interiéru patria medzi činnosti s najväčšou spotrebou energie [27] – podľa štatistiky z roku 2020 je spotreba energie v súkromnom sektore v rámci EU na vykurovanie až 62,8 %, na ohrev TÚV 15,1 % z celkovej spotreby energie v domácnosti. Z formulára realizovaného počas testovania systému vyplýva, že až 52 % domácností pre ohrev TÚV využíva elektrické bojler, pričom až v troch štvrtinách prípadov sa jedná o bojler, ktoré nedisponujú inteligentnými funkciami. Pri vykurovaní domácnosti až 71 % domácností využíva klasické termostaty bez rozšírených funkcií. Takéto zariadenia môžu byť relatívne ľahko nahradené alebo rozšírené inteligentnými zariadeniami, ktoré poskytujú ďalšie funkcie a môžu zaistiť vyšší komfort alebo úsporu energie, ako napríklad realizovaním ohrevu TÚV len pred očakávanou spotrebou, nevykurovaním interiéru v čase, kedy sa v ňom nikto nenachádza, poskytnutím prehľadu o spotrebách energií na dané činnosti a iné.

Dnes je možné zakúpiť zariadenia pre ohrev TÚV a vykurovania bez alebo s integrovanými inteligentnými funkciami. Inteligentné zariadenia podľa dostupných funkcií dokážu riadiť ohrev TÚV a vykurovania v predom nastavených hodinách, môžu sa naučiť pravidelné rutiny obyvateľov domácnosti, prípadne podľa aktuálneho stavu s využitím dostupných senzorov meniť čas ohrevu vody a vykurovania a iné. Na trhu je možné kúpiť inteligentné ohrievače TÚV alebo inteligentné termostaty riadiace vykurovanie od rôznych výrobcov v rôznych cenových kategóriách, avšak ich funkcie sú limitované na dané zariadenie a vo väčšine prípadov ide o uzatvorený systém, ktorý monitoruje a vykonáva iba jednu konkrétnu činnosť a nie je vždy možné ich nastaviť presne podľa požiadaviek používateľa, prípadne prepojiť s iným systémom využívaným v domácnostiach. Zároveň tieto zariadenia sú z dôvodu zložitejšej elektroniky drahšie a preto menej rozšírené. Na druhú stranu, výrazne rozšírenejšie „klasické neinteligentné“ zariadenia častokrát fungujú iba princípom zapni a vypni, čo znamená, že ich činnosť sa vykonáva vždy, keď meraná teplota vody alebo vzduchu v miestnosti klesne pod určitú predom nastavenú hranicu – nevedia posúdiť to, či je ohrev vody alebo vzduchu pre obyvateľov domácnosti naozaj potrebný.

Z vyššie uvedených dôvodov je cieľom práce vytvorenie zariadenia a systému, ktorý rozšíri klasické „neinteligentné“ zariadenia o inteligentné funkcie, teda bude efektívne riadiť

ohrev TÚV a vykurovania interiéru. Zariadenie bude pomocou senzorov zbierať dáta, ktoré vďaka vytvorenému systému následne využije na predikciu požadovaných dát do budúcnosti s využitím metód strojového učenia. Systém tak využije naučené opakujúce sa návyky členov domácnosti (príchod z práce v určitom čase, pravidelné víkendy na chate a podobne), údaje z pripojených senzorov o aktuálnych teplotách vody a vzduchu, prítomnosť osôb v domácnosti a iné, čo bude viesť k automatizácii daných činností, a teda možnému zníženiu nákladov, ako aj k zvýšeniu komfortu, pričom systém bude možné rozširovať o ďalšie senzory podľa potrieb domácnosti.

Práca je rozdelená do logických kapitol, ktoré na začiatku popisujú potrebnú teóriu a následne zhrňajú praktickú realizáciu vytvoreného zariadenia a systému. Kapitola 2 uvádza do problematiky internetu vecí a inteligentnej domácnosti, ako aj popis zariadení, ktoré je možné v inteligentnej domácnosti využiť. Kapitola 3 popisuje ohrev TÚV a vykurovania domácnosti a dostupné komerčné riešenia. V kapitole 4 je uvedený popis dát časových radov, spôsob ich uloženia a nástroje pre predikciu budúcnosti pomocou týchto dát. Následne kapitola 5 predstavuje návrh riešenia zariadenia a systému pre prediktívne riadenie. Kapitola 6 popisuje samotnú implementáciu systému a posledná kapitola 7 uvádza vykonané testovanie a experimenty, ako aj dosiahnuté výsledky.

Kapitola 2

Moderné technológie v domácnostiach

S neustálym vývojom technológií v oblasti počítačov, mobilných telefónov a iných „inteligentných“ zariadení získavajú na význame aj pojmy ako internet vecí (*Internet of Things*, IoT) a inteligentná domácnosť. Ide o termíny, ktoré popisujú koncept prepojenia zariadení pomocou takzvanej komunikácie stroj-stroj cez internet alebo domácu sieť. Zariadenia patriace do spomenutých kategórií tak používateľom umožňujú jednoducho monitorovať stav prostredia a zariadení, automatizovať úlohy či služby a iné, a to pomocou pripojených softvérových aplikácií, systémov a domácich asistentov [17]. IoT a inteligentná domácnosť sa tak stávajú viac rozšírené a práve na ne sa zameriava táto kapitola. Na začiatku je stručný popis internetu vecí a ďalej sa kapitola venuje popisu inteligentnej domácnosti a dostupných komerčných riešení.

2.1 Internet vecí (IoT)

Aj keď je pojem IoT hlavne v oblasti informačných a komunikačných technológií už pomerne bežný a stal sa jedným z hlavných výskumných tém, jeho formálna definícia je nejednoznačná a rôzni autori popisujú IoT rozdielne [4, 53]. Väčšina autorov sa však zhodne v tom, že ide o celosvetovú sieť prepojených inteligentných objektov a zariadení pre snímanie, monitorovanie, ovládanie, komunikáciu, analýzu a podobne, ktoré sú prístupné z kadekoľvek a kedykoľvek, a to pomocou rôznych komunikačných kanálov cez akúkoľvek sieť [34]. Samotné inteligentné zariadenia sú taktiež schopné vymieňať dáta s aplikáciami alebo medzi sebou s ostatnými inteligentnými zariadeniami. Na to používajú rozhrania pre pripojenia na internet, vstup-výstupné rozhrania pre senzory, rozhrania pre pamäť a ukladanie dát a audiovizuálne rozhrania [51]. IoT sa rozširuje do mnohých oblastí, ako napríklad inteligentný priemysel (priemysel 4.0), transport, zdravotníctvo, poľnohospodárstvo, domácnosti, inteligentné mestá a mnohé iné [65].

Spôsob komunikácie IoT zariadení

Okrem oblastí využitia týchto zariadení je možné IoT zariadenia rozdeliť do dvoch kategórií podľa spôsobu pripojenia pre komunikáciu, a to na drôtové a bezdrôtové [21]. Aj keď sú bezdrôtové zariadenia oblasťou, ktorou sa IoT rozvíja, k dispozícii je stále veľké množstvo drôtových IoT zariadení. Oba spôsoby majú svoje výhody a nevýhody a zároveň aj svoje

využitie v tejto oblasti – pre niektoré zariadenia je vhodné použiť drôtové pripojenie, pre iné zase bezdrôtové.

Drôtové IoT technológie sú spoľahlivé, bezpečné a môžu podporovať vysokú rýchlosť prenosu dát s nízkou latenciou, preto sú vhodné pre stacionárne zariadenia komunikujúce na krátku vzdialenosť. Naopak nevýhodami drôtových IoT zariadení sú vyššie náklady na implementáciu káblov a horšia podpora mobility a rozšírenia. Drôtové IoT technológie, ako názov napovedá, pre komunikáciu využívajú drôtové technológie, ako napríklad [21]:

- *Ethernet* – pre prepojenie zariadení sa používajú smerovače a prepínače, využíva sa technológia *Power over Ethernet* (PoE), teda technológia pre napájanie elektrickou energiou spolu s dátami pomocou „bežnej“ krútenej dvojlinky. Nevýhodou je obmedzená vzdialenosť na približne 100 metrov.
- *Long Reach PoE* (LRPoE) – rieši problém obmedzenej vzdialenosti predošlej technológie, pre komunikáciu využíva telefónne káble [5].
- *Power Line Communication*, PLC – komunikácia cez elektrické vedenie, v ktorom sa pre komunikáciu využíva modulácia a „klasická“ elektrická sieť.

Bezdrôtové IoT technológie majú naopak výhody ako mobilita, jednoduchá rozširiteľnosť a nižšie finančné náklady a sú jediným možným riešením pre mobilné IoT zariadenia. Bezdrôtové komunikačné siete možno rozdeliť do dvoch kategórií – siete dlhého dosahu (*Low Power Wide Area Network*, LPWAN) a siete krátkeho dosahu (*Short Range Network*) [1]. Najpoužívanejšie technológie v sieťach dlhého dosahu sú *SigFox*, *LoRaWAN* a *Weightless* [54]. Najpoužívanejšie bezdrôtové technológie v sieťach krátkeho dosahu sú napríklad [21, 1]:

- *Bluetooth Low Energy* (BLE) – technológia umožňuje nadviazanie komunikácie typu peer-to-peer, využíva techniku TDMA (*Time Division Multiple Access*), čo znamená, že pre komunikáciu má zariadenie pevne stanovený čas. Kedykoľvek chce zariadenie odosielať dáta, vytvorí spojenie a dáta v priradenom časovom okne odošle. Výhodou BLE je nízka spotreba energie a vyššia bezpečnosť oproti Bluetooth. Medzi nevýhody tejto technológie patrí menší dosah pohybujúci sa od jednotiek do desiatok metrov, nevhodnosť na prenos väčších dát (menšia šírka pásma) a menšia odolnosť voči rušeniu. Technológia BLE je vhodná pre zariadenia s nízkou spotrebou energie, napríklad senzory ako inteligentné zámky, fitness sledovače, zdravotnícke prístroje a iné [16].
- *ZigBee* – sieťový komunikačný protokol s vlastnosťami ako nízka spotreba energie, rýchla bezdrôtová konektivita, podpora veľkého množstva uzlov, flexibilná štruktúra siete a iné. Sieť ZigBee pozostáva aspoň z jednej centrálnej jednotky (koordinátor), smerovačov a koncových zariadení. Koordinátor je zodpovedný za spustenie siete a prijíma, odosiela, spracováva a ukladá dáta. ZigBee smerovač preposiela dáta z koncových zariadení do centrálnej jednotky – môže ísť o samostatný vysielateľ alebo ZigBee zariadenie so stálym zdrojom energie. Koncové zariadenia, najčastejšie senzory s napájaním z batérie, sú väčšinu času v stave spánku a prebúdajú sa iba počas odosielania dát na smerovač alebo koordinátor. Nevýhodou ZigBee sietí je nízka bitová rýchlosť a menšia odolnosť voči rušeniu [38].
- *Wi-Fi* – využíva sa na lokálne siete a prístup k internetu. Ide o známu a osvedčenú technológiu komunikácie. Privátne Wi-Fi siete sú bezpečné, umožňujú rýchle pripojenie viacerých zariadení do siete. Zároveň podporujú vysokú rýchlosť a neobmedzené

množstvo prenosu dát. Nevýhodou je, že verejné Wi-Fi siete môžu byť nezabezpečené, ich konfigurácia vyžaduje väčšie technické znalosti, so zvyšujúcim sa počtom zariadení v sieti klesá kvalita signálu (a teda rýchlosť prenosu dát) a zariadenia komunikujúce pomocou Wi-Fi majú veľkú energetickú spotrebu, preto je potrebné ich napájať z elektrickej siete alebo častejšie nabíjať ich batérie [45].

- *Z-Wave* – technológia podobná protokolu ZigBee, dosahuje nižších prenosových rýchlostí, ale na väčšiu vzdialenosť [42].
- *LTE (Cellular)* – komunikácia cez mobilnú sieť. Výhodou je vysoká bezpečnosť, stabilita, väčšia odolnosť voči rušeniu a menšia spotreba energie, avšak nevýhody sú vyššia cena, ktorá závisí od objemu dát a v určitých miestach horšie pokrytie mobilného signálu. Využívajú sa v zariadeniach, u ktorých sa očakáva, že budú ďalej od domácností a teda nebudú mať dobrý Wi-Fi signál [45].

2.2 Domácnosť s využitím inteligentných zariadení

Zariadenia spadajúce do internetu vecí sa rozširujú do mnohých oblastí a jednou z nich je aj domácnosť – vzniká inteligentná domácnosť (*Smart Home*). Definícia pojmu inteligentnej domácnosti je opäť nejasná, ale [9, 55] popisujú inteligentnú domácnosť ako štandardnú domácnosť s niekoľkými systémami pre domácu automatizáciu, ktoré získavajú dáta a informácie z domáceho prostredia a pomocou nich spoľahlivo podporujú domáce služby.

Medzi hlavné účely inteligentnej domácnosti patrí kontrola a riadenie energií, zvýšenie bezpečnosti [29], obmedzenie ľudských zásahov do manuálneho ovládania domácnosti, zobrazenie informácií o domácnosti [66], ako aj zvýšenie pohodlia pri každodenných činnostiach poskytnutím centralizovaného prístupu k automatizácii riadenia inteligentnej domácnosti [12] a iné.

Z vyššie uvedeného sa dá odvodiť niekoľko vlastností, ktoré možno označiť ako výhody inteligentnej domácnosti [7]. Patria medzi ne napríklad:

- Poskytnutie nových možností – inteligentné domácnosti poskytujú neobmedzené možnosti na nové inteligentné zariadenia, ktoré môžu zjednodušovať a zlepšovať život obyvateľom domácnosti [29].
- Energetická efektívnosť – veľký záujem vyvolávajú inteligentné zariadenia na úsporu energie – či iba monitorovaním spotreby energie, alebo aj samotným efektívnym riadením domácich zariadení [66].
- Vzdialený prístup – ďalšou vlastnosťou inteligentnej domácnosti je vzdialený prístup, a to najmä z pohľadu bezpečnosti v domácnosti. Mnohé z týchto funkcií sú veľmi užitočné vtedy, keď sa obyvatelia nenachádzajú v domácnosti – zapnutie kúrenia pred príchodom z práce, overenie stavu spotrebičov, uzamknutie dverí a podobne [12].
- Monitorovanie domácnosti prostredníctvom senzorov – využitie senzorov pre monitorovanie dymu, plynu alebo úniku vody, monitorovanie ovzdušia, teploty, počasia a mnoho iných. Údaje zo senzorov môžu slúžiť na automatické prediktívne systémy činností a potrieb obyvateľov, inteligentné zavlažovanie, upozornenie obyvateľov pri poruchách a iné.

Spôsobý komunikácie s inteligentnými zariadeniami

Aby inteligentná domácnosť bola inteligentnou, potrebuje zariadenia, ktoré majú možnosť komunikovať. Na začiatku je možné tieto zariadenia rozdeliť na dva typy podľa spôsobu, ako komunikujú s používateľom.

Prvým typom je využitie softvérovej aplikácie pre smartfón alebo počítač priamo pre konkrétne zariadenie alebo aplikácie od konkrétneho výrobcu. Jedná sa o lacnejšie, ale menej komplexné riešenie. Aplikácie od konkrétnych výrobcov väčšinou podporujú len zariadenia vlastnej alebo partnerskej značky. Väčšina zariadení v tomto prípade využíva pre komunikáciu protokoly Wi-Fi alebo BLE [42]. Medzi takéto aplikácie patria napríklad Mi Home od spoločnosti Xiaomi, SmartThings od spoločnosti Samsung, Honeywell Home, Shelly a podobne.

Druhým typom je využitie takzvaných asistentov pre inteligentnú domácnosť (*Smart Home Assistants*). Ide o zariadenia, ktoré plnia funkciu centrálnej jednotky (brány) a všetky ovládané zariadenia sú pripojené do tejto centrálnej jednotky. Výhodou tohoto prístupu je to, že vďaka domácejmu asistentovi je možné pripojiť zariadenia od rôznych výrobcov, prípadne zariadenia s rôznymi komunikačnými protokolmi. Následne je možné všetky pripojené zariadenia monitorovať alebo ovládať pomocou jednej aplikácie. Nevýhodou môže byť vyššia obstarávacia cena a uzatvorenosť systému, čo znamená, že systém nemôže byť úplne prispôsobený požiadavkám používateľov. Medzi najpredávanejšie domáce asistenty patria Amazon Echo s virtuálnym asistentom Alexa, Aeotec Smart Home Hub pre zariadenia od spoločnosti Samsung, Apple HomePod, Google Nest Hub a ďalšie.

Avšak ak používateľ nechce komerčné riešenie domáceho asistenta s uzatvoreným systémom, môže využiť nástroje s otvoreným zdrojovým kódom pre tvorbu domácich automatizácií. Výhodou je, že používateľ si môže prispôbiť systém tak, ako sám chce. Nevýhodou je fakt, že je vyžadovaných viac skúseností a času pre kompletné nastavenie systému. Zároveň je potrebné mať zariadenie, na ktorom daný systém bude fungovať ako centrálna jednotka pre pripojené zariadenia. Najčastejšie sa využíva jednodoskový počítač Raspberry Pi alebo mikrokontrolerová vývojová doska Arduino. Najpoužívanejšie nástroje pre domácu automatizáciu sú Home Assistant, Frigate, openHAB, Jeedom, Node-RED a mnohé iné.

Zariadenia pre inteligentnú domácnosť

Na trhu je veľké množstvo rôznych typov inteligentných zariadení pre domácnosť od rôznych výrobcov, ako napríklad senzory na meranie teploty (Aqara Temperature Sensor), pohybové senzory (Sonoff ZigBee Motion Sensor), termostatické hlavice na radiátory (Immax NEO Smart), elektrické spínače (Shelly 1PM Plus), bezpečnostné kamery (Amazon Cloud Cam), zámky (August Smart Lock Pro), reproduktory (Amazon Echo), žiarovky (Philips Hue), termostaty (Nest Thermostat E), vypínače na svetlo (TP-Link HS200 Smart Wi-Fi Light Switch), bezpečnostné systémy (SimpleSafe), zásuvky (Belkin WeMo Insight Smart Plug), vysávače (iRobot Roomba) a mnohé iné [17].

Kapitola 3


Analýza technológií pre ohrev teplej úžitkovej vody a vykurovania domácnosti

Ku komfortnému bývaní v dnešnej dobe patrí nepochybne potreba mať k dispozícii teplú úžitkovú vodu (TÚV) a spôsob vykurovania domácnosti. Existujú viaceré metódy, ako tieto dve potreby zabezpečiť – líšia sa spôsobom fungovania, druhom získania energie, účinnosťou, dostupnými funkciami a podobne.

Táto kapitola popisuje spôsoby ohrevu TÚV a zariadenia na to používané a ďalej sa venuje spôsobu vykurovania domácnosti, ako aj dostupné riešenia klasického a aj inteligentného vykurovania.

3.1 Realizácia ohrevu teplej úžitkovej vody v domácnostiach

Ohrev TÚV je možné rozdeliť do dvoch hlavných kategórií. Prvou kategóriou je ohrev TÚV pomocou zdroja na vykurovanie domácnosti, teda ohrev TÚV v zásobníku vody pripojeného ku kotlu, tepelnému čerpadlu, solárnemu kolektoru a podobne. Druhou kategóriou je ohrev TÚV pomocou samostatných ohrievačov vody – tie je možné ďalej rozdeliť na zásobníkové ohrievače vody nazývané bojler a prietokové ohrievače vody. Tieto ohrievače vody pre ohrev najčastejšie využívajú elektrickú energiu alebo plyn. Výhody bojleru oproti prietokovému ohrievaču vody sú, že vždy je k dispozícii väčšie množstvo teplej vody a ohrev prebieha priebežne, preto bojler nepotrebuje tak vysoký príkon – je možné ho pripojiť aj do bežnej elektrickej zásuvky, nakoľko potrebný príkon sa pohybuje od 1,5 do 2,5 kW. Bojler sa tak hodí do domácností s pravidelnou väčšou spotrebou TÚV. Nevýhoda bojleru spočíva vo veľkosti zásobníku, ktorý zaberá viac miesta. Výhody prietokového ohrievača sú kompaktné rozmery (väčšinou v blízkosti odberného miesta) a menšie tepelné straty pri distribúcii teplej vody. Prietokový ohrievač je tak vhodný na občasné použitie, napríklad na chate, v dielni a podobne. Nevýhodou je náročnosť na potrebný príkon, kde podľa množstva ohriatej vody za minútu môže byť vyžadovaný príkon od 3 až do 30 kW [62]. Nakoľko sa práca venuje ohrevu TÚV pomocou elektrického zásobníkového ohrievača vody, podrobnejší popis konštrukcie a fungovania sa bude venovať práve tomuto zariadeniu.



Obr. 3.1: Rez (schéma) elektrickým bojlerom Dražice OKCE. Obrázok prevzatý z [40].

Popis elektrického bojleru

Elektrický bojler, zobrazený na obrázku 3.1, využíva na ohrev úžitkovej vody elektrickú energiu [40]. V spodnej časti tlakovej nádoby bojleru sa nachádza vykurovacia špirála, ktorá mení elektrickú energiu na teplo a tým zohrieva vodu v nádobe. Teplá voda následne stúpa do hornej časti tlakovej nádoby, z kade sa odoberá stúpacou rúrkou pre výstup teplej vody. Studená voda sa vzápätí napúšťa do spodnej časti nádoby tak, aby nedochádzalo k premiešaniu studenej a teplej vody.

Väčšina „klasických“ bojlerov disponuje dvomi termostatmi – jeden je bezpečnostný a jeho nastavenie vykonáva výrobca, druhý je pre nastavenia požadovanej teploty vody. Keď je požadovaná teplota vody dosiahnutá, spínač odpojí prívod elektrickej energie do špirály. Zároveň keď teplota vody klesne pod určitú hranicu (pri testovanom bojleri orientačne o 2°C pod maximálnou teplotou), spínač sa automaticky zopne a špirála začne ohrievať vodu.

„Klasický“ bojler je jednoduché elektrické zariadenie bez zložitej elektroniky, čo môže priaznivo viesť k dlhšej bezproblémovej prevádzke. Medzi ďalšie výhody „klasických“ bojlerov patrí nižšia cena a jednoduché mechanické nastavenie požadovanej teploty. Avšak ich jednoduchá elektronika je naopak aj nevýhodou, nakoľko tieto bojlerov fungujú princípom zapni a vypni, teda nedokážu regulovať vykurovací výkon a vodu ohrievajú stále, keď teplota vody klesne pod nastavenú hranicu – deje sa tak aj vtedy, keď nie je teplá voda potrebná (v noci, počas dňa, keď sú všetci obyvatelia domácnosti v práci a podobne). To má za následok vyššiu spotrebu elektrickej energie. Klasický bojler teda nemá možnosť nastavenia, kedy teplú vodu netreba a nie je potrebné ju pravidelne ohrievať. Jedinou možnosťou je vypojenie bojleru z elektrickej siete, čo spôsobí, že teplá voda nebude k dispozícii hneď po zapojení bojleru, ale až po čase, ktorý potrebuje bojler na ohrev vody v zásobníku.

