



**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

**VYUŽITÍ METOD STROJOVÉHO UČENÍ PRO ÚSPORU  
ENERGIE V CHYTRÉ DOMÁCNOSTI**

USING MACHINE LEARNING METHODS TO SAVE ENERGY IN A SMART HOME

**DIPLOMOVÁ PRÁCE**

MASTER'S THESIS

**AUTOR PRÁCE**

AUTHOR

**Bc. ADAM GRÜN WALD**

**VEDOUcí PRÁCE**

SUPERVISOR

**Ing. ZDENĚK MATERNA, Ph.D.**

BRNO 2024

## Zadání diplomové práce



156586

Ústav: Ústav počítačové grafiky a multimédií (UPGM)  
Student: **Grünwald Adam, Bc.**  
Program: Informační technologie a umělá inteligence  
Specializace: Softwarové inženýrství  
Název: **Využití metod strojového učení pro úsporu energie v chytré domácnosti**  
Kategorie: Umělá inteligence  
Akademický rok: 2023/24

### Zadání:

1. Proveďte rešerši existujících řešení pro úsporu energie (např. ohřev TUV, řízení vytápění) v chytrých domácnostech.
2. Navrhněte hardwarovou i softwarovou část vlastního řešení využívajícího historická data a predikci pomocí metod strojového učení k řízení energeticky náročných spotřebičů.
3. Realizujte navržené řešení.
4. Ověřte funkčnost řešení dlouhodobým testem na alespoň dvou testovacích instalacích.
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:

- Hotové body 1-2, rozpracovaný bod 3.

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: 1.11.2023  
Termín pro odevzdání: 17.5.2024  
Datum schválení: 9.11.2023

## Abstrakt

Tato diplomová práce řeší využití strojového učení pro úsporu energie v domácnosti, konkrétně se pak zaměřuje na využití predikce spotřeby teplé vody z bojleru pro chytrý ohřev. Pro predikci spotřeby je využita sekvenční neuronová síť s LSTM vrstvou, která je natrénována na datech jako je spotřeba teplé vody v čase, přítomnost uživatelů v domácnosti, denní doba či informace o aktuálním počasí. Data byla sbírána ve dvou testovacích domácnostech. Tato predikce je následně využita v implementovaném algoritmu, který zajišťuje, aby voda v bojleru byla ohřívána na vyšší teplotu, jejíž hodnotu určuje množství predikovaného odebraného tepla, až před předpokládanou spotřebou teplé vody. Díky tomuto chytrému ohřevu došlo ke snížení tepelných ztrát bojleru a tím i ke snížení spotřeby energie o téměř 27 % při zachování tepelného komfortu členů domácnosti. Toto řešení, které umožňuje jeho uživatelům ušetřit ročně více než 1500 Kč, bylo také zveřejněno jako doplněk v rámci platformy Home Assistant.

## Abstract

This thesis addresses the use of machine learning for energy saving in the home, specifically focusing on the use of hot water boiler consumption prediction for smart heating. A sequential neural network with an LSTM layer is used to predict the consumption, which is trained on data such as hot water consumption over time, presence of users in the home, time of day or current weather information. Data were collected in two test households. This prediction is then used in an implemented algorithm that ensures that the water in the boiler is heated to a higher temperature, the value of which is determined by the amount of predicted heat extracted, before the predicted hot water consumption. Thanks to this smart heating, the heat loss of the boiler has been reduced and thus the energy consumption has been reduced by almost 27% while maintaining the thermal comfort of the household members. This solution, which allows its users to save more than 1500 Kč annually, has also been released as an add-on as part of the Home Assistant platform.

## Klíčová slova

chytrá domácnost, strojové učení, úspora energií, IoT

## Keywords

smart home, machine learning, energy savings, IoT

## Citace

GRÜNWALD, Adam. *Využití metod strojového učení pro úsporu energie v chytré domácnosti*. Brno, 2024. Diplomová práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Ing. Zdeněk Materna, Ph.D.

# Využití metod strojového učení pro úsporu energie v chytré domácnosti

## Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně pod vedením pana Ing. Zdeňka Materny, PhD. Uvedl jsem všechny literární prameny, publikace a další zdroje, ze kterých jsem čerpal.

.....  
Adam Grünwald  
13. května 2024

## Poděkování

Rád bych poděkoval mému vedoucímu Ing. Zdeňku Maternovi, Ph.D. za cenné rady a konzultace.