Bojlery s inteligentnými funkciami

Vyššie spomenutý problém riešia bojler s inteligentnými funkciami. Počet a rozsah týchto funkcií závisí od výrobcu a typu inteligentného bojleru. Na trhu sú k dispozícii inteligentné bojler od viacerých výrobcov s rôznymi funkciami [25], ako napríklad inteligentné učenie (automaticky sa prispôsobuje používateľom a ohrieva vodu podľa ich potrieb a spotreby), diagnostika (automatická kontrola funkčnosti bojleru a upozornenie používateľa na prípadné chyby alebo potrebný servis), ochrana proti baktérii Legionella (pravidelné zvýšenie teploty vody v bojleri), možnosť vzdialeného ovládania (bojler je možné vypnúť, zapnúť alebo nastaviť požadovanú teplotu vzdialene cez aplikáciu v inteligentnom telefóne), detekcia a využitie hromadného diaľkového ovládania (bojler zistí a zapamätá si časy vysokej tarify, ak je k dispozícii dvojtarifná sieť). Medzi u nás dostupné inteligentné bojler patria napríklad:

- OKHE SMART (Dražice) – elektrický bojler s funkciami ako využitie učiaceho algoritmu, využitie hromadného diaľkového ovládania (HDO), možnosť nastavenia a zobrazenia štatistik o bojleri v aplikácii cez Bluetooth, nastavenie režimu „dovolenka“ a ochrana proti baktérii Legionella. Bojler však nemá možnosť pripojenia k domácejmu asistentovi a nemá tak možnosť využiť údaje z ostatných senzorov, prípadne byť ovládaný vzdialene cez internet [22].
- PSH Universal (Stiebel Eltron) – bojler s učiacim algoritmom, avšak bez možnosti pripojenia bojleru k internetu a teda bez možnosti vzdialeného ovládania alebo monitorovania [58].
- Velis WiFi O (Ariston) – bojler má k dispozícii inteligentné funkcie ako učiaci algoritmus, možnosť pripojenia bojleru k aplikácii pomocou Wi-Fi a tak ho vzdialene monitorovať a ovládať a ochrana proti baktérii Legionella. Bojler však nevie pracovať s HDO [3].
- Euro In (Eliz) – bojler s funkciou učiaceho algoritmu, avšak učenie prebieha len prvý týždeň a následne už nedochádza k preučeniu podľa nových návykov osôb v domácnosti. K dispozícii sú verzie s alebo bez Wi-Fi a bojler vie využiť HDO [24].

Ďalšou možnosťou je využiť komerčné produkty, ktoré fungujú ako inteligentné ovládanie pre bojler bez rozšírených funkcií. Môžu mať podobu ovládacích jednotiek s vlastnými teplomermi. Medzi dostupné jednotky patrí ovládač od spoločnosti Aquanta¹, ktorý je možné pomocou Wi-Fi pripojiť do domácej siete. Poskytuje štatistiky o spotrebe vody, dostupnosti teplej vody, odporúčania na šetrenie ako aj učiacu funkciu využívajúcu vzory denných aktivít pre úsporu pri ohreve vody. Ďalšími produktami sú potom „inteligentné zásuvky“, do ktorých sa pripojí elektrický bojler a pomocou mobilnej aplikácie je možné bojler vypínať a zapínať, vytvárať časový harmonogram a podobne, ktoré sú dostupné od spoločností ako Shelly, Sonoff, Immax NEO a iné.

Zároveň je možné využiť aj zariadenia „domácej výroby“, ktorých zdrojové kódy sú častokrát verejné na internete a ich realizácia je lacnejšia ako zakúpenie už hotového komerčného produktu, avšak ich inštalácia a správne nastavenie vyžaduje viac skúseností. Medzi ne patrí napríklad riešenie využívajúce modul Shelly vzniknuté v rámci práce [30]. Zariadenie disponuje dvomi teplotnými čidlami, ktoré získavajú orientačnú teplotu vody vo vnútri bojleru a orientačnú teplotu vody v rúrke na výstup teplej vody. Zariadenie zároveň

¹<https://aquanta.io/>

zapína a vypína bojler, ktorý je do daného zariadenia pripojený – tým riadi samotný ohrev TÚV. Navrhnutý systém pre rozhodovanie využíva historické údaje, konkrétne plán ohrevu pre aktuálny týždeň vychádza z dát za posledné 2 týždne – pred väčšou očakávanou spotrebou vody dôjde k zapnutiu ohrevu, inak sa voda udržiava na nižšej, udržiavacej teplote. Systém zároveň disponuje funkciami ako antiLegionella, naučenie časov HDO a integrovanie Google kalendára a v ňom udalosti Dovolanka, počet spŕch alebo požadovaná teplota. Vytvorené riešenie však nevyužíva informácie o prítomnosti osôb v domácnosti, je vyžadovaný notebook pre získavanie dát a realizovanie rozhodovania v rovnakej sieti ako vytvorené zariadenie a systém nedokáže využiť dlhšie závislosti a návyky členov domácnosti.

Druhou možnosťou je riešenie na báze mikrokontroléru a inteligentnej zásuvky v rámci práce [39]. Riešenie využíva podobný princíp ako predošlá práca, avšak v riešení neboli implementované rozšírené funkcie antiLegionella a integrácia Google kalendára.

Baktéria Legionella

Dôležitým pojmom v rámci ohrevu TÚV je baktéria Legionella [43]. Ide o baktériu nachádzajúcu sa vo vode, ktorá sa najčastejšie množí v miestach bez pohybu vody, ako sú zásobníky, „slepé“ uzly v rozvode a podobne. Baktéria sa množí pri teplote vody od 20°C do 50°C, najväčšia intenzita reprodukcie prebieha pri teplote od 37°C do 42°C [26]. Samotné nakazenie baktériou prebieha pri vdýchnutí vodnej pary alebo mikroskopických kvapiek obsahujúcich túto baktériu napríklad počas sprchovania, umývania rúk a podobne.

Zdravý človek so správne fungujúcim imunitným systémom sa baktériou väčšinou nenakazí, avšak ohrozené skupiny sú staršie osoby, osoby s ochoreniami dýchacieho ústrojenstva alebo s oslabeným imunitným systémom [26]. Pri týchto osobách vdýchnutím baktérie Legionella môže dôjsť k rozvoju akútnych respiračných ochorení, teploty alebo pneumónie. Bez liečby je ochorenie smrteľné a úmrtnosť sa odhaduje na 40 až 80 % [41]. Ochorenie spôsobené baktériou je možné liečiť antibiotikami, čím sa úmrtnosť znižuje na 12 %.

Preveniou pred touto baktériou je správne nastavenie teploty pri ohreve TÚV, ako aj odstránenie „slepých“ uzlov v rozvode. Baktéria neprežije vo vode s teplotou nad 60°C, preto je vhodné ohrev TÚV vykonávať až na túto teplotu. Zároveň sa odporúča pravidelne (napríklad raz mesačne) zvýšiť teplotu vody v zariadení nad 70°C a studenú vodu skladovať pri teplote pod 20°C [26].

Hromadné diaľkové ovládanie

Ďalším dôležitým pojmom pri ohreve TÚV a vykurovania pomocou elektrickej energie je HDO a s ním spojená vysoká a nízka tarifa, ľudovo nazývaná nočný prúd. HDO a dvojité tarifa sa zaviedla pre zníženie spotreby elektrickej energie počas najväčšieho zaťaženia siete (špičky). Distribučné spoločnosti tak motivujú svojich zákazníkov k zníženiu spotreby počas špičiek a tak ku stabilizácii odberu v sieti. Ako z názvu vyplýva, počas vysokej tarify je cena za jednotku kWh vyššia ako počas nízkej tarify, je teda žiadúce pre zníženie nákladov za elektrickú energiu využívať zariadenia s veľkým odberom počas nízkej tarify. HDO je teda diaľková regulácia odberu elektrickej energie, silový signál prepína medzi nízkou a vysokou tarifou [46]. Domácnosti, ktoré pre ohrev TÚV a vykurovanie využívajú elektrickú energiu, môžu u svojho dodávateľa elektrickej energie požiadať o pridelenie dvojitej tarify. Následne sa nainštaluje viactarifový elektromer a HDO prijímač.

Pri prepínaní vysokej a nízkej tarify v sieti elektromer deteguje, v ktorej tarife má spotrebu elektrickej energie merať, to znamená, že všetky zásuvky v domácnosti pripojené k danému elektromeru pracujú v tejto tarife. V domácnosti môže byť nainštalovaný

samostatný obvod ovládaný stýkačom, do ktorého je pripojené elektrotepelné zariadenie, napríklad elektrický bojler a iné elektrické vykurovacie zariadenia. V čase vysokej tarify sa stýkač prepne a odpojí tento obvod – odpojí zariadenie s vysokou spotrebou. V čase nízkej tarify ho opäť zapne. Týmto spôsobom môže dodávateľ elektrickej energie znižovať zaťaženie siete v čase výkonových špičiek. Časy HDO sú rôzne, závisia od dodávateľa a oblasti, v ktorej sa domácnosť nachádza.

3.2 Spôsoby vykurovania interiéru

Tak ako v prípade ohrevu TÚV, tak aj vykurovanie domácností môže byť realizované viacerými spôsobmi, ktoré sa líšia hlavne použitým „palivom“. Medzi ne patria [61]:

- Tepelné čerpadlá – v súčasnosti sa tepelné čerpadlá stávajú čoraz obľúbenejšou voľbou, a to vďaka nízkym prevádzkovým nákladom. Tepelné čerpadlo funguje na princípe využitia termickej energie, ktorá je akumulovaná v životnom prostredí, konkrétne vo vzduchu, v zemi alebo vo vode. V prípade vzduchu ide o najjednoduchšie riešenie, avšak jeho efektívnosť klesá s nízkymi teplotami vzduchu v zimnom období. Využitie geotermálnej energie (zo zeme) je rovnako efektívne počas celého roku, ale vyžaduje vysoké náklady na zemné práce a povolenia s nimi spojené. V prípade podzemnej vody ide o jeden z najefektívnejších zdrojov tepla, no opäť sú potrebné vyššie prvotné náklady a povolenia, pričom nie všade je povolené využívať tento zdroj tepla. Medzi výhody tepelných čerpadiel patria nízke náklady na vykurovanie a prevádzka bez emisií CO₂. Nevýhodami sú vysoké počiatkové náklady a je potrebný správny návrh vykurovania ešte pred jeho realizáciou, inak samotné vykurovanie nebude fungovať správne. Nakoľko ide o novšiu technológiu s vyššou obstarávacou cenou, využíva sa hlavne v nových alebo novo rekonštruovaných domácnostiach, ktoré už častokrát disponujú inteligentnými funkciami, preto sa tepelné čerpadlá a celé vykurovanie domácností rozširujú o termostaty s inteligentnými funkciami alebo inteligentnými centrálnymi jednotkami [32].
- Solárny systém – je možné ho rozdeliť na dva druhy – solárna termika pre ohrev vody a fotovoltaika pre výrobu elektrickej energie. Solárne systémy prevažne slúžia ako doplnkový spôsob k inému vykurovaciemu systému, najčastejšie len pre ohrev TÚV. Nespornou výhodou solárnych systémov je práca výlučne s obnoviteľnou energiou – samotné zariadenie nevyžaduje žiadne ďalšie palivo na jeho prevádzku. Naopak nevýhodou môžu byť vyššie obstarávacie náklady a nutnosť mať vhodnú orientáciu strechy voči slnku. Spojenie solárnych systémov s inteligentnými zariadeniami umožňuje ich vzdialené monitorovanie, v prípade inteligentných domácností využívajúcich aj iné senzory je solárne systémy možné využiť pri prediktívnom riadení ohrevu TÚV a vykurovania. Napríklad, aj keď je teplota vody v bojleri pod minimálnou teplotou, ale v blízkej budúcnosti je predpovedané vyššie slnečné žiarenie, ohrev vody sa nezačne realizovať hneď, ale počká sa na dostatočné množstvo vyrábanej elektrickej energie z fotovoltaiky.
- Plynový kotol – výroba tepelnej energie prebieha spaľovaním plynu. Jedná sa o malé kompaktné zariadenia s vysokou efektívnosťou dosahujúcou až 98 %. Jediným predpokladom pre ohrev pomocou plynového kotlu je mať k dispozícii plyn, ktorý delíme na zemný plyn, kvapalnú plyn a bioplyn. Zemný plyn je prirodzene vzniknutá, fosílna surovina, ktorá sa získava z podzemných ložísk. Kvapalnú plyn je vedľajší produkt

pri ťažbe ropy a je vhodný na skladovanie v zásobníkoch, ktoré sa môžu nachádzať aj v blízkosti domu. Bioplyn je obnoviteľná surovina vznikajúca pri kvasení rastlín a zvyškov potravín, prípadne z hnoja. Plynové kotle je možné regulovať pomocou klasických zapni/vypni termostátov, equitermickej regulácie alebo inteligentných termostátov. Niektorí výrobcovia do samotných zariadení inštalujú moduly pre pripojenie k internetu a k iným inteligentným zariadeniam.

- Kotel na pelety – získava tepelnú energiu spaľovaním drevených normovaných výlis- kov – peliet, vďaka čomu môže fungovať skoro automaticky. V kombinácii s pokročilou reguláciou dokáže optimálne vytvárať teplo pre vykurovanie objektu aj bez častého manuálneho zásahu. Pri naplnení zásobníka na pelety nie je potrebné kotel manu- álne doplňovať aj niekoľko dní alebo týždňov. Výhody vykurovania pomocou peliet sú využitie obnoviteľného paliva a automatické a účinné vykurovanie. Nevýhodou sú veľké priestorové požiadavky na skladovanie peliet a vyššie obstarávacie náklady. Nie- ktoré kotle už disponujú inteligentnými funkciami, ako napríklad vzdialené ovládanie, sledovanie a optimalizácia spotreby, diagnostika a iné.
- Kotel na drevo – jedná sa o jednoduchý a často využívaný typ vykurovania. Pri jednoduchom zapojení do systému sa jedná o ťažšie regulovateľný zdroj tepla. Pre do- siahnutie vyššieho komfortu sú potrebné ďalšie náklady na akumuláciu nádrže a equ- itermickú reguláciu. Nevýhodou však je vysoká manuálna náročnosť pri vykurovaní kusovým drevom a ťažšie dosiahnuteľný teplotný komfort bez dodatočných nákladov.
- Elektrické kúrenie – elektrické kúrenie je možné rozdeliť na viac druhov – elektrické kotly, elektrické (odporové) podlahové vykurovanie alebo samostatné elektrické ohrie- vače. Jedná sa o vykurovanie s nižšou obstarávacou cenou, je ľahko regulovateľné pomocou pripojených klasických termostátov alebo termostátov s inteligentnými fun- kciami, ktoré pridávajú ďalšie možnosti pre efektívnejšiu realizáciu vykurovania. Elek- trické vykurovanie je nenáročné na priestorové požiadavky. Podlahové vykurovanie sa inštaluje priamo do konštrukcie podlahy, preto sa väčšinou realizuje pri novostavbách alebo rozsiahlejších rekonštrukciách domácností. Výhodou je jednoduchá inštalácia a vysoký komfort.
- Palivové články – je to nový spôsob vykurovania a zároveň výroby elektrickej ener- gie pre vlastnú spotrebu. Pracuje na báze chemického procesu, pri ktorom sa štiepi vodík, ktorý je získavaný z plynu pomocou vstavanej jednotky. Palivové články sú efektívne v kombinovanej výrobe tepelnej a elektrickej energie, účinnosť je približne 90 %. Nevýhodou však sú veľmi vysoké obstarávacie náklady, nakoľko sa jedná o novú technológiu.

Aj keď je hlavným prvkom vykurovania domácnosti práve vykurovacie zariadenie me- niace „palivo“ na tepelnú energiu, druhým dôležitým prvkom vykurovacieho systému je termostat, ktorý samotné vykurovanie „ovláda“. Základné termostaty bez rozšírených fun- kcií fungujú na princípe zapni a vypni podľa aktuálnej teploty získanej z teplotného senzoru. Existuje však aj väčšie množstvo typov termostátov disponujúcich ďalšími „inteligentnými“ nastaveniami a funkciami.

Termostaty s rozšírenými inteligentnými funkciami

Na trhu je k dispozícii veľké množstvo termostátov s inteligentnými funkciami, ktoré dokážu viac než len ovládanie vykurovania. Oproti „klasickým“ termostatom ponúkajú množstvo

rozšírených funkcií, ako je vzdialené ovládanie vykurovania pomocou telefónu cez aplikácie od výrobcov alebo s využitím integrácie termostatu do domáceho asistenta, zapnutie alebo vypnutie vykurovania podľa polohy telefónu alebo senzoru na detekciu prítomnosti osôb v domácnosti, senzory vlhkosti, inteligentné učenie vykurovania podľa návykov osôb v domácnosti, učenie modelu domácnosti a podobne [64]. Najlepšie inteligentné termostaty podľa [64] sú:

- Amazon Smart Thermostat – termostat s inteligentnými funkciami ako možnosť hlasového ovládania s virtuálnym asistentom Alexa, funkcia *Geofencing* (sledovanie polohy mobilného telefónu na určenie prítomnosti osoby v domácnosti) a iné, pričom výhodou je nízka nákupná cena, ale termostat nemá možnosť pripojenia externých teplotných senzorov [64] a teda je veľmi náročné realizovať zónové ovládanie vykurovania. Zariadenie získalo certifikáciu *ENERGY STAR* a teda podľa EPA (Agentúra pre ochranu životného prostredia v USA) je ročná úspora na vykurovaní približne 50 dolárov [2].
- Ecobee Premium – termostat s funkciami ako predošlý spomenutý termostat, navyše s možnosťou rozšírenia o ďalšie externé senzory, zabudovaným senzorom kvality vzduchu, avšak nevýhodou je vysoká nákupná cena a niektoré doplnkové funkcie sú dostupné len pri mesačnom predplatnom [20]. Vďaka týmto funkciám zariadenie získalo certifikáciu *ENERGY STAR* a podľa výrobcov je ročná úspora na vykurovaní a chladení až 26 % [23].
- Honeywell Home T9 – termostat opäť s funkciami ako spomenutý termostat od Amazonu, navyše s možnosťou rozšírenia o senzor detekcie osôb v miestnosti pre zabezpečenie rovnomerného vykurovania a chladenia jednotlivých miestností v domácnosti, avšak nepodporuje pridanie ostatných Honeywell zariadení, ktoré nie sú špecificky určené pre daný termostat. Ďalšou nevýhodou je opäť vyššia nákupná cena [19].
- Nest Learning Thermostat – termostat opäť s podobnými funkciami, navyše pracuje s ostatnými zariadeniami od spoločnosti Nest, má funkciu učenia návykov vykurovania a chladenia a funkciu na výpočet doby vykurovania interiéru. Nevýhodou je vysoká nákupná cena [18]. Podľa výrobcov sa ročná spotreba energie na vykurovanie pri použití daného termostatu zníži o 10 % [28].

Tieto termostaty, ako aj mnohé iné komerčné produkty, sú však uzatvorené systémy a teda je možné využívať len funkcie, ktoré dané zariadenie poskytuje, prípadne rozšíriť zariadenie o tie senzory, ktoré sú pre zariadenie určené. Tieto senzory sú však častokrát pomerne drahé a tým sa ešte viac zvyšujú obstarávacie náklady. Na trhu je mnoho inteligentných termostatov v rôznych cenových kategóriách a s rôznymi funkciami a pri výbere nového inteligentného termostatu je preto vhodné zohľadniť, aké funkcie dokáže používateľ využiť, či má k dispozícii domáceho asistenta a podobne.

Okrem komerčných inteligentných termostatov existujú aj „domáce“ riešenia, ktoré sú (ako v prípade takýchto zariadení pre ohrev TÚV) lacnejšie, avšak vyžadujú viac skúseností s ich inštaláciou a nastavením. Medzi takéto riešenia patrí *Raspberry-Pi Home Heating Controller* [50], ktorý pre svoju činnosť využíva minipočítače Raspberry Pi Zero, konkrétne jeden minipočítač slúžiaci ako centrálna jednotka a následne jeden minipočítač pre každú monitorovanú miestnosť, v ktorej je pomocou pripojeného jedného alebo viacerých drôtových senzorov DS18B20 získavaná teplota. Minipočítače sú rozšírené o USB Wi-Fi moduly, aby mohli spolu komunikovať. Ohrev prebieha na základe zapínania a vypínania vykurovacieho telesa podľa nastavených podmienok a teplôt pre jednotlivé miestnosti. Softvérová časť

je rozšírená o užívateľské rozhranie, v ktorom je možné nastaviť týždenný plán vykurovania, požadovanú teplotu a iné. Zariadenie tak umožňuje monitorovanie teploty v rôznych miestnostiach, detekcia prítomnosti osôb v domácnosti cez MAC adresu mobilného zariadenia na lokálnej Wi-Fi sieti, týždenné plánovanie a vzdialená kontrola vykurovania. Zariadenie vo verzii zdieľanej autorom však nedisponuje funkciami ako zónové vykurovanie (iba monitorovanie), učenie návykov obyvateľov domácnosti a prediktívne riadenie vykurovania podľa ich činností.

Kapitola 4

Predikcia budúcnosti s využitím dát časových radov

Predikcia budúcnosti sa zaoberá odhadovaním premenných od súčasnosti do budúcnosti. Avšak, aby bola predpoveď vôbec možná, musí byť založená na reálnych faktoroch, a preto sa využívajú údaje z minulosti. Ide o oblasť, ktorá sa v posledných rokoch veľmi rýchlo rozvíja [33], pretože predikcia časových radov umožňuje porozumieť vplyvu minulých dát na budúce udalosti. Pri predikcii sa analyzujú historické dáta, identifikujú sa vzory a vytvárajú sa krátkodobé alebo dlhodobé predpovede [59].

4.1 Dáta časových radov a ich predikcia

Dáta časových radov vznikajú ako kolekcia pozorovaní jedného subjektu v rôznych časových intervaloch (zvyčajne s rovnakými rozostupmi v prípade metrík alebo s rozdielnymi rozostupmi v prípade udalostí). Patria tam napríklad pravidelne získavané meteorologické údaje, hodnoty finančných trhov, vývoj šírenia ochorenia v populácii a podobne. Pre vykreslenie časových radov sa najčastejšie využívajú čiarové grafy [6], nakoľko najvhodnejšie zobrazujú vývoj daných hodnôt v čase. Využívajú sa v štatistike, spracovaní signálov, predpovedi počasia, astronómii a v mnohých iných oblastiach, ktoré zahŕňajú pravidelné merania [37]. Predikcia udalostí alebo hodnôt závisí od niekoľkých faktorov, napríklad ako dobre rozumieme faktorom, ktoré k predpovedi prispievajú, koľko máme k dispozícii dát, ako podobná je budúcnosť voči minulosti a ako môžu samotné predikcie ovplyvniť predikovanú budúcnosť. Dobré predikcie zachytávajú skutočné vzory a vzťahy, ktoré existujú v historických údajoch, ale neopakujú minulé udalosti, ktoré sa už nebudú opakovať. Preto je pri analýze dát potrebné správne rozlišovať náhodné javy a kolísania hodnôt od skutočných vzorov [33].

Dôležitým faktorom v dátach časových radov je to, že sa viažu na čas a majú teda prirodzené jednosmerné časové usporiadanie – tým sa líšia od ostatných druhov dát. Z toho vyplýva aj rozdielny spôsob ich uloženia. Pre ukladanie týchto dát sa používajú databázy časových radov [31]. Jedná sa o databázy optimalizované pre ukladanie dát časových radov – metrík, udalostí alebo meraní s časovými značkami. Tieto databázy sa značne odlišujú od ostatných typov databáz, a to hlavne funkciami ako napríklad ukladanie a kompresia dát s časovou pečiatkou, správa životného cyklu dát, agregácia (spojenie dát s po sebe idúcimi časovými značkami pomocou priemeru, mediánu a podobne, v ľubovoľnom časovom rozsahu), spracovanie veľkého množstva záznamov a iné. Vďaka ich vlastnostiam a stále

sa zvyšujúceho množstva rôznych meraní a ukladaní dát s časovými značkami ide o jeden z najrýchlejšie sa rozvíjajúcich segmentov databázových systémov v posledných rokoch [60, 31].