# Obsah

<b>1</b>	<b>Úvod</b>	<b>2</b>
<b>2</b>	<b>Metody strojového učení a jejich využití v chytré domácnosti</b>	<b>3</b>
2.1	Modely časových řad . . . . .	3
2.2	Využití metod strojového učení v praxi . . . . .	11
<b>3</b>	<b>Zařízení a technologie pro chod chytré domácnosti</b>	<b>13</b>
3.1	Systémy chytré domácnosti . . . . .	13
3.2	Chytré osvětlení . . . . .	19
3.3	Chytré vytápění . . . . .	20
3.4	Chytrý ohřev vody . . . . .	22
<b>4</b>	<b>Návrh řešení pro úsporu energií v chytré domácnosti</b>	<b>29</b>
4.1	Řídicí komponenty a čidla . . . . .	29
4.2	Softwarová část . . . . .	31
4.3	Algoritmus chytrého ohřevu TUV . . . . .	33
<b>5</b>	<b>Implementace ohřevu TUV s využitím strojového učení</b>	<b>35</b>
5.1	Domácí server pro chod systému chytré domácnosti . . . . .	35
5.2	Zařízení pro sběr dat a řízení bojleru . . . . .	37
5.3	Tvorba trénovací sady dat . . . . .	41
5.4	Tvorba modelu a predikce spotřeby . . . . .	43
5.5	Úspěšnost predikce . . . . .	43
5.6	Doplněk chytrého ohřevu pro Home Assistant . . . . .	45
<b>6</b>	<b>Testování implementovaného řešení a vyhodnocení úspor</b>	<b>47</b>
6.1	Testovací domácnosti . . . . .	47
6.2	Dosažená úspora . . . . .	48
6.3	Komfort uživatelů a zpětná vazba . . . . .	51
6.4	Plán do budoucna . . . . .	52
<b>7</b>	<b>Závěr</b>	<b>53</b>
	<b>Literatura</b>	<b>54</b>

# Kapitola 1

## Úvod

V dnešní době, kdy se moderní technologie stávají neodmyslitelnou součástí našich domovů, se nabízí mnoho možností, jak využít pokročilé techniky k efektivnějšímu a udržitelnějšímu chodu domácností. Bohužel, současná komerční řešení nenabízí zákazníkům plné využití potenciálu velkého množství sbíraných dat z chytrých zařízení v domácnosti. Efektivní využití dat z chytré domácnosti může přinést nejen úspory v rámci nákladů na chod domácnosti, ale je také šetrnější k životnímu prostředí díky snížení emisí potřebných k výrobě energie. Jeden z klíčových aspektů energetické účinnosti spočívá v efektivním řízení ohřevu teplé vody a vytápění, které je v souladu s potřebami a komfortem uživatelů a současně minimalizuje energetické ztráty. Právě vytápění a ohřev teplé vody činí v českých domácnostech čtyři pětiny všech nákladů na energie, kdy vytápění tvoří zhruba 65 % a ohřev vody zbylých 16 % [50]. Díky tomu i malé snížení nákladů znamená zajímavou úsporu.

Tato diplomová práce se zaměřuje na využití strojového učení v chytrých domácnostech s cílem optimalizovat spotřebu energie implementací inteligentního řízení ohřevu teplé vody, kdy díky predikci spotřeby bude voda v bojleru nahřívána na vyšší než pohotovostní teplotu až těsně před očekávanou spotřebou, čímž dojde ke snížení tepelných ztrát. Kromě toho by výsledné řešení mělo obsahovat další funkce pro zvýšení komfortu a bezpečí jeho uživatelů. Dále by mělo být dostupné prostřednictvím systému pro chytré domácnosti Home Assistant, aby z výhod plynoucích z chytrého ohřevu mohla těžit široká uživatelská základna tohoto systému.

Práce je rozdělena do několika kapitol, kde se kapitola 2 zaměřuje na řešení metod strojového učení a jejich využití v řešeních pro úsporu energií v domácnosti. Kapitola 3 se věnuje zařízením a technologiím využívaných v chytrých domácnostech. Kapitola 4 se pak zabývá návrhem hardwarového a softwarového řešení pro úsporu energií v chytré domácnosti pomocí chytrého ohřevu teplé vody v bojleru. V kapitole 5 je rozebrána implementace navrženého řešení. Kapitola 6 obsahuje vyhodnocení úspěšnosti implementovaného řešení a zpětné vazby od uživatelů.

## Kapitola 2

# Metody strojového učení a jejich využití v chytré domácnosti

Moderní chytré domácnosti jsou v podstatě spojením inovativních technologií s každodenním životem, což přináší řadu výhod pro obyvatele. Jednou z těchto výhod je pohodlné ovládání spotřebičů a snadný přístup k informacím o stavu domácnosti, což vede ke zvýšení komfortu a efektivity různých systémů, jako je například osvětlení nebo vytápění. Navíc díky chytrým domácnostem lze sbírat a analyzovat velké množství dat, která mohou být využita k optimalizaci různých aspektů domácího života, včetně bezpečnosti, energetické účinnosti a pohodlí obyvatel.

Data v rámci chytrých domácností mohou být vnímána jako časové řady, což znamená, že zachycují vývoj různých proměnných v čase. Mezi tyto proměnné mohou patřit například teplota, vlhkost, spotřeba elektrické energie nebo přítomnost osob v domácnosti.