Existuje veľa databáz časových radov, medzi najpoužívanejšie patria napríklad InfluxDB¹, kdb+², Prometheus³, Graphite⁴, TimeScale⁵ a mnohé iné.

Medzi základné kroky pri predikcii dát do budúcnosti patria [31]:

- Definícia problému – pochopenie spôsobu, ako sa predikované dáta využijú a kto ich využije.
- Zhromažďovanie informácií – získanie dostatočného množstva historických dát vzťahujúcich sa k predikovanej veličine, ako aj získanie odborných znalostí ľudí, ktorí dáta zbierajú a ktorí budú predikciu využívať.
- Predbežná analýza – analýza dát, či sú vôbec vhodné na predikciu – hľadanie konzistentných vzorov, trendov, sezónnosti a iných, analýza vzťahov jednotlivých dát použitých na predikciu.
- Výber a prispôbenie modelov – výber najvhodnejších modelov prebieha na základe získaných informácií, množstva historických dát a ďalších vlastností.
- Použitie a vyhodnotenie modelov na predikciu – použitie vybraného modelu na predikciu požadovaných dát a následné vyhodnotenie jeho presnosti po získaní skutočných dát z predikovaného obdobia.

Vyhodnotenie presnosti modelu predikcie dát časových radov sa líši od vyhodnotenia iných typov dát, pretože nie je možné porovnávať presnú zhodu skutočných a predikovaných dát. Predikcia je často realizovaná ako predikčný interval, teda rozsah hodnôt, ktoré predikovaná premenná môže nadobudnúť s relatívne vysokou pravdepodobnosťou. V rámci vizualizácie predikovaných hodnôt sa často zobrazuje stred rozsahu hodnôt z predikčného intervalu [31].

4.2 Metódy na predikciu budúcnosti s využitím dát časových radov

S rozvojom získavania dát a nutnosťou predikcie veľkého množstva dát časových radov vznikajú aj nové nástroje pre túto predikciu. Metódy na predikciu predstavujú základný nástroj v mnohých oblastiach rozhodovania, ako napríklad obchodné a finančné stratégie, politika a podobne [44]. Ako bolo spomenuté, metódy na predikciu využívajú to, že historické dáta zahŕňajú „vzory“ nesúce užitočné informácie pre popis skúmaného javu. Hľadanie týchto vzorov však nie je triviálne a ide o jeden z hlavných cieľov pri spracovaní dát časových radov – kedy sa vzory opakujú a ako sa môžu časom vyvíjať.

Nakoľko existuje mnoho metód na predikciu, na začiatku je potrebné analyzovať niekoľko špecifík v dátach, s ktorými bude metóda pracovať [52]. Prvým špecifikom je počet dimenzií, teda „rozmer“ dát. Dáta môžu byť jednorozmerné alebo viacerozmerné. Jednorozmerné dáta

¹<https://www.influxdata.com/>

²<https://kx.com/developers/>

³<https://prometheus.io/>

⁴<https://github.com/graphite-project/graphite-web>

⁵<https://www.timescale.com/>

znamenaajú, že k jednej časovej značke je priradená jedna premenná, výstupom metódy je jedna konkrétna premenná. Viacrozmerné dáta majú k jednej časovej značke priradených viac premenných – metódy tak môžu predpovedať jednu alebo viac hodnôt.

Ďalším špecifikom je to, či dáta obsahujú hlavné zložky, do ktorých patrí [52, 33]:

- Trend – dlhodobý smer vývoja dát, stúpanie alebo klesanie hodnôt dát časových radov počas dlhšieho časového obdobia.
- Sezónnosť – opakovanie určitého vzoru spôsobené sezónnymi udalosťami počas obdobia, ako napríklad deň, týždeň, mesiac, sezóna a iné.
- Cyklické variácie – stúpanie alebo klesanie hodnôt v nepravidelných, často veľmi dlhých intervaloch.
- Náhodné alebo nepravidelné variácie – spôsobené náhodnými faktormi – hodnoty nespádajú do žiadneho vzoru.
- Vonkajšie faktory – vplyv vonkajších faktorov na vývoj dát, napríklad politické alebo ekonomické udalosti.

Analýza týchto špecifik a rozpoznanie vzorov v dátach je kľúčovým faktorom pre úspešnú predikciu dát časových radov. Po tejto analýze nasleduje už samotný výber modelu na predikciu. Dostupné metódy je možné rozdeliť do dvoch kategórií, a to parametrické, nazývané tiež tradičné metódy, a neparametrické, teda metódy využívajúce strojové učenie [44]. Obe kategórie majú svoje výhody a nevýhody – výber najvhodnejšej metódy závisí od skúseností programátora a dát, ktoré budú na predikciu využité.

Tradičné metódy predikcie časových radov

Tieto metódy sú staršie, avšak sú aj naďalej populárne a v oblasti predikcie časových radov stále využívané. Tradičné metódy majú použitie v oblasti, kde je vhodné využiť získavanie budúcich dát pomocou rekurzie, čo znamená, že je možné získať predikciu pre nasledujúci deň, deň po ňom a tak ďalej. To je zároveň možné využiť na rozšírenie predikovaných dát o ďalšiu vlastnosť, takže ak chceme predikovať vlastnosť nastávajúcu o 15 jednotiek času namiesto 5, rekurzívne urobíme viac predikcií. Naopak môže byť zložitejšie dosiahnuť presné výsledky, prípadne zlepšiť už dosiahnuté výsledky. Nevýhodou týchto metód je nemožnosť rozšírenia jednorozmerného modelu o ďalšiu hodnotu pre rovnakú časovú značku [13].

Podmienkou tradičných metód je, že dáta musia byť stacionárne, čo znamená, že v rôznych časových obdobiach by mali mať konštantný priemer, rozptyl alebo štandardnú odchýlku a sériová korelácia (miera vzájomnej závislosti medzi hodnotami v časovom rade) by nemala závisieť od času [14]. Dáta obsahujúce zložky sezónnosť a trend nie sú stacionárne, preto je potrebné tieto zložky z dát odstrániť.

Najpoužívanejšie tradičné modely na predikciu časových radov sú [35]:

- Autoregresívny (*Autoregressive*, AR) model.
- Klzavý priemer (*Moving average*, MA).
- Autoregresívny klzavý priemer (*Autoregressive moving average*, ARMA).
- Autoregresívny integrovaný klzavý priemer (*Autoregressive integrated moving average*, ARIMA).

- Sezónny autoregresívny integrovaný kĺzavý priemer (*Seasonal autoregressive integrated moving average*, SARIMA).
- Vektorový autoregresívny (*Vector autoregressive*, VAR) model.

Ďalšie metódy a podrobné informácie je možné nájsť v [10].

4.3 Predikcia budúcnosti pomocou metód strojového učenia

Metódy strojového učenia, teda neurónových sietí na predikciu budúcnosti s využitím dát časových radov sú modernejšie a umožňujú získanie presnejších výsledkov oproti tradičným metódam, majú možnosť využitia viacrozmerých dát, priame získavanie dát pre zvolený časový úsek v budúcnosti [13] a sú robustné voči chýbajúcim dátam [11]. Nevýhodou je, že ak chceme zmeniť časový horizont, v ktorom predikujeme, potrebujeme zmeniť tréningové dáta. Medzi najpoužívanéjšie metódy strojového učenia pre predikciu budúcnosti časových radov patria napríklad konvolučné neurónové siete, rekurentné neurónové siete, siete typu *Long short-term memory* (LSTM), hlboké neurónové siete (metóda DeepAR) a iné [11].

Metóda konvolučných neurónových sietí

Konvolučné neurónové siete (*Convolutional Neural Network*, CNN) sa využívajú pre spracovanie obrazových údajov, ale vďaka schopnosti učenia a extrakcie vlastností vstupných dát je možné CNN využiť aj na predikciu časových radov. Dáta časových radov môžu byť chápané ako jednorozmerný obrázok, vďaka čomu CNN môže nájsť a extrahovať najvýraznejšie vlastnosti vstupných dát, ktoré priamo súvisia s predpovedaným problémom. CNN umožňujú prácu s viacrozmerými dátami, môžu sa učiť ľubovoľné (zložité) funkčné vzťahy a nevyžadujú učenie priamo z pozorovaní, ktoré sú medzi sebou posunuté voči sebe. Namiesto toho sa model môže naučiť predpovedať z veľkej vstupnej sekvencie, ktorá je pre problém predikcie najrelevantnejšia [11].

Metóda rekurentných neurónových sietí

Rekurentné neurónové siete (*Recurrent Neural Network*, RNN) sú najbežnejšou a najpoužívannejšou metódou na predikciu časových radov. RNN priamo pridávajú podporu pre vstupné sekvenčné dáta [11]. Aj cez obecné výhody neurónových sietí na predikciu časových radov popísané vyššie majú RNN nevýhody ako problém miznúceho gradientu a slabá pamäť, ktorá nie je schopná brať do úvahy niekoľko hodnôt z minulosti pri predpovedaní budúcnosti. Z toho dôvodu vznikli rozšírenia RNN na úpravu vnútornej pamäte, ako obojstranné neurónové siete, LSTM, *Gated recurrent unit* (GRU) a mechanizmus pozornosti (*Attention mechanism*) [49].

Rekurentné neurónové siete typu LSTM (*Long Short-Term Memory*) riešia problém miznúceho gradientu v štandardnom RNN. LSTM je teda navrhnutý tak, aby zvládol dlhodobé závislosti v sekvenčných údajoch, nakoľko ich architektúra umožňuje dlhodobejšie uchovanie informácií, ktoré možno využiť v budúcnosti [49].

Práca [63] popisuje využitie RNN typu LSTM pre riadenie ohrevu, ventilácie a chladenia (*Heating, ventilation, and air conditioning*, HVAC) v kancelárskej budove, pričom sú využité údaje o vonkajšej teplote, vnútornej teplote, spotrebe energie, intenzite slnečného žiarenia a prítomnosti osôb v budove. Podľa autorov sa dosiahla úspora energie 15 %, čo je o 2,5 % viac ako pri použití iných nimi spomínaných prístupov.

Kapitola 5

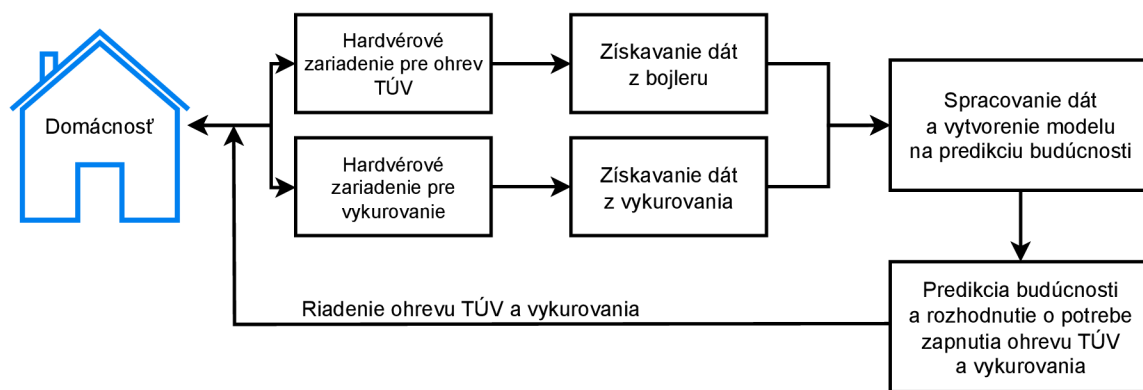
Návrh riešenia systému na riadenie ohrevu TÚV a vykurovania

Táto kapitola popisuje návrh riešenia systému pre prediktívne riadenie ohrevu teplej úžitkovej vody (TÚV) a vykurovania domácnosti. Venuje sa postupu návrhu systému, úvahám o použití jednotlivých technológií a dôvody k vytvoreniu finálneho riešenia. Celá architektúra systému je zobrazená na obrázku 5.1.

Systém bude pracovať automaticky, nebude teda očakávať žiadne vstupy od používateľa (okrem prvotného vyplnenia požadovaných údajov v konfiguračnom súbore), všetky potrebné údaje budú získané pomocou pripravených zariadení a skriptov. Navrhnutý systém bude možné na začiatku rozdeliť na dva samostatné podsystémy – podsystém pre riadenie ohrevu TÚV a podsystém pre riadenie vykurovania domácnosti. Oba podsystémy budú môcť pracovať samostatne, nezávisle na sebe, avšak zároveň budú môcť využívať „spoločné“ údaje ako napríklad informáciu o prítomnosti osôb v domácnosti a tým zlepšiť výsledky oboch podsystémov. Aj keď budú oba podsystémy navrhnuté samostatne, ich štruktúra bude podobná a bude možné ju rozdeliť na tri fázy – zber dát, vytvorenie modelu na predikciu budúcnosti pomocou strojového učenia a využitie modelu pre samotné riadenie.

Prvú fázu, zber dát, bude možné rozdeliť na dve časti, teda na hardvérovú a softvérovú časť. V rámci prvej časti bude navrhnuté a vytvorené zariadenie, ktoré bude pomocou pripojených senzorov zbierať požadované dáta, ako napríklad teploty vody v rámci riadenia ohrevu TÚV, teploty vzduchu v rámci riadenia vykurovania domácnosti a iné. Druhá časť, softvérový skript, bude slúžiť na ukladanie týchto dát do databázy časových radov, nakoľko sa bude jednať o pravidelné dáta obsahujúce časové značky (podrobnejšie popísané v kapitole 4). Výstupom prvej fázy bude databáza obsahujúca namerané dáta.

Druhá fáza, vytvorenie modelu na predikciu budúcnosti, bude využívať získané dáta z prvej fázy. Na začiatku budú z databázy načítané uložené dáta a následne bude prebiehať proces spracovania dát. Konkrétne budú získané dáta spojené do väčších časových blokov, rozšírené o údaje odvodené zo samotných hodnôt ako štandardná odchýlka hodnôt v jednotlivých blokoch, časové údaje ako deň v týždni pre daný záznam s časovou značkou a iné. Napokon budú dáta rozdelené do požadovaných dátových sád, ktoré sa využijú pre natrénovanie modelov na predikciu požadovaných hodnôt. Pre natrénovanie modelu bude využitá neurónová sieť typu *Long short-term memory* (LSTM) [56]. Aj keď sa získavané dáta v jednotlivých podsystémoch líšia, princíp ich spracovania bude rovnaký. Výstupom tejto fázy budú modely na predikciu dát časových radov.



Obr. 5.1: Architektúra návrhu systému pre riadenie ohrevu TUV a vykurovania domácnosti.

Tretia fáza, a teda samotné riadenie ohrevu TUV alebo vykurovania domácnosti, bude využívať modely z výstupu druhej fázy, ako aj časť nameraných dát z databázy za posledné časové obdobie, teda výstup z prvej fázy. Zároveň bude využívať vytvorené hardvérové zariadenie z prvej fázy podsystemu. Na začiatku bude z databázy získaná časť nameraných dát, ktorá prejde rovnakým procesom spracovania ako dáta v druhej fáze a následne budú tieto dáta spolu s načítanými modelmi slúžiť pre získanie predikcie požadovaných hodnôt do predom nastaveného času v budúcnosti. Takto predikované hodnoty budú napokon využité pre rozhodnutie, či bude ohrev TUV alebo vykurovanie potrebné zapnúť alebo nie. Po získaní rozhodnutia o vypnutí / zapnutí ohrevu alebo vykurovania bude vykonanie požiadavky realizované pomocou už spomenutého vytvoreného hardvérového zariadenia (alebo programového rozhrania, ak ním ovládané zariadenie disponuje).

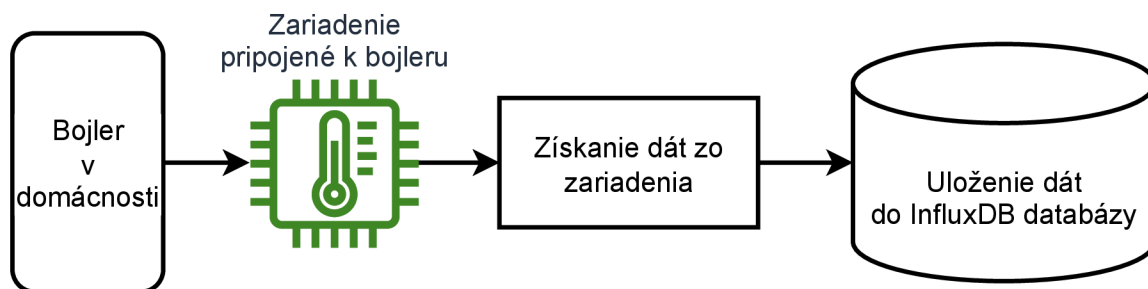
Kapitola návrhu riešenia bude rozdelená na dve hlavné sekcie – prvá sekcia bude pojednávať o podsysteme pre riadenie ohrevu TUV, druhá sekcia následne o podsysteme pre riadenie vykurovania. Zároveň obe sekcie budú delené na tri hlavné časti, kde každá časť bude popisovať jednu vyššie spomenutú fázu. Tieto časti budú popisovať výber jednotlivých spôsobov riešenia, typ a spôsob získania jednotlivých dát a iné.

5.1 Riadenie ohrevu teplej úžitkovej vody

Navrhnutý podsystem bude slúžiť na riadenie ohrevu TUV, ktorý bude prebiehať v elektrickom zásobníkovom ohrievači – elektrickom bojleri (ďalej len ako bojler). Riadenie ohrevu TUV v plynovom bojleri bude možný až po dodatočných úpravách podsystemu a tento spôsob nebude súčasťou navrhnutého podsystemu, nakoľko autor nemá k dispozícii takéto zariadenie a nemôže otestovať všetky náležitosti a zaručiť tak bezpečné riadenie prevádzky plynového bojleru. Navrhnutý podsystem pre riadenie ohrevu TUV bude fungovať na princípe vypínania a zapínania ovládanej elektrickej zásuvky, do ktorej bude bojler pripojený. Tak bude priamo ovládaný prívod energie do elektrickej špirály zariadenia.

Hardvérové zariadenie a zber dát z bojleru

Architektúra kroku získavania dát z bojleru je zobrazená na obrázku 5.2. Aby bolo možné samotnú predikciu do budúcnosti realizovať, bude potrebné pravidelne získavať požadované dáta z bojleru. Konkrétne, základné získavané dáta budú aktuálna spotreba elektrickej energie (ktorá bude využitá pri zobrazení štatistík), orientačná teplota vody vo vnútri



Obr. 5.2: Architektúra kroku získavania dát z bojleru v systéme pre riadenie ohrevu TÚV.

bojleru a orientačná teplota rúrky na výstup teplej vody (bude odrážať akciu spotreby teplej vody). Nakoľko samotný bojler nemá možnosť merania a odosielania požadovaných dát, bude potrebné vytvoriť externé hardvérové zariadenie, ktoré tento zber a odosielanie dát zabezpečí. Zároveň toto zariadenie musí mať možnosť ovládania daného bojleru, musí byť jednoduché na inštaláciu a malo by sa nachádzať v prijateľnej cenovej kategórii.

Pre splnenie týchto podmienok bude hardvérové zariadenie možné realizovať niekoľkými spôsobmi, ako napríklad:

- Pre získanie aktuálnej spotreby elektrickej energie:
 - Samostatný spínací modul – spínacie moduly sú k dispozícii od viacerých výrobcov, ako napríklad Shelly, Sonoff a iné. Moduly môžu disponovať Wi-Fi pripojením a tak je možné ich ovládať vzdialene, avšak ich inštalácia vyžaduje viac skúseností, nakoľko je k takémuto modulu potrebné pridať elektrickú zásuvku alebo priame pripojenie elektrických vodičov z bojleru do modulu.
 - Inteligentná elektrická zásuvka – jedná sa o jednoduchšie riešenie, kedy sa do existujúcej elektrickej zásuvky pripojí inteligentná zásuvka, do ktorej sa pripojí vidlica elektrického kábla bojleru. Opäť sú k dispozícii od mnohých výrobcov, ako Aqara, TP-Link, Shelly, Immax Neo, Sonoff a mnohé iné. Často disponujú Wi-Fi pripojením, avšak nemajú možnosť pripojenia ďalších senzorov alebo iných rozšírení.
 - Reléová doska pre modul Arduino – princíp je podobný už spomenutému spínaciemu modulu, avšak takéto reléové dosky pre svoju činnosť a komunikáciu s okolím vyžadujú mikrokontrolér, ktorý bude dosku ovládať. Riešenie je rozšíriteľné a je možné k nemu pridať mnohé senzory, avšak sa vyžaduje už spomenutá mikrokontrolérová vývojová doska Arduino, kvôli čomu môže byť toto riešenie finančne náročnejšie a značne zložitejšie na realizáciu.
- Pre získanie požadovaných teplôt:
 - Prídavný modul Shelly Addon – funguje ako rozšírenie spínacieho modulu od spoločnosti Shelly, pričom do tohoto prídavného modulu je možné pripojiť drôtové teplotné čidlá DS18B20, ktoré sú vhodné na meranie požadovaných teplôt. Výhodou je jednoduché napojenie k danému spínaciemu modulu.
 - Samostatné teplotné senzory – sú k dispozícii od viacerých výrobcov ako napríklad Aqara, Sonoff a iné, avšak mnohé senzory nie sú vhodné na meranie teploty pod ochranným plášťom bojlera alebo na výstupnej rúrke.

- Sensory pre modul Arduino – pre meranie teploty modulom Arduino je opäť možné využiť teplotné čidlá DS18B20, avšak ako pri reléovej doske, aj tu platí vysoká zložitost pri realizácii riešenia a sú potrebné skúsenosti s platformou Arduino.

Uvedených bolo len niekoľko riešení, k dispozícii sú mnohé ďalšie, ako aj komerčné riešenia disponujúce rôznymi funkciami, avšak ich cena je niekoľkonásobne vyššia ako spomenuté zariadenia.

Vzhľadom na výhody a nevýhody jednotlivých zariadení bude ako centrálna jednotka pre zber a odosielanie dát použitý spínací modul od spoločnosti Shelly, konkrétne typ modulu Shelly 1PM¹. Tento modul je možné ovládať bezdrôtovo (pripojenie pomocou Wi-Fi) pomocou mobilnej aplikácie, webového rozhrania alebo cez požiadaviek na programové rozhranie. K samotnému zariadeniu Shelly bude pripojený prídavný modul Shelly Addon² pre pripojenie dvoch teplotných čidiel DS18B20³. Toto rozšírenie modulu bude zabezpečovať získanie hodnôt požadovaných teplôt. Zariadenie bude teda schopné získať hodnoty dvoch teplôt a aktuálnej spotreby elektrickej energie. Vďaka pripojeniu zariadenia k internetu pomocou Wi-Fi budú namerané dáta pravidelne získavané a ukladané do databázy.