V rámci této kapitoly rozeberu v části 2.1 vlastnosti časových řad a jednotlivé modely, kdy se zaměřím na predikování veličin v čase. Ve druhé části této kapitoly 2.2 poté představím existující řešení, která se zabývají využitím strojového učení v praxi chytrých domácností.

### 2.1 Modely časových řad

Pro popis technik strojového učení pro chytrou domácnost, je nezbytné porozumět jednotlivým metodám, které lze aplikovat na data získaná z těchto prostředí. Jelikož hlavní snahou v rámci mé práce je odhadnout chování uživatelů v čase, jako spotřeba teplé vody, zaměřím se proto na rozbor predikce s pomocí modelů časových řad.

Modely časových řad tvoří významnou statistickou disciplínu, ve které v poslední době dochází k velkému rozvoji díky zvýšení výkonu výpočetní techniky. Predikce vývoje časových řad se používá například pro předpověď vývoje akciových trhů [46], predikci prodejů [15], nebo spotřeby elektrické energie [7].

K samotnému modelování časových řad lze využít několika přístupů, které se liší v míře využití náhodných vlivů ve statistickém modelu. Podle toho, zda k jedné časové značce je přiřazena jedna nebo více veličin, rozlišujeme metody na jednorozměrné a vícerozměrné.

#### Vlastnosti časových řad

Pro pochopení modelování časových řad je vhodné znát vlastnosti, které se mohou u těchto dat vyskytnout [26, 10]:

1. Trend – jedná se o dlouhodobý trend v datech, během kterého hodnoty buď rostou nebo klesají v průběhu času.
2. Sezónnost – jde o vzor, který se opakuje v datech v pravidelných intervalech. Jedná se například například o denní, týdenní, či měsíční.
3. Cykličnost – je to vzor stoupání či klesání opakující se v delších nepravidelných časových horizontech.
4. Stacionarita – vztahuje se na vlastnosti časových řad, které zůstávají konstantní v průběhu času – průměr, rozptyl, autokorelace.
5. Autokorelace – sleduje stupeň podobnosti mezi časovou řadou a posunutou verzí sebe sama.
6. Odlehlé hodnoty – odlehlé hodnoty jsou pozorování, která se významně liší od ostatních pozorování v časové řadě.
7. Chybějící hodnoty – mohou se vyskytnout v případech chybějících dat v pozorování pro některé časové body.
8. Šum – vztahuje se k náhodným fluktuacím nebo chybám v datech, které nejsou spojeny s žádným konkrétním vzorem nebo trendem.

Pro predikci chování uživatelů při zaměření na jejich výskyt v domácnosti a spotřebu teplé vody je důležité vybrat model časových řad. Ten by měl být schopný pracovat se sezónností, trendem, odlehlými hodnotami nebo s hodnotami chybějícími. Proto v této kapitole popíšu několik modelů pro predikci časových řad, včetně jejich výhod a nevýhod.

### Lineární regrese

Lineární regrese je statistickou metodou sloužící k získání předpisu funkce, díky kterému je možné předpovědět hodnotu jedné proměnné na základě znalosti jiné proměnné. To je možné díky příčinné závislosti mezi těmito proměnnými. Základním stavebním prvkem jednoduché lineární regrese je rovnice přímky 2.1:

$$y = \beta_0 + \beta_1 X_i + \epsilon_i \quad (2.1)$$

Jednoduchá lineární regrese pak zkoumá lineární vztah proměnných  $x$  a  $y$ , kde  $y$  je závislá a  $x$  nezávislá proměnná. Parametry  $\beta_0$  a  $\beta_1$  jsou neznámé konstanty, které je nutné odhadnout z nasbíraných dat, kdy  $\beta_0$  představuje konstantní člen pro posunutí přímky po ose  $y$  a  $\beta_1$  udává směrnici přímky [6].

Tento princip je pak možné rozšířit na obecnou lineární regresi, která je dána kombinací  $k$  funkcí jako 2.2:

$$y = \beta_1 f_1(x) + \dots + \beta_k f_k(x) \quad (2.2)$$

, kde :

- $f_1(x), \dots, f_k(x)$  jsou libovolné funkce,
- $\beta_1, \dots, \beta_k$  jsou koeficienty vypočteny metodou nejmenších čtverců.

### Autoregresivní model

Jedná se o jeden z nezákladnějších modelů pro predikci časových řad, který je označován zkratkou AR<sup>1</sup> a slouží pro popis náhodného procesu. Je využíván k popisu časově proměnných procesů v přírodě, ekonomice, nebo chování spotřebitelů. Tento model udává, jak výstupní proměnná lineárně závisí na svých vlastních předchozích hodnotách a na stochastickém členu. Model má proto podobu stochastické diferenciální rovnice. Spolu s modelem klouzavého průměru 2.1 je zvláštním případem a klíčovou součástí obecnějších modelů časových řad s autoregresivním klouzavým průměrem 2.1 a autoregresivním integrovaným klouzavým průměrem 2.1, které mají složitější stochastickou strukturu a které budou popsány dále.