V rámci rozšírenia hardvérového riešenia o získanie ďalšej meranej hodnoty, konkrétne aktuálneho prietoku teplej vody, bude vhodné riešenie použitie prietokomeru zapojeného do modulu Arduino. K dispozícii je viac prietokomerov, v rámci testovania podsystemu bude použitý Mosadzný prietokomer YF-B2⁴ a modul Arduino Uno⁵. Vzhľadom na použitie prietokomeru by bolo aj pre meranie ostatných požadovaných hodnôt vhodnejšie použiť reléovú dosku a sensory pre modul Arduino, avšak inštalácia prietokomeru vyžaduje zásah do vodoinštalácie a tak toto riešenie nebude vhodné pre väčšinu domácností, kde by mohol byť podsystem nasadený. Pre otestovanie tohoto rozšírenia bude prietokomer nasadený do jednej testovanej domácnosti.

Samotné získavanie a ukladanie dát do databázy bude zabezpečené softvérovým skriptom. Tento skript bude pravidelnými dotazmi na programové rozhranie Shelly získavať všetky požadované hodnoty, ktoré následne upraví do požadovaného formátu a vloží do lokálnej databázy. K dispozícii je niekoľko databáz popísaných v 4.1. Pre tento podsystem bude využitá databáza InfluxDB verzie 2.

Model predikcie časových radov

Architektúra kroku tvorby modelu na predikciu časových radov je zobrazená na obrázku 5.3. Na začiatku tohoto kroku budú namerané dáta teplôt získané zo spomenutej databázy. Nasledovať bude proces spracovania a rozšírenia dát. Proces spracovania začne spojením dát časových radov do väčších časových blokov, pričom pre každú premennú v danom bloku bude vypočítaná priemerná hodnota zo všetkých hodnôt tejto premennej spadajúcej do konkrétneho časového bloku. To sa nazýva prevzorkovanie alebo agregovanie dát [47]. Ide teda o proces, kedy bude znížený počet celkových záznamov, nakoľko merané veličiny budú pri ohreve TÚV a vykurovaní domácnosti väčšinu času stabilné a zmeny týchto teplôt

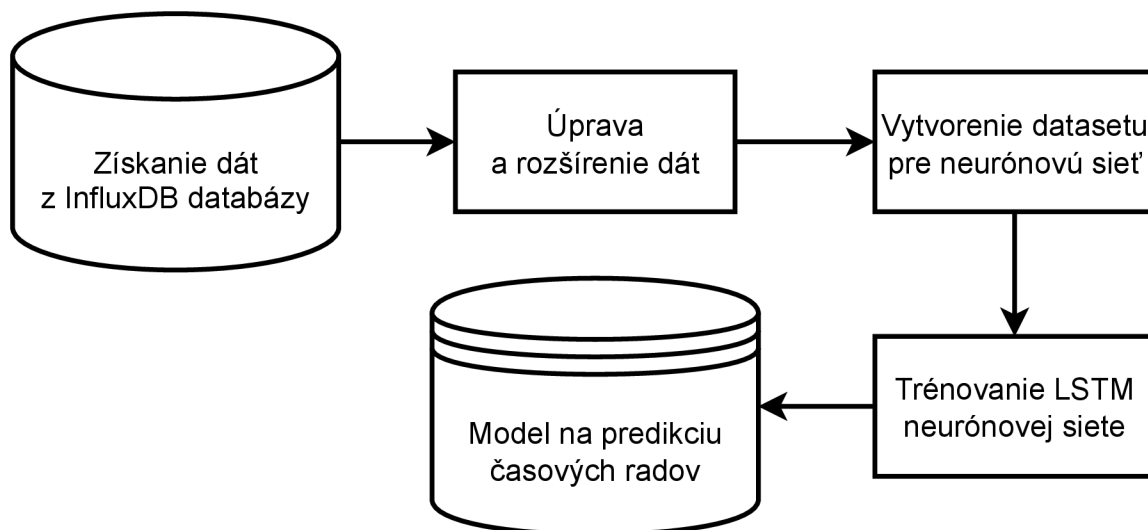
¹<https://www.alza.sk/shelly-1pm-spinaci-modul-s-meranim-spotreby-1-16-a-wifi-d5792563.htm>

²<https://www.dasmart.sk/teplotne-senzory/shelly-addon-teplotny-modul-pre-shelly-11pm-s-cidlom>

³<https://www.shelly.cloud/en/products/shop/ds18b20x1>

⁴<https://dratek.cz/arduino/74950-mosazny-prutokomer-yf-b7-m8-1-2-1-251-min-5-15v-s-termistorem.html>

⁵<https://dratek.cz/arduino/974-eses-klon-arduino-uno-r3-precise.html>

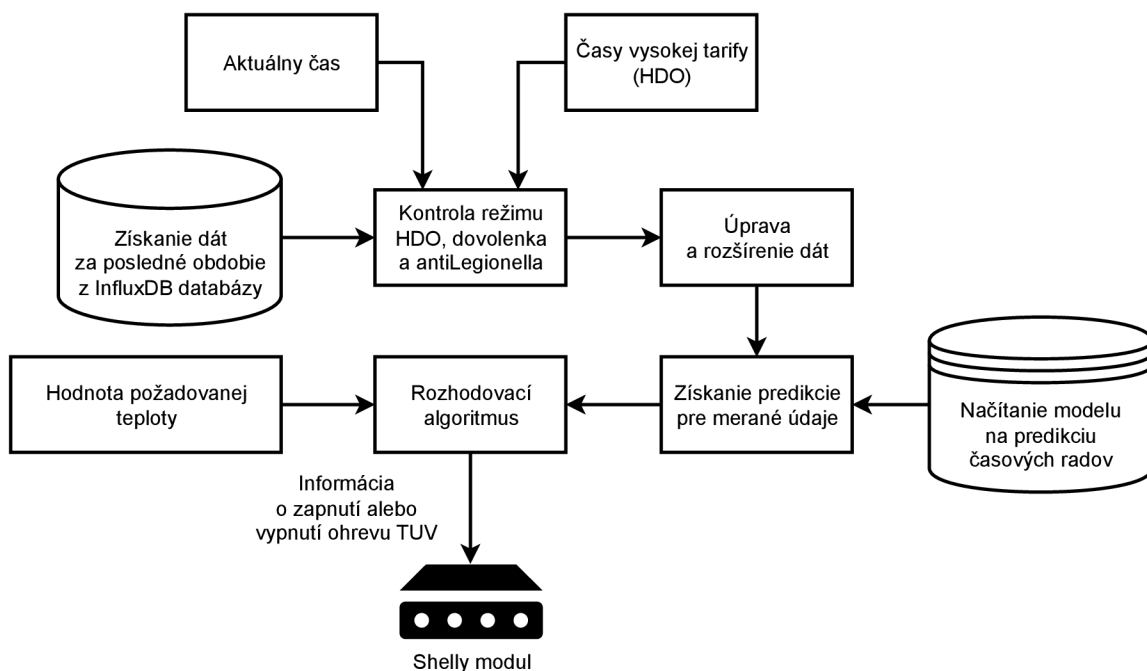


Obr. 5.3: Architektúra kroku tvorby modelu na predikciu časových radov v systéme pre riadenie ohrevu TÚV.

nie sú príliš dynamické – bez spotreby vody je teplotná strata pri 100 litrovom bojleri vo vykurovanej miestnosti za jednu hodinu približne $0,5^{\circ}\text{C}$, pri priemernej spotrebe teplej vody bez zapnutého ohrevu je teplotná strata približne 1°C za desať minút, pri zapnutom ohreve TÚV je teplotný zisk približne $0,5^{\circ}\text{C}$ za desať minút. Z toho dôvodu bude vzorkovacia frekvencia zvolená na desať minút, nakoľko dostatočne presne odráža zmeny meraných teplôt.

Následne budú tieto dáta rozšírené o vlastnosti meraných hodnôt ako štandardná odchýlka hodnôt v každom bloku, maximálna a minimálna hodnota premennej v bloku a rozdiel hodnoty oproti predošlému bloku – tieto rozšírenia pomáhajú v „zobrazení“, ako sa jednotlivé dáta v čase menia. Zároveň budú dáta rozšírené o vlastnosti týkajúce sa časových značiek, konkrétne pridanie čísla dňa v týždni a sínusu a kosínusu pre deň a týždeň, ktoré zobrazuje cyklické opakovanie záznamov v danom časovom období, teda napríklad informácia o tom, že vzdialenosť nedele a pondelku je menšia ako pondelku a štvrtku [8]. Všetky techniky použité pre rozšírenie dát sa nazývajú pojmom *features engineering*, teda transformácia existujúcich a pridávanie nových príznakov pre zlepšenie presnosti vytvárania modelu a aj samotnej predikcie dát. Viac techník je možné nájsť v [36, 57].

Po rozšírení dát bude potrebné vytvoriť dátovú sadu, ktorá sa použije pre tréning modelu neurónovej siete. Pri vytváraní dátovej sady bude využitá technika klzavého alebo rolovaného okna [15], kde sa zoberie niekoľko hodnôt do minulosti a k tomu sa priradí niekoľko hodnôt do budúcnosti a celé „okno“ sa posunie o jednu hodnotu ďalej, kde sa proces opäť zopakuje. Pre všetky dáta budú týmto spôsobom vytvorené „okná“, v ktorých bude minulosť a k nej priradená budúcnosť, ktorá bude danou minulosťou ovplyvnená. Následne bude dátová sada (obsahujúca vytvorené okná) rozdelená na tréningovú, validačnú a testovaciu dátovú sadu. Tieto sady dát budú následne využité ako vstup pre model neurónovej siete. Podľa 4.3 existuje viac metód, respektíve neurónových sietí vhodných na predikciu dát časových radov. Vzhľadom na uvedené výhody a nevýhody v danej kapitole bude v systéme využitá rekurentná neurónová sieť typu LSTM [49, 11], ktorej výstupom bude model predpovedajúci budúcnosť, konkrétne hodnoty požadovaných dát niekoľko časových jednotiek do budúcnosti.



Obr. 5.4: Architektúra kroku riadenia ohrevu TUV v systéme.

Riadenie ohrevu teplej úžitkovej vody

Poslednou časťou bude samotné ovládanie ohrevu TUV v bojleri. Architektúra kroku riadenia ohrevu TUV je zobrazená na obrázku 5.4. Posledná časť bude využívať výstupy z prvej aj druhej fázy podsystému – časť nameraných dát uložených v databáze (hodnoty teploty vody vo vnútri bojleru a na výstupnej rúrke a prípadne aktuálneho prietoku teplej vody) a modely na predikciu dát natrénované pomocou spomenutej neurónovej siete typu LSTM. Nakoniec bude v tretej fáze podsystému opäť využité vytvorené hardvérové zariadenie.

Pri procese riadenia ohrevu TUV v bojleri budú na začiatku vykonané prvotné funkcie, konkrétne kontrola na vysokú tarifu, kontrola na funkcie „Dovolenka“ a *AntiLegionella*. Kontrola vysokej tarify 3.1 bude využívať časy vysokej tarify, ktoré uvedie používateľ do konfiguračného súboru. Ak čas vysokej tarify nebude v konfiguračnom súbore uvedený alebo domácnosť nemá k dispozícii dvojtarifný elektromer, podsystém bude pracovať rovnako počas celého dňa. V prípade, že predikovaná budúcnosť bude v čase vysokej tarify, podsystém nebude zapínať ohrev TUV. Rovnaký princíp bude využitý aj pri kontrole režimu „dovolenka“, a teda v prípade, že používateľ vo svojom kalendári spoločnosti Google⁶ vytvorí udalosť „Dovolenka“, v tom čase nebude realizovaný ohrev vody v bojleri, voda bude iba udržiavaná na nízkej teplote pre zamedzenie šírenia baktérie *Legionella*. Funkcia *AntiLegionella* jedenkrát mesačne zvýši teplotu vody v bojleri nad teplotu 70°C pre zničenie baktérie *Legionella* popísanej v 3.1.

Následne bude využitá časť (niekoľko posledných hodín alebo dní) nameraných dát, ktoré sa rovnakým spôsobom ako v prípade druhej fázy načítajú z databázy. Na tieto dáta bude aplikovaný rovnaký proces spracovania a rozšírenia dát ako v predošlej fáze, nakoľko pre predikciu dát do budúcnosti budú potrebné aktuálne dáta v rovnakom formáte ako dáta, ktoré budú použité na tvorbu modelu. Aktuálne namerané hodnoty za posledné

⁶Dostupný na adrese <https://calendar.google.com/calendar/>.

časové obdobie spolu s vytvoreným modelom budú využité na predikciu dát do budúcnosti – predikcia teploty vody v bojleri (`teplota_1`) a predikcia teploty vody v rúrke na výstup teplej vody (`teplota_2`).

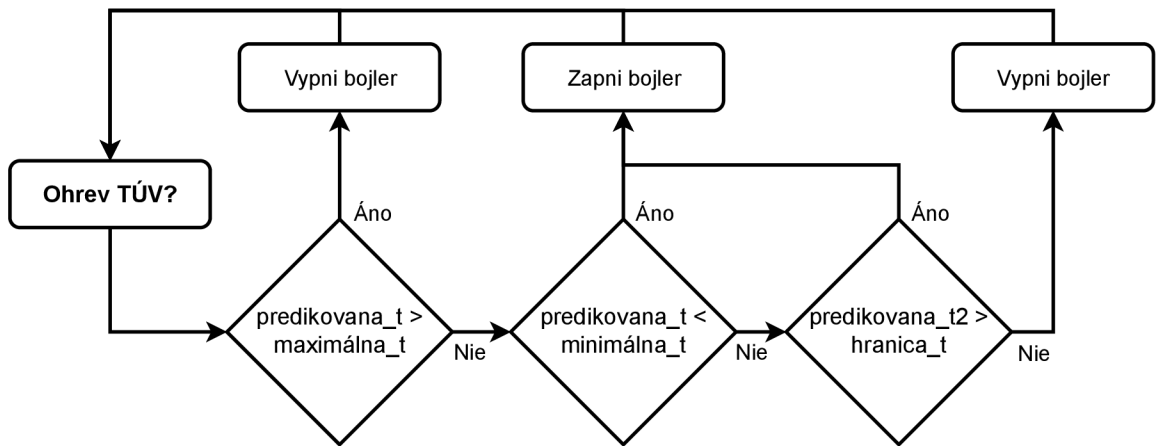
Z požadovanej teploty vody v bojleri uvedenej v konfiguračnom súbore, v základe nastavená na 60°C, (ktorú si používateľ môže podľa jeho požiadaviek upraviť) bude vypočítaný rozsah hodnôt, v ktorom sa bude daná teplota pohybovať. Napríklad, pri teplote 60°C, vypočítaný rozsah bude 53°C až 57°C, nakoľko reálna teplota odoberanej vody z bojleru je vyššia ako meraná teplota. Z požadovanej teploty vody bude zároveň určená hodnota „druhej“ teploty, ktorá predstavuje hranicu, či sa používa teplá voda alebo nie. Napríklad, ak bude opäť požadovaná teplota 60°C, hranica spotreby vody bude 44°C. Následne budú predikované dáta a vypočítané hodnoty požadovanej teploty využité v „rozhodovacej“ funkcii. Konkrétne rozhodovanie bude prebiehať princípom porovnávania predikovaných teplôt, vypočítanou dolnou a hornou hranicou požadovanej prvej teploty a vypočítanou hranicou druhej teploty odpovedajúcej použitiu teplej vody. Základná rozhodovacia funkcia bude pozostávať z najmenej štyroch pravidiel:

1. ak je predikovaná `teplota_1` vyššia ako horná hranica požadovanej prvej teploty, vypni ohrev
2. ak je predikovaná `teplota_1` v rozsahu požadovanej teploty a predikovaná `teplota_2` je pod hranicou (neočakáva sa spotreba), vypni ohrev
3. ak je predikovaná `teplota_1` v rozsahu požadovanej teploty a predikovaná `teplota_2` je nad hranicou (očakáva sa spotreba), zapni ohrev
4. ak je predikovaná `teplota_1` nižšia ako dolná hranica požadovanej prvej teploty, zapni ohrev

Vývojový diagram pre popísané pravidlá je zobrazený na obrázku 5.5. Rozhodovacia funkcia bude môcť byť ďalej rozšírená podľa požiadaviek používateľa.

Napríklad, ak bude predikovaná orientačná teplota vody vo vnútri bojleru 58°C a požadovaná teplota bude 60°C, ohrev vody sa vypne alebo ostane vypnutý. Ak orientačná teplota vody klesne na 55°C, avšak v blízkej budúcnosti sa nebude očakávať spotreba teplej vody, ohrev vody ostane vypnutý. V prípade rovnakej orientačnej teploty vody vo vnútri bojleru, avšak v blízkej budúcnosti sa bude očakávať spotreba vody (podľa naučených opakujúcich sa návykov / činností osôb v domácnosti), ohrev vody v bojleri sa zapne (až do doby, kým predikovaná teplota vody vo vnútri bojleru nepresiahne hornú hranicu požadovanej teploty, a teda 57°C, alebo sa už nebude očakávať ďalšia spotreba vody). Nakoniec, ak predikovaná teplota vody klesne pod 53°C, ohrev vody sa zapne, kým teplota vody nepresiahne spodnú hranicu požadovanej teploty, a teda 53°C – následne sa opäť bude rozhodovať podľa toho, či sa očakáva spotreba teplej vody alebo nie.

Celý proces riadenia ohrevu TÚV z pohľadu používateľa bude vyzeráť tak, že používateľ v konfiguračnom súbore môže upraviť želanú teplotu vody v bojleri (a vyplní ostatné požadované údaje), môže vyplniť časy vysokej tarify (ak je k dispozícii dvojtarifná sieť) a na vstavanom termostate bojleru zvýši teplotu na 70-75°C. Zvyšný proces riadenia ohrevu TÚV bude prebiehať automaticky a nevyžadujú sa ďalšie zásahy používateľa do chodu podsystému.



Obr. 5.5: Vývojový diagram pre popis rozhodovania ovládania ohrevu TUV. Hodnota `predikovana_t` je predikovaná teplota vody v bojleri, hodnoty `maximálna_t` a `minimálna_t` sú vypočítané hranice požadovanej teploty vody v bojleri. Informácia, či sa očakáva spotreba TUV je získaná z predikovanej druhej teploty `predikovana_t2`, ktorá pri prekročení nastavenej hranice `hranica_t` odráža akciu spotreby TUV.

5.2 Riadenie vykurovania domácnosti

Činnosť podsystemu na riadenie vykurovania domácnosti bude závisieť od typu ovládaného vykurovania. Možnosti vykurovania domácnosti sú popísané v 3.2. Podsystem bude opäť možné rozdeliť na tri časti, a to zber dát, vytvorenie modelu na predikovanie časových radov a samotné riadenie vykurovania. Ako v prípade predošlého podsystemu, aj tu budú všetky tri časti pracovať nezávisle na sebe, avšak budú využívať spoločné prvky – databázu s nameranými dátami, modely vytvorené neurónovou sieťou typu LSTM a vytvorené hardvérové zariadenie. Fungovanie podsystemu bude z väčšej časti podobné fungovaniu podsystemu pre ohrev TUV – z toho vyplýva, že sa budú využívať podobné alebo rovnaké funkcie. Sekcia bude popisovať obecný prístup k riadeniu vykurovania domácnosti, ktorý je možný použiť na viaceré typy vykurovania. Platí však, že systém bude vhodný pre nasadenie v domácnostiach s plynovým alebo elektrickým vykurovaním.

Vzhľadom na dostupné vykurovacie zariadenia, ktoré budú neskôr použité na testovanie podsystemu, budú popísané tri prístupy ovládania vykurovacieho zariadenia – nahradenie klasického termostatu za ovládaný spínací modul, ovládanie inteligentnej termostatickej hlavice alebo vzdialené ovládanie vykurovacieho zariadenia disponujúceho pripojením k internetu a možnosťou vzdialeného ovládania.

Hardvérové zariadenie a zber dát z domácnosti

Pre realizáciu zberu potrebných dát o domácnosti bude opäť potrebné vytvoriť hardvérové zariadenie, ktoré toto získanie dát zabezpečí. Na rozdiel od zariadenia pre zber dát z bojleru bude v tomto podsysteme potrebné vytvoriť zariadenie, ktoré bude mať možnosť získavať údaje z viacerých miestností domácnosti, preto budú využité bezdrôtové senzory. Požadované dáta závisia od požiadaviek používateľa a dostupných senzorov. Základné potrebné dáta budú aspoň jedna „centrálne“ teplota miestnosti a informácia o prítomnosti osôb v domácnosti, ktorá bude môcť byť realizovaná viacerými spôsobmi, ako napríklad

GPS lokácia mobilných telefónov používateľov (vzdialenosť od domácnosti alebo informácia, či sa mobilný telefón nachádza v predom nastavenej zóne okolo domácnosti), pohybový senzor alebo informácia o spotrebe teplej vody, ak domácnosť bude využívať aj podsystem pre riadenie ohrevu TÚV. Medzi rozširujúce údaje budú patriť teploty z iných miestností pre využitie zónového vykurovania (každá miestnosť domácnosti bude môcť byť vykurovaná na inú teplotu, ak bude k dispozícii zariadenie na reguláciu kúrenia pre danú miestnosť – napríklad termostatické ventily) alebo vlhkosť v daných miestnostiach (lepšie riadenie pociťovej teploty). Po úprave podsystemu bude zároveň možné využiť meteorologické údaje (slnko svietiace do miestnosti, teplota a počasie vonku a iné). Ako v prípade prvého podsystemu, tak ani pri vykurovaní domácnosti nemá samotný kotol možnosť zbierať všetky potrebné údaje a tak bude vytvorené hardvérové zariadenie, ktoré túto činnosť zabezpečí – zároveň by opäť malo byť jednoduché na inštaláciu a v prijateľnej cenovej kategórii.

Samotné hardvérové zariadenie bude možné rozdeliť na dve časti – senzory pre zber dát a centrálna jednotka pre komunikáciu so senzormi a komunikáciu so softvérovou časťou podsystemu. K dispozícii je veľké množstvo bezdrôtových senzorov na meranie teploty, napríklad od spoločností Sonoff, Tuya, Aqara a iné. Pohybové senzory pre údaje o prítomnosti osôb v domácnosti opäť môžu byť od spoločností Sonoff, Tuya, Aqara a mnohé iné. Oba typy senzorov pre komunikáciu najčastejšie využívajú Bluetooth Low Energy (BLE), Wi-Fi alebo ZigBee. Ako centrálna jednotka môže slúžiť notebook alebo počítač, ale v tom prípade sa vyžaduje nepretržitá prevádzka tohoto zariadenia, čo nie je príliš vhodné. Z toho dôvodu sa ako centrálna jednotky v inteligentných domácnostiach využívajú minipočítače, napríklad Raspberry Pi, alebo mikrokontrolérové vývojové dosky ako Arduino.

V prípade, že kotol alebo pripojený termostat nebude možné ovládať vzdialene cez internet, termostat bude nahradený za inteligentný spínací modul, napríklad spínací modul od spoločnosti Shelly – v tomto prípade bude dôležité, aby mal spínací modul „suchý kontakt“, teda možnosť prepojenia vodičov bez privedenia externého napätia do týchto vodičov. Tento spínací modul bude tak možné využiť aj pri zónovom vykurovaní realizovanom elektrickým podlahovým kúrením, kde pre každú miestnosť je samostatný obvod so samostatným termostatom. V rámci zónového vykurovania, ak sú pre vykurovanie miestností v domácnosti využité radiátory, budú môcť byť využité inteligentné termostatické hlavice, napríklad od spoločností Tesla, Tuya, Immax NEO, Aqara a iné. Inteligentné termostatické hlavice sú však drahšie (cena za jednu termostatickú hlavicu sa pohybuje približne od 850 do 2500 Kč) a preto treba počítať s vyššími prvotnými nákladmi.