Model lze popsat rovnicí 2.3:

$$y_t = \beta_0 + \sum_{i=1}^p \beta_i y_{t-i} + \varepsilon_t \quad (2.3)$$

, kde :

- $\beta_i$  popisuje, jak moc stav systému před  $i$  kroky ovlivní aktuální hodnoty,
- $p$  definuje řád modelu,
- $\varepsilon_t$  je šumový člen.

Za normálních okolností se dá předpokládat, že  $\beta_i$  se bude s rostoucím  $i$  zmenšovat, což znamená, že události, které se stanou dále v minulosti, mají menší vliv na aktuální události. Dále vše, co se stalo dříve než před  $p$  časovými kroky, nemá na predikovanou hodnotu žádný vliv.

Tento model je možné rozšířit pro práci s vícerozměrnými daty – VAR<sup>2</sup>, kdy stejně jako u autoregresivního modelu je každá proměnná definovaná rovnicí, která modeluje její vývoj v čase. Jediné předchozí znalosti, které jsou zapotřebí, je seznam proměnných, o nichž lze předpokládat, že se v čase vzájemně ovlivňují.

Mezi výhody tohoto modelu patří schopnost předpovědi díky opakujícím se vzorcům v datech, menší požadavky na množství dat k trénování a jednoduchost implementace. Jako nevýhoda je často uváděna schopnost modelování pouze lineárních závislostí v datech, nebo předpoklad, že historická data mají stejný dopad na budoucí hodnoty, což nemusí být vždy pravda [31].

<sup>1</sup>AR – AutoRegressive model (Autoregresivní model).

<sup>2</sup>VAR – Vector AutoRegressive model (Vektorový autoregresivní model).

## Model klouzavého průměru

Další z modelů je model klouzavého průměru označován jako MA<sup>3</sup>, který je často využíván pro modelování jednorozměrných řad. V případě modelu s klouzavým průměrem se výstupní proměnná modeluje jako lineární kombinace minulých chyb nebo reziduí namísto minulých hodnot této proměnné [31].

V modelu MA se předpokládá, že rezidua jsou nezávislé a identicky rozdělené náhodné proměnné s normálním rozdělením [29]. Je definován rovnicí 2.4:

$$x_t = \mu + \omega_t + \theta_1\omega_{t-1} + \theta_2\omega_{t-2} + \dots + \theta_q\omega_{t-q} \quad (2.4)$$

, kde :

- $q$  specifikuje řád klouzavého průměru, což představuje počet minulých chyb, které jsou zahrnuty do modelu,
- $\mu$  je průměr řady,
- $\theta_1, \dots, \theta_q$  jsou parametry modelu,
- $\omega_t, \dots, \omega_{t-q}$  jsou členy bílého šumu.

Tento model lze rovněž rozšířit pro práci s více časovými řadami, což umožňuje analyzovat jejich vzájemné vztahy. Tento model tak modeluje jejich závislost a predikuje budoucí hodnoty na základě průměru předchozích hodnot těchto časových řad.

Mezi výhody tohoto modelu se stejně jako v případě AR řadí jednoduchá implementace. Dále také schopnost zachycení krátkodobých závislostí v pozorovaných datech. Mezi nevýhody patří přehlížení složitých závislostí obsažených v datech a požadavek na velké množství trénovacích dat. Model rovněž není vhodný pro data obsahující trendy či sezónnost, což se dá v případě predikce režimu domácnosti předpokládat [22].

## ARMA

Autoregresivní model klouzavého průměru je kombinací předchozích dvou modelů. Používá se pro popis slabě stochastického procesu s využitím dvou polynomů – jeden pro klouzavý průměr a druhý pro autoregresi.

Výsledný model se obvykle označuje jako  $ARMA(p, q)$ , kde  $p$  je počet členů AR části a  $q$  pak počet členů části MA.

Pro nalezení ideálních hodnot  $p$  a  $q$  pro trénování modelu se využívají rozšířené autokorelační funkce EACF<sup>4</sup> [47].

Pro modelování vícerozměrných časových řad se využívá rozšíření VARMA<sup>5</sup>, které dokáže modelovat vzájemnou závislost mezi více časovými řadami pomocí autoregrese a klouzavého průměru.

Mezi hlavní výhody modelu ARMA se řadí jeho schopnost kombinování AR a MA modelů, díky čemuž jsou v datech zachyceny jak autokorelace, tak křížové korelace. Dále jej lze použít nejen pro predikci budoucnosti, ale také pro testování hypotéz. Nevýhoda ARMA

<sup>3</sup>MA – Moving Average (Model klouzavého průměru).

<sup>4</sup>EACF – Extended Autocorrelation Function (Rozšířená autokorelační funkce).

<sup>5</sup>VARMA – Vector Auto Regressive Moving Average model (Vektorový autoregresivní model klouzavého průměru).

modelu je ta, že tento model vyžaduje velké množství pozorování pro přesné odhadnutí parametrů modelu. To může být limitující u krátkých časových řad, nebo pro řady s chybějícími daty. Mezi nevýhody se řadí také to, že ARMA model předpokládá stacionaritu v datech, což u mnoha reálných časových řad nemusí být splněno a může způsobit nepřesné předpovědi modelu nebo zavádějící výsledky.

## ARIMA

Model ARIMA se od modelu ARMA liší tím, že umožňuje modelování jak stacionárních, tak nestacionárních časových řad. Tento model obsahuje přídavnou komponentu – diferenciaci, která je využívána pro transformaci nestacionárních časových řad na stacionární. Diferenciace spočívá v rozdílu mezi po sobě jdoucími pozorování časové řady. V případě potřeby lze pro zajištění stacionarity provést tento krok vícekrát. Jakmile dojde k diferenciaci dat, lze na ně aplikovat ARMA model.

Model ARIMA lze charakterizovat podle jeho řádů jako  $p, d$  a  $q$  –  $ARIMA(p, d, q)$ , kde  $p$  je počet členů AR části,  $d$  je počet diferenciací potřebných k dosažení stacionarity a  $q$  udává počet členů části MA.

## SARIMA

Rozšířením modelu ARIMA o sezónní složku získáváme model SARIMA, který je schopný zachytit sezónnost v datech časové řady. Sezónní složka se uvádí v další závorce velkými písmeny. Výsledný model je pak definován jako 2.5:

$$SARIMA(p, d, q)(P, D, Q, M) \quad (2.5)$$

, kde :

- $D$  označuje řád integrace sezónního procesu (počet transformací potřebných k tomu, aby se časová řada stala stacionární),
- $P$  označuje řád autoregresního procesu pro sezónní složku,
- $Q$  označuje řád klouzavého průměru pro sezónní složku,
- $M$  označuje periodicitu, tj. počet období v sezóně, např. 12 pro měsíční údaje.

Vektorová verze, která rozšiřuje model SARIMA pro modelování vícerozměrných časových řad se sezónní složkou a vzájemnými závislostmi, se nazývá VARIMA.

Jako výhoda modelu SARIMA je uváděna jeho schopnost modelování sezónnosti v datech a zachycení krátkodobých i dlouhodobých závislostí. Za nevýhodu je pak označována nutnost zadefinování více parametrů pro nastavení modelu, což zvyšuje komplexnost a výpočetní náročnost tohoto modelu. Další nevýhodou může být menší přesnost v případě, kdy se v datech vyskytuje nesezónní trend, strukturální změny nebo posuny. SARIMA totiž předpokládá, že jsou sezónní vzory stálé a konzistentní v čase, což nemusí být vždy pravda. V těchto případech pak může být samotná ARIMA více flexibilní a robustní [5].

## SARIMAX

Dalším možným rozšířením předchozích modelů je přidání exogenních proměnných<sup>6</sup>. Tato varianta se označuje jako SARIMAX. Tento model je schopný vylepšit modelování časové řady v případě, kdy existuje vztah mezi exogenními proměnnými a výslednou proměnnou.

SARIMAX model lze použít pro modelování časových řad, ve kterých jsou exogenní proměnné relevantní – pro ekonomická data, kde mohou být exogenní proměnné např. HDP, inflace, měnová politika atd. Tyto proměnné mohou být využity ke zlepšení predikce časové řady.

Tento model je založen na předpokladu stacionarity časové řady a je citlivý na správnou volbu řádu modelu, případně vhodnou identifikaci sezónnosti.

Verze tohoto modelu pro modelování vícerozměrných časových řad se nazývá VARMAX. Výhodou modelů VARMAX je, že dokáží zachytit krátkodobé i dlouhodobé závislosti v datech. Dále také jejich schopnost zpracovávat nestacionární časové řady dat. Jako nevýhoda je uváděn obtížný proces stanovení správných hodnot  $p$ ,  $d$  a  $q$ , případně  $P$ ,  $D$  a  $Q$ . Modely ARIMA a SARIMA jsou citlivé na odlehlé a extrémní hodnoty v datech. Zahrnutí exogenních proměnných do modelu může zajistit určitou míru robustnosti. Model SARIMAX je tak schopen lépe zachytit základní vzorce v datech a být méně citlivý na odlehlé hodnoty.

## Prophet


Prophet je knihovna s otevřeným zdrojovým kódem od společnosti Facebook, která je založena na využití bayesovského přístupu k předpovídání časových řad, a která zahrnuje přizpůsobení dat zobecněnému aditivnímu modelu GAM<sup>7</sup>.

Tento model zahrnuje několik složek jako je trend, sezónnost, nebo svátky. Složka trendu se modeluje pomocí funkce definované po částech nebo logistické funkce, zatímco složka sezónnosti se modeluje pomocí Fourierových řad. Bayesovský přístup umožňuje odhad nejistoty a zahrnutí předchozích znalostí o datech viz obrázek 2.1. Model dokáže provádět předpovědi časových řad s dobrou přesností za pomoci jednoduchých intuitivních parametrů a má podporu pro zahrnutí vlivu vlastní sezónnosti a svátků [38, 14].