V rámci riešenia podsystemu budú využité teplotné senzory Aqara⁷, pohybový senzor Sonoff⁸ a ako centrálna jednotka Raspberry Pi 4⁹ s operačným systémom HomeAssistant. Komunikácia medzi Raspberry Pi 4 a senzormi bude realizovaná technológiou ZigBee, pričom ZigBee sieť bude vytvorená pomocou Sonoff ZigBee USB 3.0 Dongle¹⁰. Raspberry Pi 4 bude k internetu pre vzdialené ovládanie pripojené cez LAN alebo Wi-Fi. Ako spínací modul pre nahradenie klasického termostatu bude slúžiť Shelly Plus 1¹¹, pre ovládanie radiátorov budú slúžiť termostatické hlavice Immax NEO Smart¹².

Softvérová časť prvej fázy podsystemu je realizovaná priamo v softvéri HomeAssistant¹³ (ďalej ako skratka HA), v ktorom bude pomocou vstavaných rozšírení vytvorená databáza

⁷<https://www.aqara.com/eu/product/temperature-humidity-sensor/>

⁸<https://sonoff.tech/product/gateway-and-sensors/snz-03/>

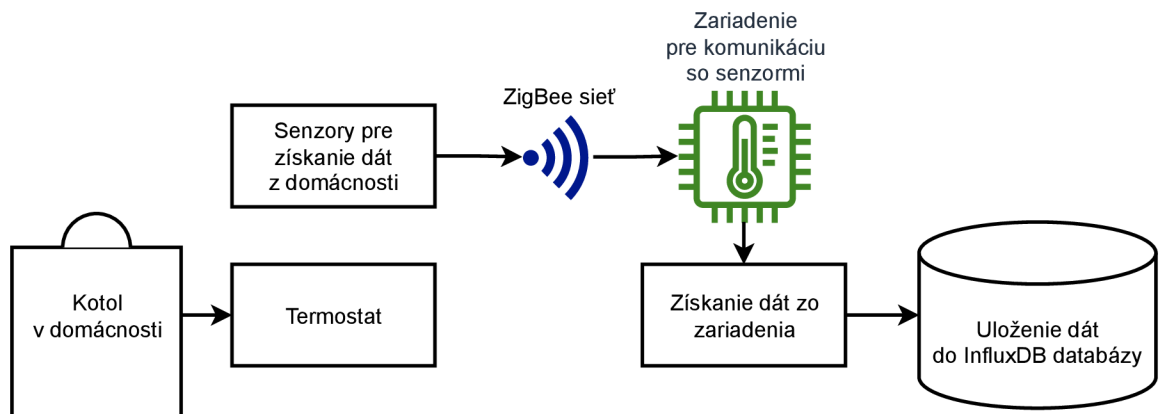
⁹<https://www.raspberrypi.com/products/raspberry-pi-4-model-b/>

¹⁰<https://sonoff.tech/product/gateway-and-sensors/sonoff-zigbee-3-0-usb-dongle-plus-e/>

¹¹<https://www.shelly.cloud/en/products/shop/shelly-plus-1>

¹²<https://www.immax.sk/immax-neo-smart-termostatica-hlavice-zigbee-p13447/>

¹³<https://www.home-assistant.io/>



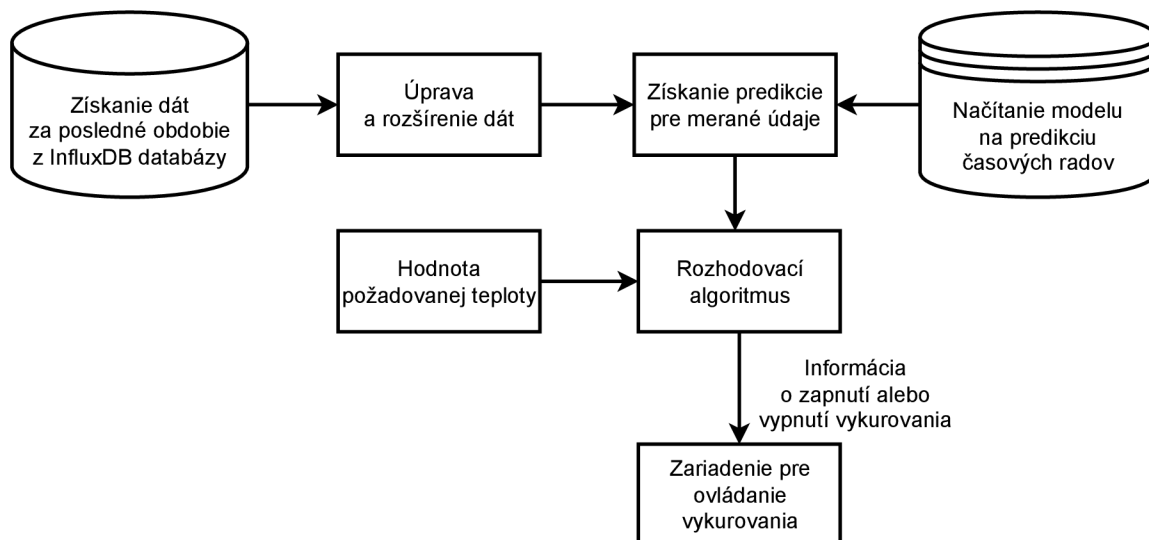
Obr. 5.6: Architektúra kroku získavania dát z domácnosti v systéme pre riadenie vykurovania.

časových radov, konkrétne InfluxDB verzie 1. Údaje zo všetkých senzorov budú ukladané do tejto databázy. Následná vzdialená komunikácia s Raspberry Pi 4, respektíve softvérom HA, bude možná cez lokálnu sieť alebo pomocou VPN, napríklad Tailscale. Nakoľko všetky vybrané senzory budú napájané batériou a teda dáta do databázy budú posielať iba vtedy, keď sa merané hodnoty zmenia, každý senzor bude odosielať dáta v inú dobu a preto budú v databáze ukladané vo formáte `čas`, `názov_senzoru`, `hodnota`. Návrh kroku pre zber požadovaných dát z domácnosti je zobrazený na obrázku 5.6.

Model predikcie časových radov

Na začiatku bude opäť potrebné získať namerané dáta z databázy v softvéri HA, pre ktoré bude využité spomenuté VPN Tailscale. Po získaní dát z databázy prejdú dáta procesom spracovania a rozšírenia. Na začiatku sa z formátu `čas`, `názov_senzoru`, `hodnota` vytvorí tabuľkový formát – `čas`, `hodnota_senzor1`, `hodnota_senzor2`, `hodnota_senzor3`, ... Prázdne hodnoty v jednotlivých časoch budú vyplnené z predošlých hodnôt (predpokladá sa, že hodnota meraná daným senzorom sa od posledného merania nezmenila, bude možné ju teda „skopírovať“). Následne sa aplikuje rovnaký proces spracovania a rozšírenia dát ako v prípade tvorby modelu predikcie časových radov pre podsystem na riadenie ohrevu TÚV popísaného v 5.1 – prevzorkovanie dát do väčších časových blokov, rozšírenie o štandardnú odchýlku, maximálnu a minimálnu hodnotu premennej v bloku, rozdiel hodnoty oproti hodnote rovnakej premennej v predošlom bloku a rozšírenie o vlastnosti časových značiek (pridanie čísla dňa v týždni, sínus a kosínus pre deň a týždeň).

Po rozšírení dát bude opäť využitá technika kĺzavého okna na všetky hodnoty a na všetky premenné, pre ktoré bude vytvorený model predikcie – konkrétne teploty zo všetkých senzorov a údaje o prítomnosti osôb v domácnosti. Následne bude dátová sada obsahujúca vytvorené okná rozdelená na tréningovú, validačnú a testovaciu dátovú sadu. Tieto sady dát sa následne využijú ako vstup pre neurónovú sieť. Ako v prípade predošlého podsystemu, aj pre tento podsystem sa pre vytvorenie modelov predikcie časových radov použije rekurentná neurónová sieť, konkrétne typ *Long-short Term Memory* (LSTM). Návrh riešenia pre tvorbu modelu bude rovnaký ako v predošlom podsysteme, ktorého architektúra je zobrazená na obrázku 5.3.



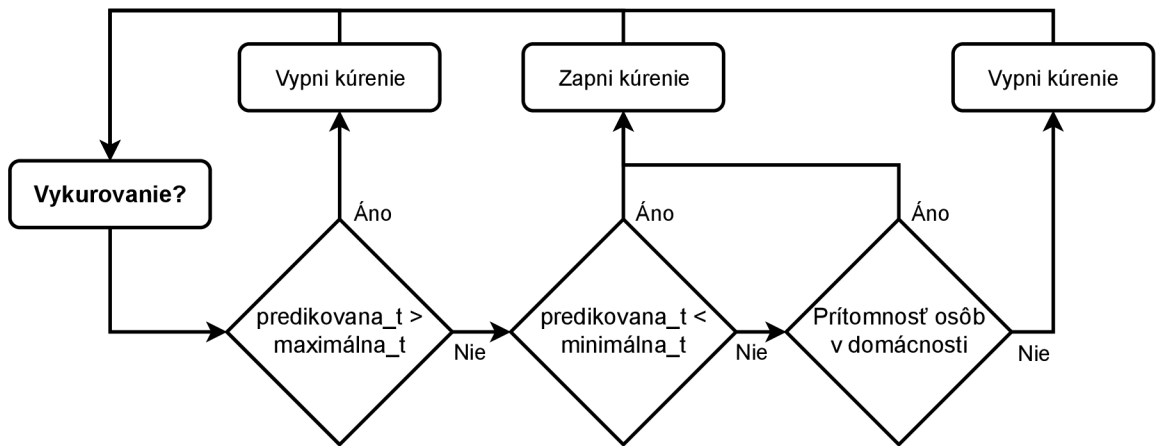
Obr. 5.7: Architektúra kroku riadenia vykurovania domácnosti.

Ovládanie vykurovania domácnosti

Posledná fáza – ovládanie vykurovania domácnosti – bude ako v prípade ovládania podsystemu pre ohrev TÚV využívať modely na predikciu budúcnosti a namerané dáta uložené v databáze hardvérového zariadenia. Na začiatku sa vykonajú prvotné funkcie, a teda kontrola režimu „dovolenka“ a v prípade elektrického vykurovania domácnosti aj kontrola na vysokú tarifu. Podrobnejší popis je uvedený v 5.1. Architektúra návrhu riešenia pre krok ovládania vykurovania je zobrazená na obrázku 5.7.

Následne bude využitá časť nameraných dát, ktoré prejdú rovnakým procesom načítania dát z databázy, spracovania a rozšírenia. Aktuálne dáta za posledné časové obdobie budú spolu s vytvorenými modelmi využité na predikciu požadovaných dát do budúcnosti – teploty z jednotlivých meraných miestností, ako aj informácia o prítomnosti osôb v domácnosti. Používateľ do konfiguračného súboru vyplní požadovanú teplotu (pre každú miestnosť v prípade zónového vykurovania) a prípadne časy vysokej tarify, ak domácnosť využíva elektrické vykurovanie a má k dispozícii dvojtarifnú sieť. Z požadovanej teploty bude opäť vypočítaný rozsah, a teda dolná a horná hranica požadovanej teploty, ktoré sa použijú pri finálnom rozhodovaní. Nakoniec, keď sú získané požadované a aj predikované teploty, je opäť možné vykonať „funkciu rozhodovania“. Množstvo pravidiel, ktoré budú v rozhodovacej funkcii použité, závisí od počtu miestností a dostupných sensorov, avšak ako v predošlom podsysteme, aj tu budú použité minimálne štyri pravidlá pre každú miestnosť samostatne, v ktorej bude riadené vykurovanie:

1. ak je predikovaná teplota vyššia ako horná hranica požadovanej teploty, vypni vykurovanie
2. ak je predikovaná teplota v rozsahu požadovanej teploty, ale neočakáva sa prítomnosť osôb v domácnosti, vypni vykurovanie
3. ak je predikovaná teplota v miestnosti v rozsahu požadovanej teploty, ale očakáva sa prítomnosť osôb v domácnosti, zapni vykurovanie



Obr. 5.8: Vývojový diagram pre popis rozhodovania ovládania vykurovania domácnosti. Hodnota `predikovana_t` je predikovaná teplota vzduchu v danej miestnosti, hodnoty `maximálna_t` a `minimálna_t` sú vypočítané hranice požadovanej teploty.

- ak je predikovaná teplota nižšia ako dolná hranica požadovanej teploty, zapni vykurovanie

Vývojový diagram pre popísané pravidlá je zobrazený na obrázku 5.8. Autor práce bude môcť ďalej rozširovať systém o ďalšie pravidlá podľa požiadaviek používateľov.

Samotné požiadavky „vypni vykurovanie“ a „zapni vykurovanie“ budú realizované rôzne, podľa ovládaného zariadenia. V prípade, že bude klasický termostat nahradený spínacím modulom Shelly, požiadavka bude odoslaná práve na programové rozhranie daného spínacieho modulu. Ak bude zariadenie (kotel alebo termostat) disponovať pripojením k internetu a možnosťou vzdialeného ovládania, požiadavka bude odoslaná cez programové rozhranie tohoto zariadenia. Nakoniec, ak ovládané zariadenie bude inteligentná hlavica, požiadavka bude odoslaná na ňu.

Kapitola 6

Implementácia systému

Táto kapitola sa zameriava na popis implementácie systému pre prediktívne riadenie ohrevu teplej úžitkovej vody (TÚV) a vykurovania domácnosti pomocou metód strojového učenia, ktorého návrh bol popísaný v kapitole 5. Kapitola je rozdelená na tri časti – použité technológie, popis implementácie podsystému pre riadenie ohrevu TÚV a popis implementácie podsystému pre vykurovanie domácnosti. Nakoľko oba podsystémy majú niektoré funkcie podobné, popis prvého podsystému bude podrobnejší a popis niektorých častí druhého podsystému sa bude odkazovať na predošlú sekciu. Viac podrobností o jednotlivých funkciách v implementácii je možné nájsť v komentároch zdrojových kódov. Samotné sekcie implementácie jednotlivých podsystémov budú rozdelené na popis hardvérového riešenia, zber a ukladanie nameraných dát, tréningovanie neurónovej siete a tvorba modelu, riadenie ohrevu TÚV alebo vykurovania domácnosti a nakoniec prípadné pomocné nástroje.

6.1 Použité technológie

Systém a jeho pomocné skripty sú implementované v programovacom jazyku Python vo verzii 3.10. Pre prácu s dátami, tvorbou dátových rámcov a matíc sú použité knižnice Pandas¹ a NumPy². Pre ukladanie nazbieraných dát je využitá databáza InfluxDB³ vo verziách 1.X a 2.X. Druhá verzia databázy je realizovaná ako kontajner v softvéri Docker⁴. Pre predikciu budúcnosti s využitím dát časových radov je použitá rekurentná neurónová sieť typu *Long short-term memory* (LSTM), konkrétne implementácia v jazyku Python za použitia softvéru TensorFlow⁵ a rozhrania Keras⁶. Implementácia a testovanie systému prebiehalo na OS Windows 10. Hardvérové riešenie druhého podsystému využíva softvér HomeAssistant⁷ so vstavanými rozšíreniami, konkrétne rozšírenia InfluxDB, Mosquitto broker, Tailscale a Zigbee2MQTT.

¹<https://pandas.pydata.org/>

²<https://numpy.org/>

³<https://www.influxdata.com/>

⁴<https://www.docker.com/>

⁵<https://www.tensorflow.org/>

⁶<https://keras.io/>

⁷<https://www.home-assistant.io/>

6.2 Implementácia podsystému pre riadenie ohrevu teplej úžitkovej vody

Táto sekcia popisuje dôležité časti finálnej implementácie podsystému riadenia ohrevu TÚV. Na začiatku je stručne uvedená finálna realizácia hardvérového zariadenia pre zber dát a riadenie elektrického bojleru, následne sa kapitola venuje popisu skriptov podľa jednotlivých častí, dôležitým knižniciam, funkciám využitým v podsystéme a pomocným nástrojom použitým pri implementácii riešenia.

Podsystém pracuje s nameranými hodnotami troch (pri rozšírení hardvérového zariadenia štyroch) veličín – aktuálna spotreba elektrickej energie (využíva sa pre zobrazenie štatistík, pri tvorbe modelu a rozhodovaní o ovládaní ohrevu TÚV sa nevyužíva), orientačná teplota vody vo vnútri bojlera (`teplota_1`), teplota rúrky na výstup teplej vody z bojleru odrážajúca akciu spotreby teplej vody (`teplota_2`), pri rozšírení hardvérového zariadenia aktuálny prietok teplej vody cez výstupnú rúrku, konkrétne množstvo pretečenej vody za nastavenú jednotku času (rozširuje informáciu o akcii spotreby teplej vody – údaj je využitý pri tvorbe modelu pre `teplota_2`). Spomenuté veličiny sú zároveň rozšírené o vlastnosti týkajúce sa časových značiek.

V rámci behu celého podsystému sa využíva `water_heating_conf_file.json` – konfiguračný súbor vo formáte JSON, obsahujúci všetky potrebné údaje podsystému, konkrétne:

- Požadovaná (orientačná) teplota vody vo vnútri bojlera – nahradzuje nastavenie teploty na termostate bojlera.
- Informácie o bojleri – môžu byť v rámci budúceho rozšírenia využité pre vytvorenie modelu bojleru, a teda výpočtu rýchlosti ohrevu vody v bojleri.
- Údaje o module Shelly – centrálnej jednotke hardvérového zariadenia – informácie slúžia pre možnosť komunikácie s týmto modulom.
- Údaje o použitej databáze pre ukladanie nameraných dát – slúžia na vytvorenie spojenia, možnosti zápisu do databázy a čítania z nej.
- Časy vysokej tarify – ak domácnosť disponuje dvojtarifnou sieťou a zariadenie nie je pripojené k obvodu, ktorý je odpájaný HDO stýkačom.
- Informácie, či sa majú využiť funkcie `antiLegionella` a `Dovolenka`.
- Údaje o prietokomere – či je v domácnosti prietokomer využitý a údaje pre pripojenie zariadenia Arduino k podsystému.
- Nastavenia podsystému – časy opakovania získavania dát, pretrénovania modelu neurónovej siete, riadenia ohrevu TÚV, veľkosť jedného okna pri procese prevzorkovania a veľkosť posuvného okna pred procesom tréningu modelu neurónovej siete.

Konfiguračný súbor je jediný súbor, ktorý je potrebné pre správne fungovanie podsystému upraviť. Jednotlivé časti a skripty podsystému zároveň využívajú spoločné funkcie zo skriptu `boiler_utils.py`. Jedná sa o funkcie:

- `get_data_from_db()` – získanie dát z InfluxDB databázy. Pre inicializáciu klienta⁸ pre spojenie s databázou sa využíva funkcia `InfluxDBClient()`, ktorá vyžaduje vyššie

⁸Celý postup je možné nájsť v oficiálnej dokumentácii na adrese <https://docs.influxdata.com/influxdb/cloud/api-guide/client-libraries/python/>.

spomenuté údaje o použitej databáze, následne sa vytvorí spojenie pre požiadavky a za použitia požiadavky v jazyku Flux⁹ sa pomocou funkcie `query_data_frame()` stiahnu všetky požadované dáta z databázy v časovom rozmedzí špecifikovanom v požiadavke. Funkcia teda vracia uložené dáta vo formáte `Dataframe` z knižnice `pandas`.

- `get_data_from_conf_file()` – načítanie všetkých dát z konfiguračného súboru.
- `transform_and_extend_dataset()` – spracovanie a rozšírenie dát, konkrétne operácie súhrnne nazývané pojmom *Features engineering* [36] popísaného v 5.1. Proces začína prevzorkovaním (spojením údajov do desaťminútových blokov) [47], následne sa pre každú veličinu v bloku vypočíta štandardná odchýlka, minimálna a maximálna hodnota. Pre všetky tieto operácie sa využíva funkcia `groupby()` z knižnice `pandas`. Pre výpočet rozdielu hodnoty z jedného bloku oproti predošlému bloku je využitá funkcia `diff()` z rovnakej knižnice. Nakoniec prebieha výpočet vlastností týkajúcich sa časových značiek, a teda pridanie čísla dňa v týždni a sínusu a kosínusu pre deň a týždeň [8]. Na to sa využívajú funkcie z knižníc `pandas` a `NumPy`. Výstupom je prevzorkovaná a rozšírená dátová sada.
- `split_dataset()` – rozdelenie dátovej sady. Nakoľko predikované hodnoty sú dve merané teploty, celá dátová sada sa rozdelí na dve menšie – každá dátová sada obsahuje jednu teplotu a k nej priradené údaje z procesu rozšírenia dát.

Všetky hlavné skripty sa vykonávajú v nekonečnom cykle, pričom na konci každého cyklu dochádza k uspaniu programu pomocou funkcie `sleep()`. Doba uspania skriptu sa líši na činnosti, ktorú skript vykonáva. Získavanie a ukladanie nameraných dát prebieha každých 90 sekúnd, pretrénovanie modelu na predikciu dát každých 24 hodín, riadenie ohrevu TÚV každých desať minút. Všetky tieto časové údaje môžu byť upravené v konfiguračnom súbore. Zároveň všetky skripty na začiatku každého cyklu vykonávajú načítanie obsahu konfiguračného súboru a okrem skriptu pre ukladanie dát aj načítanie nameraných dát z databázy.

Realizácia hardvérového zariadenia pre získavanie údajov z bojleru

Finálne hardvérové zariadenie sa skladá z dvoch častí – senzory pre získavanie požadovaných dát a centrálna jednotka pre zber dát a komunikáciu s podsystémom. Ako centrálna jednotka slúži spínací modul Shelly 1PM, pre pripojenie senzorov je využitý rozširujúci modul Shelly Addon. Získavanie požadovaných hodnôt teplôt je realizované pomocou káblových teplotných čidiel DS18B20 pripojených do rozširujúceho modulu Shelly Addon. Do modulu Shelly je privedená energia z elektrickej siete, z modulu Shelly vedú vodiče do externej elektrickej zásuvky, ktorá je týmto modulom monitorovaná a aj ovládaná. Do tejto zásuvky je zapojený prívodný kábel bojleru – modul Shelly tak môže ovládať, kedy do bojleru tečie elektrická energia a teda kedy bude realizovaný ohrev TÚV. Spínací modul Shelly 1PM a rozširujúci modul Shelly Addon môžu byť nahradené novšími zariadeniami od tejto spoločnosti, konkrétne spínací modul Shelly Plus 1PM a rozširujúci modul Shelly Addon Plus, avšak tento rozširujúci modul v čase vyhotovenia hardvérového zariadenia ešte nebol na trhu, preto vytvorené zariadenie využíva staršie moduly – obe verzie modulov však disponujú rovnakými funkciami potrebnými pre zber dát a riadenie ohrevu TÚV.

⁹<https://www.influxdata.com/products/flux/>



Obr. 6.1: Komponenty potrebné pre realizáciu hardvérového zariadenia na získavanie dát a riadenie ohrevu TÚV v elektrickom bojleri.

Komponenty pre vytvorenie finálneho hardvérového zariadenia sú zobrazené na obrázku 6.1. Samotné zariadenie bolo následne vložené do vytvoreného obalu, aby nemohlo dôjsť k dotyku živej časti zariadenia. Celé zariadenie v ochrannom obale je zobrazené na obrázku 6.2.

Pre pripojenie vytvoreného zariadenia k lokálnej Wi-Fi sieti je na začiatku potrebné sa pripojiť k prístupovému bodu vytvorenému modulom Shelly cez adresu 192.168.33.1 a v nastaveniach zariadenia zadať autentifikačné údaje k požadovanej Wi-Fi sieti. Následne je v nastaveniach zariadenia potrebné povoliť pripojenie do *cloudu* poskytovaného spoločnosťou Shelly. Vďaka tomu je možné zariadenie monitorovať a ovládať vzdialene cez internet. Pre pripojenie zariadenia ku *cloudu* stačí mať vytvorený používateľský účet na adrese <https://home.shelly.cloud/>. Následne je možné prístupový bod v nastaveniach vypnúť alebo nastaviť prihlasovacie údaje, aby nebolo možné do zariadenia prísť bez autorizácie.

Hardvérové zariadenie pre rozšírenie získavania dát o aktuálny prietok / množstvo pretečenej teplej vody na výstupnej rúrke využíva mosadzný prietokomer YF-B2, ktorý je pripojený k mikrokontrolérovej vývojovej doske Klon Arduino UNO R3 precise. Nakoľko doska Arduino v základe nedisponuje modulom pre Wi-Fi, je využité pripojenie USB k notebooku, kde je aj spustený tento podsystem. Komponenty pre pomocné zariadenie s prietokomerom sú zobrazené na obrázku 6.3.

Získavanie a ukladanie nameraných dát

Získavanie dát zo zariadenia a ich uloženie do lokálnej databázy je realizované v skripte `get_data_from_shelly.py`. Spôsob vytvorenia klienta pre komunikáciu s databázou je rovnaký ako v spomenutej funkcii pre získavanie dát z databázy, s tým rozdielom, že namiesto čítania obsahu databázy je vytvorené spojenie pre zápis dát. Následne sa vo funkcii



Obr. 6.2: Finálna realizácia hardvérového zariadenia inštalovaná do testovacích domácností.


`get_data()` pomocou POST požiadavky z knižnice `requests` na programové rozhranie Shelly Cloud získajú aktuálne informácie o Shelly zariadení. Tieto informácie sú vo formáte JSON a obsahujú aj nepotrebné údaje a tak sa z dát získajú len tie údaje, ktorú sú pre beh pod-systému relevantné – aktuálna spotreba elektrickej energie, `teplota_1` a `teplota_2`. V prípade využitia prietokomeru v domácnosti sa otvorí komunikácia s doskou Arduino (cez USB alebo internet, testovaná bola komunikácia cez USB) pomocou funkcie `Serial()`. Arduino vypisuje namerané dáta na sériovú linku, na ktorej skript „počúva“ a tieto údaje zo sériovej linky „číta“. Následne sa vytvorí záznam so všetkými nameranými údajmi a pomocou funkcie `write()` sa údaje vo formáte `aktuálny_čas`, `aktuálna_spotreba`, `teplota_1`, `teplota_2`, `aktuálny_prietok` zapíšu do databázy.

Skript `water_heating.ino`, ktorý je spustený na doske Arduino pre získavanie dát z prietokomeru¹⁰, počíta počet pulzov z prietokomeru za meranú jednotku a pomocou kalibračného faktoru vypočíta prietok – počet litrov za sekundu. Následne vypíše počet nameraných mililitrov vody pretečených cez prietokomer za určitý čas a počítadlo sa vynuluje.

Trénovanie neurónovej siete a tvorba modelu na predikciu dát

Pre tvorbu neurónovej siete a využitie nameraných dát pre model na predikciu dát do budúcnosti slúži skript `main_boiler.py`. Beh skriptu, respektíve jednotlivých cyklov, začína

¹⁰Zdrojový kód je prevzatý a upravený z <https://navody.drateg.cz/navody-k-produktum/arduino-prutokomer-1-30-1-min.html>.



Obr. 6.3: Komponenty potrebné pre realizáciu pomocného zariadenia s využitím prietokomeru pre získavanie dát o aktuálnom prietoku teplej vody.

získaním obsahu konfiguračného súboru a uložených nameraných dát z databázy za zvolené časové obdobie, napríklad údaje za posledné tri mesiace. Získané dáta sa spracujú a rozšíria a následne sa celá dátová sada rozdelí na dve menšie dátové sady, pre každú meranú teplotu jedna. Pre to sú využité spoločné funkcie zo skriptu `boiler_utils.py`. Aby mohli byť dátové sady ďalej upravované, transformujú sa z dátového rámca z knižnice `pandas` na maticu pomocou funkcie `to_numpy()`.

Nasleduje proces tvorby kľavého okna [15] – celý proces prebieha v cykle cez všetky dáta a slúži na vytvorenie „okien“ s niekoľkými vstupnými hodnotami a k nim priradenými niekoľkými výstupnými hodnotami. Z matice obsahujúcej dáta sa zoberie desať záznamov (obsahujúcich hodnotu požadovanej teploty, rozširujúce údaje priradené k danej teplote a vlastnosti týkajúce sa časovej značky), ktoré budú tvoriť vstupné dáta. Zoznam obsahujúci tieto dáta sa otočí, aby „najnovšia“ hodnota bola v zozname na prvom mieste. Následne sa vyberie päť záznamov (z celého záznamu sa vyberie iba hodnota požadovanej teploty) tvoriacich výstupné dáta, pričom prvý záznam výstupných dát odpovedá poslednému záznamu vstupných dát. Napríklad, záznamy 0–9 sú vstupné dáta, záznamy 9–13 sú k nim priradené výstupné dáta. Po vytvorení „jedného okna“ sa celý proces opakuje o jeden záznam „ďalej“ – záznamy 1–10 ako vstupné dáta, 10–14 ako výstupné dáta. Týmto spôsobom sa prejde cez celú dátovú sadu.

Potom sa dátová sada (vytvorené okná) rozdelí na tréningové, validačné a testovacie dátové sady v pomere 80:10:10, aby bolo možné ich využiť v procese učenia neurónovej siete. Nasleduje proces tvorby modelu neurónovej siete, v ktorom sú využité funkcie z knižnice `Keras`. Na začiatku sa vytvorí model neurónovej siete typu `Sequential`, ktorý predstavuje postupné lineárne usporiadanie vrstiev. Následne sa do modelu neurónovej siete pomocou funkcie `add()` pridávajú jednotlivé vrstvy – vrstva `LSTM` so 64 skrytými neurónmi a následne tri plne prepojené vrstvy `Dense` s 32, 16 a piatimi neurónmi. Využíva sa aktivačná funkcia `ReLU` pre prvé tri vrstvy a lineárna (`linear`) aktivačná funkcia pre výstupnú vrstvu, ktorá

„produkuje“ výstupné hodnoty. Ako stratová funkcia (hodnotenie chyby medzi predikciami modelu a skutočnými hodnotami cieľovej premennej) a metrika (vyhodnotenie výkonu modelu počas tréovania) je využitá metrika priemernej absolútnej chyby (**Mean Absolute Error**, MAE). Stratová funkcia a metrika sú využité pre kompiláciu modelu pomocou funkcie `compile()`, kde sa zároveň špecifikuje optimalizačný algoritmus, konkrétne optimizér Adam s rýchlosťou učenia 0,001. Pre ukladanie iba najlepšieho modelu počas tréovania je vytvorená inštancia `ModelCheckpoint()`. Následne už prebieha samotné tréovanie modelu na tréovacej dátovej sade a overuje sa na validačnej dátovej sade, tréovanie prebieha po dobu 500 epochov. Dáta sa tréujú v dávkach o veľkosti 64. Vyhodnotenie presnosti neurónovej siete na testovacej dátovej sade sa vykonáva pomocou funkcie `evaluate()`. Výstupom celého skriptu a tejto fázy podsystému sú modely na predikciu dát do budúcnosti, konkrétne jeden model pre každú tréovanú premennú, a teda model pre predikciu prvej teploty a model pre predikciu druhej teploty.

Riadenie ohrevu TÚV elektrickým bojlerom

Posledná fáza podsystému, riadenie ohrevu TÚV, prebieha v skripte `boiler_control.py`, kde sú na začiatku vykonané kontroly, následne sa predikujú hodnoty požadovaných dát do budúcnosti a nakoniec sa rozhodne o vypnutí alebo zapnutí ohrevu TÚV. Ak domácnosť využíva dvojtarifnú sieť a používateľ povolí kontrolu a uvedie časy vysokej tarify v konfiguračnom súbore, na začiatku prebieha práve táto kontrola. Z konfiguračného súboru sa získajú všetky časy vysokej tarify (ich začiatok a koniec) a následne sa kontroluje, či aktuálny čas je v niektorom z časových rozsahov vysokej tarify. Ak áno, beh skriptu sa „uspí“ až do konca aktuálneho časového rozsahu vysokej tarify a následne sa pokračuje v behu aktuálneho cyklu. Pre kontrolu vysokej tarify sa využívajú funkcie z knižnice `datetime`.

Potom sa vykonávajú funkcie „Dovolenka“ a „AntiLegionella“ – ak používateľ v konfiguračnom súbore povolí použitie týchto funkcií. Funkcia `Dovolenka` (`vacation()`) využíva integráciu internetového kalendára od spoločnosti Google¹¹. Na začiatku sa zo súboru `token.pkl` načítajú autentifikačné údaje, ktoré umožnia prístupovať ku Google kalendáru používateľa, na čo sa využíva funkcia `build()` z knižnice `googleapiclient.discovery`. Následne sa získajú všetky udalosti z primárneho kalendára používateľa, z ktorých sa filtrujú iba udalosti s názvom „Dovolenka“. Potom funkcia prechádza každou získanou udalosťou s daným názvom a skontroluje, či aktuálny dátum a čas spadajú do časového rozsahu začiatku a konca danej udalosti. Ak sa aktuálny dátum (a čas) nachádza v rámci nejakej dovolenky, nevykonáva sa ohrev TÚV na bežnú teplotu, voda sa udržiava na teplote 10 až 15°C, aby nedochádzalo k šíreniu baktérie Legionella. Druhá funkcia „AntiLegionella“ slúži na zabitie už spomenutej baktérie Legionella, ktorá bola popísaná v 3.1. Funkcia porovnáva aktuálny čas a dátum s požadovanými hodnotami – ak je prvý deň v mesiaci a štyri hodiny v noci, funkcia dá požiadavku na zapnutie ohrevu, a teda zvýšenie teploty vody vo vnútri bojleru nad 70°C, ktorú udržiava po dobu jednej hodiny.

Z databázy sa získajú záznamy za posledné časové obdobie (napríklad jeden posledný deň). Tieto dáta, ako bolo uvedené v kapitole 5.1, opäť prejdú procesom spracovania, rozšírenia a rozdelenia, nakoľko pre predikciu budúcnosti sa vyžaduje rovnaký formát „aktuálnych“ dát ako dáta, ktoré boli použité pre tréovanie modelu neurónovej siete. Popis spracovania, rozšírenia a rozdelenia dátovej sady bol uvedený na začiatku sekcie 6.2. Následne je z týchto dát vytvorená časť „vstupných dát“ jedného kľavého okna, pričom postup je podobný ako v predošlej fáze. Nakoľko pre predikciu budúcnosti stačí jedno „okno“ s aktuálnymi hodno-

¹¹Celý postup dostupný na <https://developers.google.com/calendar/api/quickstart/python>.

tami, zoberie sa desať najaktuálnejších hodnôt. Z nich sa vytvorí matica pomocou funkcie `to_numpy()`. Vytvorí sa zoznam obsahujúci desať posledných záznamov a celý zoznam sa otočí, aby opäť najaktuálnejší záznam bol na začiatku zoznamu. Tento proces sa vykonáva pre obe predikované teploty zvlášť.

Po vykonaní všetkých vyššie spomenutých kontrol a úpravách aktuálne nameraných dát sa vypočíta spodná a horná hranica teploty vody z konfiguračného súboru, ako aj hranica druhej teploty, ktorá sa považuje za akciu spotreby teplej vody. Pre tento výpočet sú použité čísla odvodené z pozorovaní a testovaní pri vývoji podsystemu. Potom sa načítajú modely vytvorené v druhej fázy podsystemu pomocou skriptu `main_boiler.py`. Následne sa desať posledných záznamov s nameranými dátami spolu s modelmi použijú pomocou funkcie `predict()` na získanie predikcie piatich hodnôt do budúcnosti pre každú predikovanú premennú – pričom sa využíva posledná hodnota, teda hodnota 40 minút do budúcnosti. Po získaní predikovaných dát je možné vykonať finálny „algoritmus rozhodovania“. Samotné pravidlá boli popísané v 5.2 – porovnávajú sa predikovaná prvá teplota, dolná a horná hranica požadovanej teploty, predikovaná druhá teplota a hranica druhej teploty. Na základe daných pravidiel sa určí „status“, ktorý sa má modulu Shelly odoslať – vypnúť alebo zapnúť. Finálne ovládanie ohrevu TUV v bojleri je realizované pomocou požiadaviek na programové rozhranie Shelly Cloud, cez ktoré je možné modul spínať a tak vypnúť alebo zapnúť tok elektrickej energie cez daný modul. Pre poslanie požiadavky sa využíva POST požiadavka z knižnice `requests`, pričom potrebné údaje o zariadení ako autentifikačný kľúč a identifikačné číslo zariadenia Shelly sú získané z konfiguračného súboru.

Ostatné nástroje

Ďalší skript, ktorý je dostupný v rámci podsystemu, je skript `boiler_statistics.py`. Využívanie tohoto skriptu nie je vyžadované, nemá vplyv na funkčnosť podsystemu, slúži iba pre zobrazenie štatistík o spotrebe elektrickej energie a prípadne množstve teplej vody. Na začiatku sa získajú dáta z databázy za posledné tri mesiace. Z týchto dát sa odstránia premenné teplôt, nakoľko sa pracuje iba s hodnotami aktuálnej spotreby elektrickej energie a prípadne spotreby teplej vody z pripojeného prietokomeru. Následne sa pomocou funkcie `groupby()` vytvorí „okná“ v rozsahu jedného dňa, týždňa a mesiaca. Pre jednotlivé okná sa spočíta suma spotreby elektrickej energie za dané časové obdobie – spotreba za aktuálny deň a dva predošlé dni (rovnako pre týždeň a mesiac). Z dátovej sady, obsahujúcej okná pre deň, týždeň alebo mesiac a sumou spotreby elektrickej energie a spotreby vody, sa v cykle získa daná hodnota pre konkrétne okno, ktorá sa v prípade spotreby elektrickej energie podelí počtom záznamov za jednu hodinu (40 záznamov za hodinu, ak sa dáta do databázy zapisujú každých 90 sekúnd), nakoľko databáza obsahuje hodnoty aktuálnej spotreby elektrickej energie v jednotke [Wh]. Následne sa hodnota podelí hodnotou 1000 a výsledok je orientačná spotreba elektrickej energie v danom časovom okne v jednotke [kWh]. Cyklus sa vykonáva pre tri hodnoty. Pre výpis spotreby teplej vody netreba vykonávať delenie počtom záznamov, nakoľko vytvorené okná už obsahujú sumu spotreby vody za dané časové obdobie. Pri výpise sa suma iba podelí hodnotou 1000 pre výpis v litroch.

6.3 Implementácia podsystemu pre riadenie vykurovania domácnosti

Táto sekcia popisuje dôležité časti finálnej implementácie podsystemu riadenia vykurovania domácnosti. Na začiatku je stručne uvedená finálna realizácia hardvérového zariadenia pre

zber dát z domácnosti, následne sa kapitola venuje popisu skriptov podľa jednotlivých častí, dôležitým knižniciam a funkciám využitým v podsysteme.

Podsystem pre vykurovanie je variabilnejší oproti predošlému podsystemu, je ovplyvnený použitými senzormi, ich množstvom, typom a vstavanými funkciami vykurovacieho zariadenia a iné. Podsystem pracuje primárne s hodnotou teploty z jednej miestnosti (ak v domácnosti nemá byť využité zónové riadenie vykurovania) a hodnotou týkajúcou sa prítomnosti osôb v domácnosti. Podsystem je možné rozšíriť o ďalšie teploty z iných miestností pre zónové vykurovanie alebo premenné ako vlhkosť v miestnostiach a pri rozšírení podsystemu aj meteorologické údaje a iné.

V rámci behu celého podsystemu sa využíva `heating_conf_file.json` – konfiguračný súbor vo formáte JSON, obsahujúci všetky potrebné údaje podsystemu, konkrétne:

- Požadovaná (orientačná) teplota vzduchu v jednotlivých miestnostiach, v ktorých je želané riadenie vykurovania.
- Údaje o moduloch Shelly – v prípade nahradenia klasických termostatov spínacími modulmi – informácie slúžia pre možnosť komunikácie s týmito modulmi.
- Údaje o ovládaných termostatických hlaviciach – informácie slúžia pre možnosť komunikácie s týmito hlavicami.
- Nastavenie zariadenia Viessmann Vicare – ak domácnosť využíva zariadenie s daným modulom.
- Údaje o použitej databáze pre ukladanie nameraných dát – slúžia na vytvorenie spojenia a možnosti čítania z databázy.
- Časy vysokej tarify – ak domácnosť disponuje dvojtarifnou sieťou a využíva sa elektrické vykurovacie zariadenie.
- Informácie, či sa má využiť funkcia Dovolenska.
- Nastavenia podsystemu – časy opakovania získavania dát, pretrénovania modelu neurónovej siete, riadenia vykurovania, veľkosť jedného okna pri procese prevzorkovania a veľkosť posuvného okna pred procesom tréningu modelu neurónovej siete.

Konfiguračný súbor je jediný súbor, ktorý je potrebné pre správne fungovanie podsystemu upraviť. Ako v predošlom podsysteme, aj tu sa využíva skript `heating_utils.py` obsahujúci spoločné funkcie, konkrétne funkcie:

- `get_data_from_db()` – získanie dát z databázy. Princíp funkcie je rovnaký ako vo funkcii s rovnakým menom v predošlom podsysteme. Rozdiel je len v spôsobe stiahnutia dát z databázy – v predošlom podsysteme sa všetky dáta získali naraz, avšak v tomto podsysteme sa stiahnutie dát z databázy realizuje na časti, nakoľko pri vývoji systému dochádzalo k chybe, ak bol objem sťahovaných dát z hardvérového zariadenia priveľký. Celý rozsah dát, z ktorého sú požadované dáta, sa rozdelí po piatich dňoch (objem dát za päť dní je dostatočne malý na bezproblémové získanie požadovaného obsahu), z ktorých sa získajú dáta z databázy a vložia sa do dočasného zoznamu. Po prejdení celého rozsahu požadovaného času sa všetky získané menšie dátové sady zo zoznamu spoja do jednej veľkej sady, s ktorou ďalej podsystem pracuje. Na komunikáciu s databázou sa využíva funkcia `InfluxDBClient()` a knižnica `datetime` pre prácu s časovými rozsahmi.

- `get_data_from_conf_file()` – získanie dát z konfiguračného súboru – funkcia je rovnaká ako v predošlom podsystéme.
- `transform_and_extend_dataset()` – úprava a rozšírenie dát. Oproti funkcii z predošlého podsystému sa líši v spôsobe režie chýbajúcich dát. Zatiaľčo v predošlom podsystéme k chýbajúcim dátam nedochádzalo, nakoľko senzory v danom hardvérovom zariadení dokážu dáta získavať za menej ako jednu sekundu a dáta z modulu Shelly sú získavané a ukladané pravidelne, v hardvérovom zariadení podsystému pre riadenie vykurovania sa využívajú senzory s nepravidelným časom odosielania dát – senzory odosielať dáta vtedy, keď sa hodnota meranej veličiny zmení. Z toho dôvodu môže jeden senzor posielat dáta každú minútu, avšak iný senzor v inej miestnosti domácnosti len raz za niekoľko hodín. Z toho dôvodu po prevzorkovaní dát a vytvorení pravidelných okien dáta z mnohých sensorov v daných časových rozsahoch chýbajú. Zo spomenutého dôvodu však platí, že ak hodnota v danom čase chýba, je rovnaká ako predošlá získaná hodnota. Pre doplnenie („skopírovanie“) chýbajúcich hodnôt danej premennej do každej časovej značky v databáze z predošlej získanej hodnoty sa využíva funkcia `fillna()` z knižnice `pandas`. Okrem toho, ako bolo uvedené v 5.2, je potrebné získané dáta transformovať na tabulkový formát, kde k jednej časovej značke sú priradené hodnoty všetkých premenných. Na to sa využíva funkcia `pivot_table()` z rovnakej knižnice. Výsledkom teda je záznam obsahujúci časovú značku a hodnoty všetkých meraných veličín – mnohé z nich však chýbajú, preto sa používa spomenuté doplnenie chýbajúcich hodnôt. Následne sa dáta rozšíria o rozdiel od predošlej hodnoty a vlastnosti ohľadom časovej značky rovnakým spôsobom ako v prípade predošlého podsystému.
- `split_dataset()` – rozdelenie dátových sád. Princíp je opäť rovnaký ako vo funkcii v predošlom podsystéme, líši sa iba tým, že v tomto podsystéme nie je stanovený presný počet sensorov a tak je funkcia „dynamickejšia“.

Všetky hlavné skripty sa opäť vykonávajú v nekonečnom cykle, pričom na konci každého cyklu dochádza k uspaniu programu pomocou funkcie `sleep()`. Zároveň všetky skripty na začiatku cyklu vykonávajú načítanie obsahu konfiguračného súboru a načítanie nameraných dát z databázy.

Realizácia hardvérového zariadenia pre zber a ukladanie nameraných dát z domácnosti

Finálne hardvérové zariadenie pre zber požadovaných dát sa opäť skladá z dvoch častí – centrálnej jednotky a pripojených sensorov. Ako bolo uvedené v 5.2, kvôli väčšej variabilite umiestnenia sensorov pre zber požadovaných dát zariadenie využíva bezdrôtové senzory. Pre možnosť využitia sensorov od viacerých výrobcov je ako centrálna jednotka zvolený minipočítač Raspberry Pi 4, pre komunikáciu so senzormi je minipočítač rozšírený o Sonoff ZigBee USB 3.0 Dongle Plus-E pre vytvorenie ZigBee siete. Ako senzory pre získavanie teploty sú použité teplotné senzory Aqara, pre získavanie informácie o prítomnosti osôb v domácnosti bol v prvej testovanej domácnosti použitý pohybový senzor Sonoff, v druhej testovanej domácnosti sa pre informáciu o prítomnosti osôb využil *Geofencing*, teda vzdialenosť mobilných telefónov obyvateľov od danej domácnosti. Pre zónové vykurovanie v druhej domácnosti bola využitá inteligentná termostatická hlavica na radiátor Immax NEO Smart. Pre nahradenie klasického termostatu bol v prvej domácnosti použitý spínač



Obr. 6.4: Komponenty potrebné pre realizáciu hardvérového zariadenia pre riadenie vykurovania domácnosti.

modul Shelly 1 Plus (pripojený k lokálnej Wi-Fi sieti), ktorý disponuje suchým kontaktom. Hardvérové zariadenie, konkrétne centrálna jednotka, bolo pripojené k internetu pomocou LAN.