---

<sup>6</sup>Exogenní proměnné jsou proměnné, které jsou vnější vůči modelu a nejsou ovlivňovány jinými proměnnými v modelu. Tyto proměnné mohou být využity k vysvětlení variability závislé proměnné v modelu, která by jinak zůstala nevysvětlena. Exogenní proměnné se používají například v modelování ekonomických časových řad, kde se může jednat o proměnné jako je například inflace, měnová politika nebo sezónnost. V SARIMAX modelu jsou exogenní proměnné zahrnuty jako doplňkové vysvětlující proměnné a mohou pomoci přesněji předpovídat závislou proměnnou [21, 31].

<sup>7</sup>GAM – Generalized Additive (Zobecněný aditivní model), je statistický model používaný k analýze vztahů mezi předpokládanými nezávislými proměnnými a odezvou, přičemž se nepředpokládá lineární vztah mezi nezávislými proměnnými a odezvou, jako u klasických lineárních modelů. GAM modely se používají například k modelování vztahů mezi teplotou a denní dobou, kde lze očekávat nelineární závislost [43].



Obrázek 2.1: Předpověď modelu Facebook Prophet, kde černé body značí trénovací data a modré oblasti odhad modelu včetně míry neurčitosti (světle modrá). Převzato z [14].

Obecná myšlenka modelu je podobná zobecněnému aditivnímu modelu. Rovnice odpovídá, jak bylo uvedeno výše, trendům, sezónnosti a svátkům. Je to dáno následujícím vztahem popsaným v rovnici 2.6:

$$y(t) = g(t) + s(t) + h(t) + \epsilon(t) \quad (2.6)$$

, kde :

- $g(t)$  značí trend,
- $s(t)$  označuje sezónnost,
- $h(t)$  určuje vliv svátků na prognózu,
- $\epsilon(t)$  je chybový člen,
- $y(t)$  je samotná předpověď.

Mezi výhody tohoto modelu patří robustnost vůči chybějícím údajům a změnám trendu a sezónnosti. Zvládá různé typy sezónnosti jako denní, týdenní nebo roční, a vlivy svátků. Model je rychlý a škálovatelný pro velké objemy dat a rovněž obsahuje vestavěné funkce pro zpracování odlehklých hodnot.

Jako nevýhoda je často uváděna omezená flexibilita ve srovnání se složitějšími modely strojového učení. Prophet také nemusí dobře fungovat na souborech dat se složitými nebo nelineárními vzory. Také nezohledňuje vnější faktory, které mohou ovlivňovat časové řady, pokud nejsou explicitně zahrnuty jako regresory [38].

## Neural Prophet

Neural Prophet je rozšířením modelu Prophet, které využívá architekturu neuronové sítě ke zlepšení svých předpovědních schopností.

Neural Prophet vychází ze stejného aditivního modelu jako Prophet, ale lineární model pro trend a sezónnost nahrazuje dopřednou neuronovou sítí s jednou skrytou vrstvou. To umožňuje zachytit složitější vzorce a nelineární vztahy v datech časových řad. Neural Prophet lze nakonfigurovat tak, aby místo výchozí dopředné neuronové sítě pro modelování trendů a sezónnosti používal architekturu neuronové sítě s LSTM vrstvou.

Kromě architektury neuronové sítě obsahuje Neural Prophet také několik dalších vylepšení oproti původní verzi, jako je použití optimalizačního nástroje Gradient Descent z knihovny PyTorch, díky němuž je proces modelování mnohem rychlejší než v případě Prophetu. Dále využití vlastních ztrátových funkcí a metrik, nebo konfigurovatelné nelineární vrstvy dopředných neuronových sítí [2].

Celkově je Neural Prophet navržen tak, aby poskytoval přesnější a flexibilnější předpovědi časových řad než Prophet, zejména v případech, kdy data časových řad obsahují složité vzorce nebo nelineární vztahy [23].

Výhodou Neural Prophet je to, že dobře zvládá nelineární trendy a sezónnost viz obrázek 2.2, efektivně zpracovává chybějící hodnoty a odlehlé hodnoty. Tento model rovněž poskytuje intervaly nejistoty pro předpovědi, čehož by se dalo využít pro uživatelské nastavení požadované úspory, kdy by se ohřev u uživatelů s větším důrazem na úsporu řídil podle hodnot ze začátku intervalu očekávané spotřeby a naopak. Na jednodušších souborech dat však nemusí dosahovat takových výsledků jako jiné tradiční modely časových řad [8].