Vďaka využitiu minipočítača Raspberry Pi 4, ktorý využíval softvér a zároveň operačný systém HomeAssistant, bolo možné využiť lokálnu databázu InfluxDB priamo na tomto zariadení. Pre vytvorenie ZigBee siete bolo potrebné na spomenuté Sonoff ZigBee USB rozšírenie nahráť firmvér¹² a v aplikácii HomeAssistant nainštalovať a nastaviť potrebné rozšírenia, konkrétne rozšírenia Mosquitto broker a Zigbee2MQTT. Databáza InfluxDB vo verzii 1.X je dostupná v aplikácii HomeAssistant ako rozšírenie InfluxDB. Pre správne fungovanie databázy je potrebné ju podľa návodu (súčasťou daného rozšírenia) nastaviť v konfiguračnom súbore `configuration.yaml`, konkrétne nastaviť adresu, port, názov databázy, prístupové údaje a názvy senzorov, ktorých hodnoty sa majú v databáze ukladať. Pre možnosť komunikácie s databázou je možné k nej pristúpiť cez lokálnu sieť alebo VPN, napríklad Tailscale opäť dostupný ako rozšírenie v HomeAssistant. Prístup pomocou využitia oficiálneho Home Assistant Cloud (účet dostupný cez službu Nabu Casa) počas vývoja ani počas testovania podsystému nefungoval, preto bolo zvolené spomenuté VPN. Prístup k databáze je teda možný cez adresu získanú v danom VPN a portom uvedeným v konfiguračnom súbore aplikácie HomeAssistant. Výstupom tejto časti podsystému je databáza obsahujúca namerané dáta zo všetkých pripojených senzorov.

Komponenty pre finálne riešenie hardvérového zariadenia pre riadenie vykurovania domácnosti sú zobrazené na obrázku 6.4.

¹²Open source softvér dostupný na https://github.com/xsp1989/zigbeeFirmware/tree/master/firmware/Zigbee3.0_Dongle-NoSigned/EZSP.

Trénovanie neurónovej siete a tvorba modelu na predikciu dát

Tvorba neurónovej siete, jej trénovanie a vytvorenie modelu na predikciu dát je realizované v skripte `main_heating.py`. Na dáta získané z databázy sa aplikuje proces transformácie a rozšírenia dát. Po úprave dát sa dátová sada pomocou funkcie `split_dataset()` rozdelí na menšie dátové sady s konkrétnymi premennými.

Potom, ako v predošlom podsystéme, nasleduje samotný proces tvorby a trénovania neurónovej siete a požadovaných modelov. Predspracovanie (tvorba posuvných okien a rozdelenie dátovej sady na trénovaciu, validačnú a testovaciu dátovú sadu) dát je totožné s predspracovaním dát z predošlého podsystému popísaného v 6.2. Nasleduje tvorba neurónovej siete pomocou knižnice `Keras`. Najprv sa opäť vytvorí model typu `Sequential` pre postupné lineárne usporiadanie vrstiev. Model neurónovej siete sa líši od typu predikovanej veličiny. Pre model na predikciu teplôt tento model obsahuje štyri vrstvy – prvá vrstva typu `LSTM` s 64 skrytými neurónmi a tri plne prepojené vrstvy `Dense` s 32, 16 a piatimi neurónmi. Opäť sa využíva aktivačná funkcia `ReLU` a výstupná lineárna aktivačná funkcia. Stratová funkcia a metrika sú opäť zvolené metriky priemernej absolútnej chyby (`Mean Absolute Error`, `MAE`). Pre model na predikciu prítomnosti osôb v domácnosti tento model obsahuje tri vrstvy – dve `LSTM` vrstvy, každá s 64 neurónmi, kde prvá vrstva vracia celé sekvencie namiesto samostatných hodnôt a výstupná plne prepojená vrstva `Dense` s aktivačnou funkciou `sigmoid`. Ako stratová funkcia je využitá metrika `BinaryCrossentropy`, metrika pre kompiláciu modelu je `Accuracy`. Následne opäť dochádza ku kompilácii modelu pomocou funkcie `compile()` s optimalizačným algoritmom `Adam` s rýchlosťou učenia 0,01. Ukladanie najlepšie modelu prebieha rovnako ako v predošlom podsystéme. Samotné trénovanie prebieha po dobu 200 epochov, pričom veľkosť dávok je 32. Pre vyhodnotenie presnosti modelu neurónovej siete sa opäť používa rovnaká funkcia `evaluate()` na testovacej dátovej sade. Výstupom tohoto skriptu sú modely na predikciu pre každú meranú teplotu a prítomnosť osôb v domácnosti.

Riadenie vykurovania domácnosti

Posledná fáza, a teda riadenie vykurovania domácnosti, popísané v 5.2 je realizované pomocou skriptu `heating_control.py`. V prípade, že domácnosť využíva elektrickú energiu pre vykurovanie domácnosti (elektrické podlahové vykurovanie, elektrický kotol a iné), má k dispozícii dvojtarifnú sieť, používateľ povolil kontrolu na vysokú tarifu a vyplnil jej časy, na začiatku skriptu sa opäť vykonáva práve táto kontrola, ktorá je totožná s funkciou popísanou v 6.2. Následne sa opäť získa časť nameraných dát z databázy, ktoré prejdú rovnakým procesom spracovania a rozdelenia ako v predošlom skripte. Aktuálne namerané dáta za posledné časové obdobie sa použijú pre vytvorenie jedného posuvného okna obsahujúceho vstupné dáta (proces popísaný v popise implementácie predošlého podsystému). Po načítaní vytvorených modelov z predošlého skriptu a použití vytvoreného posuvného okna už dochádza k predikcii hodnoty konkrétnej teploty päť časových jednotiek do budúcnosti. Pre každú meranú teplotu je použitý vlastný model a sú predikované vlastné hodnoty – tým je možné zabezpečiť samostatné vykurovanie v každej miestnosti.

Nakoniec sa vykonáva „funkcia rozhodovania“, teda aplikovanie pravidiel popísaných v 5.2. Pri vyhodnocovaní pravidiel sa využíva nastavená požadovaná teplota, predikovaná teplota a informácia o prítomnosti osôb v domácnosti.

Pri testovaní aplikácie bolo zistené, že informácia z pohybového senzoru nie je príliš presná pre určenie prítomnosti osôb v domácnosti, nakoľko nedáva presnú informáciu, či sa osoba, prípadne koľko osôb, do domácnosti vracia alebo odchádza. To je možné riešiť

použitím viacerých (pohybových) senzorov, najlepšie do každej miestnosti v domácnosti, alebo rozšírením informácie z pohybového senzoru o údaje z prvého pod systému, a teda druhej teploty odrážajúcej akciu spotreby teplej vody. Zároveň je možné využiť sledovanie mobilných telefónov osôb (pomocou aplikácie HomeAssistant v inteligentnom telefóne, vyžaduje sa však stále pripojenie na internet). Vďaka tomu je možné presnejšie určiť, či sa osoby v domácnosti nachádzajú alebo nie.

Samotné ovládanie vykurovania závisí od funkcií ovládaného vykurovacieho zariadenia. V rámci vývoja boli testované dva spôsoby ovládania vykurovacieho zariadenia, konkrétne ovládanie zariadenia disponujúceho pripojením k internetu a možnosťou vzdialeného ovládania (napríklad plynové kotle od spoločnosti Viessmann) a zariadenie bez možnosti vzdialeného ovládania, kde došlo k nahradeniu termostatu spínacím modulom Shelly 1 Plus. Prvý spôsob využíva údaje pre komunikáciu so zariadením cez programové rozhranie, ktoré používateľ uvedie do konfiguračného súboru. Následne je možné poslať POST požiadavku na zníženie alebo zvýšenie požadovanej teploty (`targetTemperature`) na vnútornom termostate zariadenia na minimálnu alebo maximálnu možnú teplotu – na základe toho sa vykurovacie zariadenie vypne alebo zapne. Druhý spôsob, v ktorom sa využíva spínací modul Shelly 1 Plus (riešenie pre domácnosti bez vykurovacích zariadení s pripojením na internet), je rovnaký ako v prípade pod systému pre ohrev TÚV – na základe výsledku z rozhodovacích pravidiel sa na programové rozhranie modulu odošle POST požiadavka obsahujúca informáciu `on` alebo `off`.

Kapitola 7

Testovanie systému a výsledky

Táto kapitola popisuje testovanie vytvoreného systému a jeho jednotlivých častí, ktoré prebiehalo počas a aj po vývoji systému.

Nakoľko je celý systém možné rozdeliť na dva podsystemy, a to podsystem pre riadenie ohrevu teplej úžitkovej vody (TÚV) a podsystem pre riadenie vykurovania domácnosti, aj testovanie bude rozdelené na dve časti. Testovanie týchto dvoch častí prebiehalo samostatne, nakoľko počas testovania nebola k dispozícii žiadna domácnosť, v ktorej by mohlo prebiehať testovanie oboch podsystemov súčasne – aj cez to je však oba podsystemy možné využiť v jednej domácnosti a tak využiť spoločné informácie, a teda prítomnosť osôb v domácnosti.

Prvá sekcia popisuje testovanie riadenia ohrevu TÚV v dvoch domácnostiach – krátky popis domácnosti, priebeh testovania a analýza výsledkov jednotlivých domácností. Na konci sekcie je uvedené stručné zhrnutie faktorov ovplyvňujúcich získané výsledky. Druhá sekcia sa následne venuje popisu testovania riadenia vykurovania domácnosti, opäť pre dve domácnosti s rôznymi prístupmi k ovládaniu samotného vykurovania.

7.1 Testovanie riadenia ohrevu teplej úžitkovej vody


Testovanie ohrevu TÚV prebiehalo v dvoch domácnostiach.

Ešte pred samotným nasadením podsystemu pre ohrev TÚV do testovanej domácnosti prebiehal s členmi domácnosti krátky pohovor, v ktorom boli kladené otázky na ich krátkodobé a dlhodobé návyky, plánované dlhodobejšie dovolenky a ich predstavy o danom podsysteme. Následne im bolo vysvetlené, ako podsystem funguje, aké dáta ukladá a ako sa s nimi ďalej pracuje. Tento pohovor slúžil na určenie, či je daná domácnosť vhodná na nasadenie podsystemu.

Okrem prvého pohovoru boli realizované aj pravidelné (raz týždenne) kontrolné pohovory, v ktorých bolo od členov domácnosti zisťované, či sú s podsystemom spokojní, či nedošlo k nejakej neplánovanej aktivite, prípadne či mali dostatok teplej vody počas ich denných aktivít. Súhrnne povedané, či im podsystem v danom týždni spôsobil zníženie komfortu alebo nie.

Prvá domácnosť

Domácnosť disponovala novým bojlerom s objemom 150 litrov, ktorý bol umiestnený vo vykurovanej technickej miestnosti. V domácnosti počas testu bývali traja členovia. Z prvého pohovoru s členmi domácnosti bolo zistené, že aj keď u členov domácnosti v niektoré



Obr. 7.1: Vývoj týždennej spotreby elektrickej energie na ohrev TÚV v prvej testovanej domácnosti.

dni dochádza k nepravidelným aktivitám, pravidelnosť ostatných aktivít je dostatočná pre nasadenie podsystému.


Na začiatku prebiehalo získavanie dát počas normálneho režimu pomocou pripojeného hardvérového zariadenia zobrazeného na obrázku 6.2, a teda samotný ohrev TÚV nebol ovládaný. Po nazbieraní dát za dva týždne boli tieto údaje (konkrétne orientačná teplota vody vo vnútri bojleru a orientačná teplota na rúrke pre výstup teplej vody, ktorá odráža akciu spotreby teplej vody) využité pre natrénovanie modelu neurónovej siete. Následne došlo k spusteniu skriptu pre riadenie bojleru, ktorý ovládal ohrev TÚV v danej domácnosti nasledujúce štyri týždne. Počas prvých dvoch týždňov bola orientačná spotreba elektrickej energie 39 kW a 45 kW. Nasledujúce štyri týždne, kedy dochádzalo k riadeniu ohrevu TÚV sa spotreba pohybovala od 32 kW do 34 kW. Počas testu obyvatelia domácnosti nepociťovali žiadne zníženie komfortu.

V rámci testu nebola využitá funkcia AntiLegionella, nakoľko používateľ neumožnil zvýšenie teploty na termostate bojleru nad 70°C. Pri testovaní sa využívala funkcia vysokej tarify – používateľ v konfiguračnom súbore špecifikoval časy vysokej tarify a v týchto časoch nedochádzalo k ohrevu TÚV.

Výsledky testu v danej domácnosti sú zobrazené v grafe 7.1. Z výsledkov je vidieť, že približné zníženie energie na ohrev TÚV v testovanej domácnosti pri použití podsystému je približne 9 kW týždenne, čo činí približne 20 % úsporu nákladov. Pri priemernej cene 0,15 € za kWh s orientačnou mesačnou spotrebou 165 kW je cena za energiu na ohrev TÚV ročne približne 300 €. Pri úspore 20 % energie je ročná úspora približne 60 €.

Druhá domácnosť

V druhej domácnosti bol vykonaný test s využitím prietokomeru. Domácnosť využívala nový bojler s objemom 100 litrov umiestnený vo vykurovanej kúpeľni. V domácnosti bývali dvaja členovia domácnosti. Obaja členovia využívali teplú vodu ráno pred odchodom do práce a večer po príchode z práce. Druhá domácnosť bola pre test vybraná špecificky z dôvodu možnosti zásahu do vodoinštalácie a teda využitia prietokomeru. Ako pri predošlom teste, aj tu bol na začiatku vykonaný úvodný pohovor pre zistenie, či je domácnosť vhodná



Obr. 7.2: Vývoj týždennej spotreby elektrickej energie na ohrev TÚV v druhej testovanej domácnosti.

pre nasadenie podsystému. ďalšie pohovory opäť prebiehali raz týždenne počas celého testovania.

Domácnosť nemala k dispozícii dvojtarifnú sieť a teda nevyužívala funkciu pre zamedzenie ohrevu počas vysokej tarify.

Prvé dva týždne opäť prebiehal zber dát bez riadenia ohrevu TÚV. Namerané dáta sa využili pre tvorbu modelu na predikciu dát do budúcnosti. Údaje z prietokomeru boli využité ako ďalšia tréningová vlastnosť pri predikcii spotreby TÚV, a môžu byť využité aj pre štatistiky o dennej, týždennej a mesačnej spotrebe vody. Denná spotreba teplej vody v domácnosti bola približne 50 až 70 litrov. Po dvoch týždňoch bolo zapnuté riadenie ohrevu TÚV, ktoré prebiehalo po dobu dvoch týždňov.

Výsledky testu v danej domácnosti sú zobrazené v grafe 7.2. Nakoľko v domácnosti bývajú len dve osoby a väčšinu času sa v domácnosti nikto nenachádzal, spotreba vody a aj energie na jej ohrev je oproti predošlej testovanej domácnosti nižšia. Výsledky ukazujú úsporu približne 6 až 7 kW elektrickej energie týždenne, čo je oproti pôvodnej hodnote pred použitím podsystému zníženie o 24 %. Priemerná ročná úspora financií pri ročnej spotrebe 118 kW je 50 €.

Analýza výsledkov z testovania ohrevu TÚV

Aj keď oba testy ukázali úsporu energie na ohrev TÚV, je potrebné vziať do úvahy všetky faktory, ktoré túto úsporu a zároveň aj komfort ovplyvňujú. Medzi takéto faktory patrí napríklad:

- Pravidelnosť návykov členov domácnosti – čím nepravidelnejšie návyky majú členovia domácnosti, tým horšie sa ich model naučí a teda dôjde k nižším úsporám, ako aj zhoršeniu komfortu.
- Teplota miestnosti, v ktorej sa bojler nachádza – pri nižšej teplote v miestnosti dochádza k väčším tepelným stratám cez plášť bojleru a je potrebné častejšie ohrievať vodu.

- Vek bojlera a kvalita izolácie – novšie bojlerly majú kvalitnejšie izolácie a teda menšie tepelné straty.

Vzhľadom na tieto faktory nie je teda možné presne určiť úsporu energie použitím daného pod systému – vykonané testy, ako aj získané výsledky sú špecifické pre každú domácnosť a môžu sa líšiť od iných domácností.

7.2 Testovanie vykurovania domácnosti

Testovanie vykurovania opäť prebiehalo v dvoch domácnostiach s rôznymi možnosťami ovládania daného vykurovania. Ako v prípade testovania ohrevu TÚV, aj pri testovaní vykurovania bol na začiatku vykonaný úvodný pohovor. Počas neho boli členovia domácnosti informovaní, ako dané testovanie prebieha a aké údaje budú z domácnosti zisťované. Následne opäť prebiehali pravidelné pohovory pre zistenie, či došlo k nejakým zmenám alebo problémom kvôli danému testovaniu alebo nie. Pre testovanie bolo využité hardvérové zariadenie zobrazené na obrázku 6.4.

Vyhodnotenie výsledkov testovania vykurovania domácnosti je zložitejšie, nakoľko nie je možné získať žiadne konkrétne hodnoty o úspore pomocou automatického merania daným pod systémom. V prípade elektrického vykurovania je možné využiť meracie moduly od spoločnosti Shelly, avšak ich cena je vyššia ako bežné spínacie moduly využité v systéme. Pri využití plynového vykurovania je získavanie aktuálnej spotreby ešte zložitejšie, nakoľko v testovaných domácnostiach sa nenachádzali impulzné plynometry s možnosťou diaľkového odpočtu.


Tretia domácnosť

V prípade tretieho testovacieho miesta sa jednalo o starší rodinný dom s plynovým kotlom staršej generácie s klasickým termostatom, pre distribúciu tepla v domácnosti boli využité radiátory bez termostatických ventilov. V domácnosti bývala jedna osoba, ktorá v ranných hodinách odchádzala do práce a v podvečerných hodinách sa vracala do domácnosti. Plynový kotol bol využívaný aktívne iba počas tohoto testovania, inak sa v domácnosti využívala kombinácia kotlu na pevné palivo a plynového kotlu.

V domácnosti boli využité viaceré senzory pre zber dát z viacerých miestností, avšak z dôvodu radiátorov bez termostatických ventilov nebolo možné využiť zónovú reguláciu a pre finálne riadenie vykurovania sa využila len teplota z najviac využívanej miestnosti (podľa požiadavky majiteľa), v ktorej bol pôvodne umiestnený aj termostat. Pre získavanie informácie o prítomnosti osôb v domácnosti bol v tomto testovacom mieste použitý pohybový senzor od spoločnosti Sonoff umiestnený v garáži, nakoľko osoba z domácnosti vždy odchádzala autom. Tento prístup bol na danom testovacom mieste dostatočný, avšak v iných domácnostiach je jeden pohybový senzor nedostatočný ako bolo uvedené v 6.3.

Na začiatku po inštalácii centrálnej jednotky a senzorov prebiehal zber a ukladanie dát bez riadenia vykurovania po dobu jedného týždňa. Následne sa dáta využili pre natrénovanie modelu na predikciu budúcnosti. Zároveň po prvom „testovacom“ týždni došlo k nahradeniu klasického termostatu za spínací modul Shelly 1 Plus, aby bolo možné realizovať samotné ovládanie. Pôvodný termostat nedisponoval možnosťou vytvorenia týždenného rozvrhu alebo iných funkcií, mal iba možnosť nastaviť požadovanú teplotu. Následný test s ovládaním vykurovania prebiehal po dobu troch týždňov.

Kvôli absencii plynometru s možnosťou vzdialeného odpočtu hodnôt bolo realizované odčítanie hodnôt manuálne, a to každý piatok vo večerných hodinách. Namerané výsledky



Obr. 7.3: Vývoj týždennej spotreby plynu na vykurovanie v tretej testovanej domácnosti.


zobrazené na grafe 7.3 zobrazujú týždennú spotrebu plynu v domácnosti. V domácnosti sa plyn okrem vykurovania využíva pre ohrev TÚV vo vstavanom zásobníku vody vo vnútri plynového kotla. Počas prvého „testovacieho“ týždňa bola spotreba plynu približne 82 m^3 , po spustení skriptu pre ovládanie vykurovania klesla týždenná spotreba plynu v priemere na 61 m^3 . Nakoľko nie je možné presne určiť množstvo plynu na ohrev TÚV a na vykurovanie, výsledkom je len orientačná úspora. Po využití vytvoreného podsystému je zníženie spotreby plynu orientačne 20 m^3 týždenne, teda úspora energie na vykurovanie je približne 20 až 30 %.

Štvrtá domácnosť

Štvrté testované miesto bol rodinný dom po rekonštrukcii kúrenia s novým typom plynového kotla, konkrétne kotol Viessmann Vitodens 111, ktorý disponoval pripojením na internet a možnosťou vzdialeného ovládania, pre otestovanie zónového vykurovania bola na radiátore v jednej miestnosti použitá inteligentná termostatická hlavica od spoločnosti Immax NEO.

Počas prvého týždňa, kedy dochádzalo k zbieraniu dát, bol kotol pripojený ku klasickému termostatu, pomocou ktorého bol riadený ohrev – majitelia teda nevyužívali vstavané funkcie kotla. Po prvom týždni zbierania dát bol klasický termostat odpojený, aby bolo možné využiť vstavané funkcie pre vzdialené ovládanie kotla. Ako v predošlej testovanej domácnosti, aj tu boli využité senzory vo viacerých miestnostiach – údaje z obývacej miestnosti boli využité pre centrálné riadenie vykurovania, údaje zo spálne len pre riadenie vykurovania v danej miestnosti.

Hodnoty spotreby plynu boli opäť získavané manuálne, a to pravidelne každý piatok. Vývoj spotreby plynu na vykurovanie domácnosti je zobrazený na grafe 7.4. Domácnosť využívala plyn ako k vykurovaniu interiéru, tak aj k ohrevu TÚV v zásobníku kotla a varenie na plynovom sporáku. Nakoľko nie je možné rozlíšiť spotrebu na tieto tri činnosti, údaje sú len orientačné. Počas prvého „testovacieho“ týždňa bola týždenná spotreba plynu $61,5 \text{ m}^3$. Po využití riadenia ohrevu podsystémom klesla týždenná spotreba plynu približne na 50 m^3 , čo predstavuje úsporu 18 %.



Obr. 7.4: Vývoj týždennej spotreby plynu na vykurovanie vo štvrtej testovanej domácnosti.

Analýza výsledkov z testovania vykurovania domácnosti

Aj keď oba testy ukázali úsporu energie na vykurovanie domácnosti, je potrebné vziať do úvahy všetky faktory, ktoré túto úsporu a zároveň aj komfort ovplyvňujú. Medzi takéto faktory patrí napríklad:

- Pravidelnosť návykov členov domácnosti – čím pravidelnejšie návyky majú členovia domácnosti, tým lepšie sa ich model naučí a dôjde k vyšším úsporám.
- Vonkajšia teplota.
- Zateplenie domácnosti – ak nie je zateplená domácnosť, dochádza k tepelným stratám a zvýšeniu nákladov na vykurovanie.
- Spôsob vetrania – nevhodné vetranie výrazne zvyšuje náklady na vykurovanie domácnosti.
- Účinnosť kotla – novšie kotle majú lepšiu účinnosť.
- Aké úsporné opatrenia vykonávali členovia pred nasadením systému – aj správne nastavenie klasického termostatu môže výrazne znížiť náklady na vykurovanie.

Výpočet budúcej ročnej úspory závisí na viacerých faktoroch. Okrem vyššie spomenutých faktorov záleží od počtu chladných dní a teploty počas nich. Pri ročnej odhadovanej spotrebe 22 000 kWh [48] pre jeden rodinný dom pri vykurovaní plynovým kotlom by mohla ročná úspora predstavovať 140 € až 240 €.