## Neuronová síť s LSTM vrstvou

LSTM<sup>8</sup> patří do rodiny RNN<sup>9</sup>, které umožňují předávat informace mezi vrstvami v čase, což umožňuje pracovat se sekvencemi proměnné délky. To poskytuje možnost modelovat posloupnosti dat, jako jsou například texty, řečové signály nebo časové řady. Oproti klasickým neuronovým sítím má RNN navíc schopnost uchovávat informace o stavu vstupních dat v paměti a používat je pro predikci dalších dat v posloupnosti [25]. Oproti klasickým dopředným neuronovým sítím tak LSTM poskytuje zpětnou vazbu, která umožňuje síti „zapamatovat si“ důležité informace, které se vyskytují v průběhu trénování. Tím se zlepšuje schopnost sítě zpracovávat a generovat nová data v závislosti na předchozích datech, což je velmi užitečné v mnoha aplikacích, jako jsou například překlad jazyka, rozpoznávání řeči, predikce textu nebo právě predikce časových řad. Taková síť je ideální pro úlohy jako je rozpoznávání řeči, strojový překlad, nebo právě předpověď časových řad [32].


Cílem architektury LSTM je poskytnout RNN krátkodobou paměť, která může trvat tisíce časových kroků, tedy dlouhou krátkodobou paměť.

Nevýhodou LSTM je, že u velkých souborů dat může být výpočetně náročné tento model natrénovat. Rovněž může být obtížné zvolit její optimální architekturu a parametry.

---

<sup>8</sup>LSTM – Long Short-Term Memory (Dlouhá krátkodobá paměť).

<sup>9</sup>RNN – Recurrent Neural Network (Rekurentní neuronová síť).



Obrázek 2.2: Výstup z modelu Neural Prophet zobrazující roční, měsíční a denní sezónnost v datech. Převzato z [40].

## 2.2 Využití metod strojového učení v praxi

Využitím metod strojového učení pro řízení atž už chytrých domácností, nebo i větších veřejných prostor se zabývá několik studií i reálných projektů. V této části se chci proto zaměřit na vybrané realizace a jejich zjištění.

Článek [34] se zabývá predikcí spotřeby v domácnosti. Autoři v něm popisují hybridní model LSTM-NP pro předpověď spotřeby elektřiny. V této práci byl zkoumán vliv informací o počasí, jako je teplota, rychlost větru a vlhkost, na zlepšení přesnosti předpovědi. Autoři hodnotí použitý model jako nejlepší ze všech testovaných, kdy jeho předpověď byla přesnější ve všech testovacích případech než ostatní zkoumané modely.

Autoři článku [45] pak použili pro řízení vytápění univerzitních budov agenta s využitím DLR<sup>10</sup>, který byl trénován na fyzikálně založeném modelu. Tento agent byl pak použit pro řízení vytápění v kancelářských prostorách univerzity, kdy jednotliví uživatelé měli možnost skrze mobilní aplikaci upřesňovat své teplotní návyky tomuto agentovi. Díky

<sup>10</sup>DLR – Deep Reinforcement Learning (Hluboké posilované učení).

řízenému vytápění bylo dosaženo úspory v rozmezí 16,6–18,2 % procent oproti klasickému řízení. Autoři dále uvádějí jako nevýhodu jejich řešení nízkou interakci uživatelů za účelem zlepšení jejich tepelného komfortu, nedostačující trénování DLR a potřebu velkého množství dat pro vytvoření modelu budovy.

Problém nedostatku dat k vytvoření fyzikálního modelu domácího vytápění je řešen v rámci článku [44], kde je tento model vytvořen za pomoci Markovských procesů. K tomu bylo využito dat z Pecan Street databáze<sup>11</sup>, která obsahuje data o dostupné sluneční energii v daném místě, spotřebě elektrických spotřebičů, ceně elektřiny v čase, venkovní teplotě a stavu HVAC<sup>12</sup> systému. Na těchto datech byla natrénována neuronová síť s cílem optimálního využití HVAC systému spolu s ostatními elektrickými spotřebiči v závislosti na aktuálně generované elektrické energii a stavu solární baterie. Autoři zde uvádějí, že se jim podařilo vytvořit robustní algoritmus, který dokáže pracovat s mnoha nejistými parametry tak, aby i při absenci dynamického teplotního modelu domácnosti bylo dosaženo tepelného komfortu při snížení spotřeby elektrické energie až o 15,21 procent.

V rámci diplomové práce [27] bylo využito LSTM neuronové sítě pro predikci spotřeby teplé užitkové vody (TUV) a výskytu osob v domácnosti pro systém vytápění. Na historických datech jako jsou teplota v domě, zaznamenaný výskyt osob v domácnosti a teplota na výstupní trubce bojleru, byly natrénovány dvě LSTM neuronové sítě pro vytápění a ohřev TUV. S jejich pomocí při optimalizování vytápění a ohřevu TUV bylo dosaženo snížení spotřeby elektrické energie v případě vytápění až o 30 % a v případě ohřevu vody v bojleru o 24 %.

Z představených studií vyplývá, že využití strojového učení může efektivně přispět k optimalizaci vytápění a ohřevu teplé vody s cílem snížení nákladů. Modely založené na LSTM sítích se ukázaly jako úspěšné nástroje pro predikci spotřeby, kdy i například informace o aktuálním počasí mohou být prospěšné pro zpřesnění výsledné predikce.