7.3 Vyhodnotenie formulára

Počas testovania systému bol realizovaný formulár pre zistenie, v akej miere sa využívajú rozdielne spôsoby vykurovania a ohrevu TÚV a aké funkcie inligetných zariadení pre tieto činnosti ľudia využívajú alebo by využívať chceli.

Formulár vyplnilo 142 ľudí, nižšie sú zobrazené otázky a tri odpovede s najväčším počtom výsledkov.

1. Akým spôsobom realizujete ohrev teplej úžitkovej vody vo Vašej domácnosti? (142 odpovedí)
 - Elektrický bojler (52 %)
 - Kombinovaný zásobník (27 %)
 - Centrálny ohrev (10 %)
2. Máte v domácnosti bojler s inteligentnými funkciami? (74 odpovedí)
 - Nie (73 %)
 - Áno (27 %)
3. Aké funkcie svojho inteligentného bojleru využívate? (20 odpovedí)
 - Vzdialené ovládanie (70 %)
 - Ochrana proti baktérii Legionella (50 %)
 - Učiaca sa funkcia (30 %)
4. Aké pridané funkcie by ste na svojom neinteligentnom bojleri využili? (54 odpovedí)
 - Ochrana proti baktérii Legionella (74 %)
 - Vzdialené zobrazenie štatistík (63 %)
 - Učiaca sa funkcia (59 %)
5. Akým spôsobom realizujete vykurovanie domácnosti? (142 odpovedí)
 - Plynový kotol (45 %)
 - Elektrický kotol (11 %)
 - Centrálné vykurovanie (11 %)
6. Aký termostat pre ovládanie vykurovania domácnosti využívate? (98 odpovedí)
 - Programovateľný týždňový termostat (on/off termostat) (51 %)
 - Neprogramovateľný klasický termostat (on/off termostat) (18 %)
 - Programovateľný s možnosťou pripojenia na internet (on/off termostat) (10 %)
7. Aké inteligentné funkcie by ste pri vykurovaní využili? (80 odpovedí)
 - Učiaca sa funkcia (53 %)
 - Zónové vykurovanie (43 %)
 - Funkcia dovolenka (25 %)
8. Aké funkcie svojho inteligentného termostatu využívate? (18 odpovedí)
 - Vzdialené ovládanie (78 %)
 - Zobrazenie štatistík (67 %)
 - Učiaca sa funkcia (11 %)

Kapitola 8

Záver

Cieľom tejto práce bolo vytvoriť systém, ktorý bude efektívne riadiť ohrev teplej úžitkovej vody (TÚV) a vykurovania v domácnosti, pre čo využije predikciu dát do budúcnosti pomocou metód strojového učenia. Nakoľko je systém určený pre riadenie dvoch činností v domácnosti, aj samotný systém je rozdelený na dve časti.

Výsledný podsystém pre riadenie ohrevu TÚV sa skladá z hardvérového riešenia obsahujúceho modul Shelly 1PM s teplotnými čidlami pre zber dát a samotné ovládanie ohrevu TÚV v bojleri. Softvérová časť podsystému sa delí na tri časti, konkrétne získavanie dát z hardvérového zariadenia a ich uloženie do databázy, spracovanie a rozšírenie dát vlastnosti hodnôt a vlastnosti časových značiek a využitie týchto dát pre tvorbu modelu na predikciu dát časových radov pomocou neurónovej siete typu *Long Short-Term Memory* (LSTM) a nakoniec využitie nameraných dát a vytvoreného modelu na predikciu dát do budúcnosti a rozhodovanie, či je potrebné realizovať ohrev TÚV. Vytvorený podsystém v testovaných domácnostiach dosahoval úsporu elektrickej energie na ohrev TÚV približne 20 až 24 %.

Druhý podsystém pre riadenie vykurovania domácnosti využíva hardvérové riešenie obsahujúce minipočítač Raspberry Pi ako centrálnu jednotku, modul pre vytvorenie ZigBee siete pre teplotné senzory od spoločnosti Aqara a pohybový senzor od spoločnosti Sonoff. Pre samotné ovládanie vykurovania bol využitý modul Shelly 1 Plus a inteligentná termostatická hlavica od spoločnosti Immax NEO. Namerané dáta sú ukladané priamo v databáze centrálnej jednotky. Následná softvérová časť podsystému využíva namerané dáta z databázy centrálnej jednotky – na začiatku prejdú dáta procesom úpravy a rozšírenia a následne sa využijú pre tvorbu modelu na predikciu meraných teplôt a prítomnosti osôb v domácnosti. Model spolu s aktuálnymi dátami sú využité na získanie samotnej predikcie, ktorá sa využíva na rozhodovanie o potrebe realizovať vykurovanie. Vytvorený podsystém dosiahol počas testovacieho obdobia úsporu približne 18 % v jednej domácnosti a 20 až 30 % v druhej testovanej domácnosti.

Systém je ďalej možné rozšíriť o jednoduché grafické užívateľské rozhranie pre pohodlnejšie nastavenie všetkých požadovaných údajov, ako aj prehľadnejšie zobrazenie štatistík o spotrebách na dané činnosti. Ďalšie možné rozšírenie zahŕňa realizáciu equitermickej regulácie pre kotle umožňujúce reguláciu výkonu. Predikciu dát pre vykurovanie domácnosti je možné rozšíriť o meteorologické údaje a intenzitu slnečného žiarenia. Systém môže byť rozšírený o informácie týkajúce sa optimálnej doby a dĺžky vetrania domácnosti.

Literatúra

- [1] AL SARAWI, S., ANBAR, M., ALIEYAN, K. a ALZUBAIDI, M. Internet of Things (IoT) communication protocols: Review. In: *2017 8th International Conference on Information Technology (ICIT)*. Institute of Electrical and Electronics Engineers (IEEE), Máj 2017, s. 685–690. DOI: 10.1109/ICITECH.2017.8079928.
- [2] AMAZON. *Amazon Smart Thermostat with C-wire power adapter* [online]. [cit. 28. júla 2023]. Dostupné z: <https://www.amazon.com/Amazon-Smart-Thermostat-C-Wire-Adapter/dp/B09F5M7ZJT>.
- [3] ARISTON. *Velis WIFI O – Rýchly Elektrický Ohrievač Vody* [online]. [cit. 9. mája 2023]. Dostupné z: <https://www.ariston.com/sk-sk/produkty/ohrievace-vody/stredne-a-velke-elektricke-zasobnikove-ohrievace-vody/velis-wifi-o>.
- [4] ATZORI, L., IERA, A. a MORABITO, G. Understanding the Internet of Things: definition, potentials, and societal role of a fast evolving paradigm. *Ad Hoc Networks*. 2017, zv. 56, s. 122–140. DOI: <https://doi.org/10.1016/j.adhoc.2016.12.004>. ISSN 1570-8705. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1570870516303316>.
- [5] AUDIN, G. *Managing wired IOT devices in a Wireless World* [online]. Mar 2020 [cit. 7. mája 2023]. Dostupné z: <https://www.nojitter.com/internet-things/managing-wired-iot-devices-wireless-world>.
- [6] AYALASOMAYAJULA, V. *Visualizing Time Series Data: 7 types of temporal visualizations* [online]. Aug 2019 [cit. 7. mája 2023]. Dostupné z: <https://humansofdata.atlan.com/2016/11/visualizing-time-series-data/>.
- [7] BALAKRISHNAN, S., VASUDAVAN, H. a MURUGESAN, R. K. Smart Home Technologies: A Preliminary Review. In: *Proceedings of the 6th International Conference on Information Technology: IoT and Smart City*. Association for Computing Machinery, 2018, s. 120–127. ICIT 2018. DOI: 10.1145/3301551.3301575. ISBN 9781450366298. Dostupné z: <https://doi.org/10.1145/3301551.3301575>.
- [8] BESCOND, P.-L. *Cyclical features encoding, it's about time!* [online]. Towards Data Science, Feb 2021 [cit. 14. júla 2023]. Dostupné z: <https://towardsdatascience.com/cyclical-features-encoding-its-about-time-ce23581845ca>.
- [9] BOUCHARD, K. a GIROUX, S. Smart homes and the challenges of data. In: Júl 2015, s. 1–4. DOI: 10.1145/2769493.2769519.
- [10] BROWNLEE, J. *11 Classical Time Series Forecasting Methods in Python (Cheat Sheet)* [online]. 2018. Aktualizované 10. 12. 2020 [cit. 18. januára 2023]. Dostupné z:

<https://machinelearningmastery.com/time-series-forecasting-methods-in-python-cheat-sheet/>.

- [11] BROWNLEE, J. *Deep Learning for Time Series forecasting* [online]. Október 2021. Aktualizované 21. 10. 2021 [cit. 18. januára 2023]. Dostupné z: <https://machinelearningmastery.com/deep-learning-for-time-series-forecasting/>.
- [12] BRUSH, A., LEE, B., MAHAJAN, R., AGARWAL, S., SAROIU, S. et al. Home Automation in the Wild: Challenges and Opportunities. In: Máj 2011, s. 2115–2124. DOI: 10.1145/1978942.1979249.
- [13] CAMPUS, P. S. W. *STAT 510: Applied Time Series Analysis* [online]. [cit. 2023-01-17]. Dostupné z: <https://online.stat.psu.edu/stat510/>.
- [14] CHATTERJEE, A. *Time Series for beginners with Arima* [online]. Kaggle, august 2018 [cit. 17. januára 2023]. Dostupné z: <https://www.kaggle.com/code/freespirit08/time-series-for-beginners-with-arima/notebook>.
- [15] CHRIST, M., BRAUN, N., NEUFFER, J. a KEMPA LIEHR, A. W. *Rolling/Time Series forecasting* [online]. [cit. 18. januára 2023]. Dostupné z: <https://tsfresh.readthedocs.io/en/latest/text/forecasting.html>.
- [16] DANCE, A. *Bluetooth low energy (BLE) and the internet of things* [online]. Feb 2023 [cit. 7. mája 2023]. Dostupné z: <https://theiotpad.com/bluetooth-low-energy-and-internet-of-things/>.
- [17] DAVIS, B. D., MASON, J. C. a ANWAR, M. Vulnerability Studies and Security Postures of IoT Devices: A Smart Home Case Study. *IEEE Internet of Things Journal*. Institute of Electrical and Electronics Engineers (IEEE). Marec 2020, zv. 7, č. 10, s. 10102–10110. DOI: 10.1109/JIOT.2020.2983983.
- [18] DELANEY, J. R. *Nest Learning Thermostat (3rd Generation) Review* [online]. Dec 2016 [cit. 9. mája 2023]. Dostupné z: <https://www.pcmag.com/reviews/nest-learning-thermostat-3rd-generation>.
- [19] DELANEY, J. R. *Honeywell Home T9 Smart Thermostat With Sensor Review* [online]. Jul 2019 [cit. 9. mája 2023]. Dostupné z: <https://www.pcmag.com/reviews/honeywell-home-t9-smart-thermostat-with-sensor>.
- [20] DELANEY, J. R. *Ecobee Smart thermostat premium review* [online]. Jun 2022 [cit. 9. mája 2023]. Dostupné z: <https://www.pcmag.com/reviews/ecobee-smart-thermostat-premium>.
- [21] DIAN, F. a VAHIDNIA, R. *IoT Use Cases and Technologies*. British Columbia Institute of Technology, november 2020. ISBN ISBN 978-1-990132-00-1.
- [22] DRAŽICE, D. závody. *Ohrievač vody OKHE SMART* [online]. [cit. 9. mája 2023]. Dostupné z: <https://www.dzd.sk/ohrievace-a-zasobniky-teplej-vody/elektricke/zavesne/okhe-smart>.
- [23] ECOBEE. *Smart thermostat premium* [online]. [cit. 28. júla 2023]. Dostupné z: <https://www.ecobee.com/en-ca/smart-thermostats/smart-thermostat-premium/>.

- [24] ELIZ. *Euro 151 Z in wifi* [online]. [cit. 9. mája 2023]. Dostupné z: <http://www.eliz.sk/sk/produkty/zasobnikove-ohrievace/elektrick%C3%A9-zvisl%C3%A9-inteligent-s-wifi/euro-151-z-in-wifi-detail>.
- [25] ELÍZ. *Na čo slúži Inteligentné Ovládanie Vášho Ohrievača?* [online]. [cit. 12. januára 2023]. Dostupné z: <https://www.eliz.sk/sk/na-co-sluzi-inteligentne-ovladanie-vasho-bojlera>.
- [26] EUROCLEAN, s. *Největší intenzita reprodukce legionelly nastává při 37–42°C. Jak ji nejlépe vymýtit?* [online]. Február 2016 [cit. 10. januára 2023]. Dostupné z: <https://voda.tzb-info.cz/13782-nejvetsi-intenzita-reprodukce-legionelly-nastava-pri-37-42-c-jak-ji-nejlepe-vymytit>.
- [27] EUROSTAT. *Energy consumption in households* [online]. June 2022 [cit. 5. mája 2023]. Dostupné z: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Energy_consumption_in_households.
- [28] GOOGLE. *How a Nest thermostat helps save energy* [online]. [cit. 28. júla 2023]. Dostupné z: <https://support.google.com/googlenest/answer/9254386>.
- [29] GRAM HANSEN, K. a DARBY, S. “Home is where the smart is”? Evaluating smart home research and approaches against the concept of home. *Energy Research & Social Science*. Marec 2018, zv. 37, s. 94–101. DOI: 10.1016/j.erss.2017.09.037.
- [30] GRÜNWARD, A. *Z hloupého bojleru chytrý pomocí chytré zásuvky*. Brno, CZ, 2021. Bakalárska práca. Vysoké učení technické v Brně, Fakulta informačních technologií. Dostupné z: <https://www.fit.vut.cz/study/thesis/23744/>.
- [31] HERRING, M. *Time series database (TSDB) explained* [online]. Máj 2022. Aktualizované 10. 06. 2022 [cit. 14. januára 2023]. Dostupné z: <https://www.influxdata.com/time-series-database/>.
- [32] HITACHI. *Climate Control Made Easy – Understanding Heat Pump Controllers* [online]. [cit. 28. júla 2023]. Dostupné z: <https://www.hitachiaircon.com/nz/articles/climate-control-made-easy-understanding-controllers>.
- [33] HYNDMAN, R. J. a ATHANASOPOULOS, G. *Forecasting: Principles and practice*. 3. vyd. Otexts, máj 2021. ISBN 978-0987507136.
- [34] KASSAB, W. a DARABKH, K. A. A–Z survey of Internet of Things: Architectures, protocols, applications, recent advances, future directions and recommendations. *Journal of Network and Computer Applications*. 2020, zv. 163. DOI: <https://doi.org/10.1016/j.jnca.2020.102663>. ISSN 1084-8045. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1084804520301375>.
- [35] KUMAR, A. *Different types of time-series forecasting models* [online]. Aug 2022 [cit. 18. januára 2023]. Dostupné z: <https://vitalflux.com/different-types-of-time-series-forecasting-models/>.
- [36] LEWINSON, E. *Three approaches to feature engineering for Time Series* [online]. Towards Data Science, Aug 2022 [cit. 14. júla 2023]. Dostupné z: <https://towardsdatascience.com/three-approaches-to-feature-engineering-for-time-series-2123069567be>.

- [37] LIN, J., KEOGH, E., LONARDI, S. a CHIU, B. A Symbolic Representation of Time Series, with Implications for Streaming Algorithms. In: *Proceedings of the 8th ACM SIGMOD Workshop on Research Issues in Data Mining and Knowledge Discovery*. New York, NY, USA: Association for Computing Machinery, 2003, s. 2–11. DOI: 10.1145/882082.882086. ISBN 9781450374224. Dostupné z: <https://doi.org/10.1145/882082.882086>.
- [38] MACHARLA, M. *Zigbee and its importance in the internet of things* [online]. Dec 2020 [cit. 7. mája 2023]. Dostupné z: <https://iot4beginners.com/zigbee-and-its-importance-in-the-internet-of-things/>.
- [39] MITURA, J. *Z hloupého bojleru chytrý pomocí chytré zásuvky*. Brno, CZ, 2021. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Dostupné z: <https://www.fit.vut.cz/study/thesis/24021/>.
- [40] MYLMS.CZ. *Zapojení a údržba bojleru* [online]. Júl 2018 [cit. 12. januára 2023]. Dostupné z: <https://www.mylms.cz/zapojeni-a-udrzba-bojleru/>.
- [41] NAKADE, J., NAKAMURA, Y., KATAYAMA, Y., OBATA, H., TAKAHASHI, Y. et al. Systematic active environmental surveillance successfully identified and controlled the Legionella contamination in the hospital. *Journal of Infection and Chemotherapy*. 2023, zv. 29, č. 1, s. 43–47. DOI: <https://doi.org/10.1016/j.jiac.2022.09.010>. ISSN 1341-321X. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1341321X22002707>.
- [42] ODUNLADE, E. *What makes a smart home smart? A guide to protocols and applications* [online]. Jan 2022 [cit. 7. mája 2023]. Dostupné z: <https://www.wevolver.com/article/what-makes-a-smart-home-smart-a-guide-to-protocols-and-applications>.
- [43] ORGANIZATION, W. H. *Legionella and the prevention of legionellosis*. World Health Organization, 2007. 252 s.
- [44] PARMEZAN, A. R. S., SOUZA, V. M. a BATISTA, G. E. Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model. *Information Sciences*. 2019, zv. 484, s. 302–337. DOI: <https://doi.org/10.1016/j.ins.2019.01.076>. ISSN 0020-0255. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0020025519300945>.
- [45] PARTICLE. *Cellular vs. WIFI for IOT: How to choose the right one* [online]. [cit. 7. mája 2023]. Dostupné z: <https://www.particle.io/iot-guides-and-resources/cellular-vs-wifi-for-iot/>.
- [46] PETAN. *HDO a noční proud – jak to vlastně funguje?* [online]. Apríl 2018. Aktualizované 11. 08. 2018 [cit. 15. júla 2023]. Dostupné z: <https://www.mylms.cz/hdo-a-nocni-proud-jak-to-vlastne-funguje/>.
- [47] PLUNKETT, J. *Introducing downsampling for time series data* [online]. Sep 2021 [cit. 7. mája 2023]. Dostupné z: <https://www.edgeimpulse.com/blog/introducing-downsampling-for-time-series-data>.

- [48] PLYN.CZ. *Topíte plynem? V roce 2020 zaplatíte v průměru kolem 31 tisíc za energii* [online]. May 2020 [cit. 14. júla 2023]. Dostupné z: <https://www.plyn.cz/ceny-plynu-za-m3-2020-vytapeni-plynem>.
- [49] PRA, M. D. *Time series forecasting with deep learning and attention mechanism* [online]. Towards Data Science, Nov 2020 [cit. 18. januára 2023]. Dostupné z: <https://towardsdatascience.com/time-series-forecasting-with-deep-learning-and-attention-mechanism-2d001fc871fc>.
- [50] PWLL, J. *Raspberry-pi home heating controller* [online]. Instructables, Sep 2017 [cit. 28. júla 2023]. Dostupné z: <https://www.instructables.com/Raspberry-Pi-Home-Heating-Controller/>.
- [51] RAY, P. A survey on Internet of Things architectures. *Journal of King Saud University – Computer and Information Sciences*. 2018, zv. 30, č. 3, s. 291–319. DOI: <https://doi.org/10.1016/j.jksuci.2016.10.003>. ISSN 1319-1578. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1319157816300799>.
- [52] REGUNATH, G. a LANTOS, D. *10 Incredibly Useful Time Series Forecasting Algorithms* [online]. Jún 2021. Aktualizované 15. 02. 2022 [cit. 15. januára 2023]. Dostupné z: <https://www.advancinganalytics.co.uk/blog/2021/06/22/10-incredibly-useful-time-series-forecasting-algorithms>.
- [53] ROSE, K., ELDRIDGE, S. a CHAPIN, L. The internet of things: An overview. *The internet society (ISOC)*. Reston, VA. 2015, zv. 80, s. 1–50.
- [54] SAMIE, F., BAUER, L. a HENKEL, J. IoT Technologies for Embedded Computing: A Survey. In:.. Október 2016. DOI: 10.1145/2968456.2974004.
- [55] SCHIEFER, M. Smart Home Definition and Security Threats. In: *2015 Ninth International Conference on IT Security Incident Management & IT Forensics*. 2015, s. 114–118. DOI: 10.1109/IMF.2015.17.
- [56] SHI, J., JAIN, M. a NARASIMHAN, G. Time Series Forecasting (TSF) Using Various Deep Learning Models. *International Journal of Computer and Systems Engineering*. Jún 2022, zv. 16, č. 6, s. 224–232. Dostupné z: <https://doi.org/10.48550/arXiv.2204.11115>.
- [57] SINGH, A. *6 powerful feature engineering techniques for time series data (using python)* [online]. Apr 2020 [cit. 14. júla 2023]. Dostupné z: <https://www.analyticsvidhya.com/blog/2019/12/6-powerful-feature-engineering-techniques-time-series/>.
- [58] STIEBEL ELTRON. *PSH 100 Universal El Stiebel Eltron* [online]. [cit. 9. mája 2023]. Dostupné z: https://www.stiebel-eltron.sk/sk/produkty-a-riesenia/ohrev_vody/zasobnikove_ohrievacevody/nastenne_ohrievacevodyod30do150l/psh-universal-el/psh-100-universal-el.html.
- [59] SUMMER, O. *What is Time Series Data? Definition, Examples, Types & Uses* [online]. December 2019. Aktualizované 01. 05. 2022 [cit. 14. januára 2023]. Dostupné z: <https://www.influxdata.com/what-is-time-series-data/>.

- [60] TAO, J. *Time-Series Database Basics* [online]. Aug 2022 [cit. 12. júla 2023]. Dostupné z: <https://devops.com/time-series-database-basics/>.
- [61] VIESSMANN, s. *Druhy Vykurovania* [online]. Júl 2017. Aktualizované 19. 02. 2018 [cit. 12. januára 2023]. Dostupné z: <https://vykurovanie24.sk/druhy-vykurovania/>.
- [62] VYKUROVANIE24.SK. *Ohrievače teplej úžitkovej Vody: Centrálna Alebo Decentrálne?* [online]. Január 2019 [cit. 12. januára 2023]. Dostupné z: <https://vykurovanie24.sk/magazin/vykurovanie/ohrievace-teplej-uzitkovej-vody-centralne-alebo-decentralne/>.
- [63] WANG, Y., VELSWAMY, K. a HUANG, B. A Long-Short Term Memory Recurrent Neural Network Based Reinforcement Learning Controller for Office Heating Ventilation and Air Conditioning Systems. *Processes*. 2017, zv. 5, č. 3. DOI: 10.3390/pr5030046. ISSN 2227-9717. Dostupné z: <https://www.mdpi.com/2227-9717/5/3/46>.
- [64] WOLLERTON, M. *Best smart thermostats for 2023* [online]. CNET, január 2023 [cit. 21. januára 2023]. Dostupné z: <https://www.cnet.com/home/energy-and-utilities/best-smart-thermostats/>.
- [65] WORTMANN, F. a FLÜCHTER, K. Internet of Things. *Business & Information Systems Engineering*. Springer. 2015, zv. 57, č. 3, s. 221–224. DOI: 10.1007/s12599-015-0383-3.
- [66] YANG, H., LEE, H. a ZO, H. User acceptance of smart home services: An extension of the theory of planned behavior. *Industrial Management & Data Systems*. Február 2017, zv. 117, s. 68–89. DOI: 10.1108/IMDS-01-2016-0017.