---

<sup>11</sup><https://www.pecanstreet.org/>

<sup>12</sup>HVAC – Heating, Ventilation and Air Conditioning (Vytápění, ventilace a klimatizace).

## Kapitola 3

# Zařízení a technologie pro chod chytré domácnosti

Díky technologickému posunu v oblasti chytrých systémů a domácností došlo k revoluci ve způsobu toho, jak lidé interagují se svými domácnostmi a co od nich požadují. V této kapitole budou rozebrány technologie a řešení, které mohou v současné době jejich uživatele využít pro vytvoření a chod jejich vlastní chytré domácnosti. Kapitola se zaměřuje na základní definici chytré domácnosti, platformy a systémy pro chytré domácnosti a konkrétní chytrá řešení, která mohou jejich uživatelům přinést kromě pohodlí také úsporu za energie, kam lze zařadit chytré osvětlení, vytápění nebo ohřev vody.

### 3.1 Systémy chytré domácnosti

Chytrá domácnost je obecný koncept propojení moderních technologií spolu s konkrétními zařízeními s cílem zvýšení jejich efektivity, komfortu uživatelů a bezpečnosti domácnosti jako takové. Lze tak nazvat domácnost vybavenou chytrými zařízeními a technologiemi, které umožňují jejich automatizaci, monitorování stavu a ovládání na základě požadavků nebo chování jejich uživatelů. Tato zařízení lze integrovat do systémů chytrých domácností, které poskytují kontrolu nad vytápěním, osvětlením, ohřevem teplé vody, bezpečnostními prvky a dalšími zařízeními pomocí mobilních aplikací, webových rozhraní nebo hlasových asistentů.

Systémy chytré domácnosti lze následně chápat jako soubor hardwarových a softwarových komponent umožňující integraci, monitoring a řízení chytrých zařízení a technologií v domácnosti. Tato struktura se skládá z centrální jednotky, která zajišťuje koordinaci svých jednotlivých komponent, dále pak z jednotlivých chytrých zařízení a technologií umožňující jejich vzájemnou komunikaci a spolupráci v rámci chytré domácnosti. Díky tomu lze následně sledovat stav domácnosti a řídit jednotlivé spotřebiče skrze uživatelské rozhraní daného systému. V této části budou popsány vybrané systémy pro chytré domácnosti.

#### Siemens Connected Home

Siemens Connected Home je systém chytré domácnosti umožňující propojení a automatizaci chytrých výrobků od společnosti Siemens. Tyto jednotky spolu komunikují pomocí technologie ZigBee, díky které lze do systému zapojit až 40 těchto zařízení. Přístup do systému chytré domácnosti je možný skrze mobilní aplikace pro Android a iOS. Nevýhodou tohoto systému je fakt, že podporuje pouze zařízení od společnosti Siemens, mezi která

patří zařízení pro ovládání HVAC systému jako jsou chytré termostatické hlavice a ventily pro systém vytápění, měřiče průtoku a chytré termostaty. Z pohledu automatizace mohou uživatelé vytvářet vlastní scénáře, kdy například při povelu „Dobrou noc“ systém zhasne všechna světla v domě. Při optimálním nastavení scénářů výrobce láká až na třicetiprocentní úsporu za energie [35]. Pokud by se zákazníci nespokojili s omezenými vlastnostmi Siemens Connected Home, mají možnost využít integrace do systému Home Assistant<sup>1</sup>, díky čemuž mohou ovládání zařízení Siemens koordinovat s ostatními zařízeními v domácnosti.

## ABB-free@home

Společnost ABB nabízí v rámci svého systému pro chytrou domácnost mnoho chytrých zařízení, které je možné integrovat pro snadnější a efektivnější chod domácností. Uživatelé si mohou zvolit z chytrého osvětlení a stmívání, automatických žaluzií a markýz, HVAC systémů, bezpečnostních prvků jako detektorů kouře či inteligentních zvonků pro dveřní komunikaci. Nad těmito zařízeními lze postavit jednotlivé automatizace pro automatické spínání světel, HVAC, polohu žaluzií, či zabezpečení domácnosti.

Jednotlivá zařízení spolu mohou komunikovat jak po společné sběrnici viz obrázek 3.1, tak i bezdrátově s využitím WLAN nebo ZigBee, kdy do takového systému lze začlenit až 150 zařízení. V systému chytrého domu ABB-free@home lze nicméně využít pouze zařízení od společnosti ABB a není tak možné využít řešení třetích stran, což může na jednu stranu zajistit stabilitu, na druhou však nevýhodu toho, že v případě ukončení podpory je nutné pořídit celý nový systém.

Využití strojového učení pro úsporu energie v domácnosti zatím není podporováno a ani uživatel nemá možnost k tomu využít své vlastní řešení. Úspory však lze dosáhnout manuálním nastavením scénářů pro optimalizaci časů spouštění HVAC a dalších spotřebičů [1].

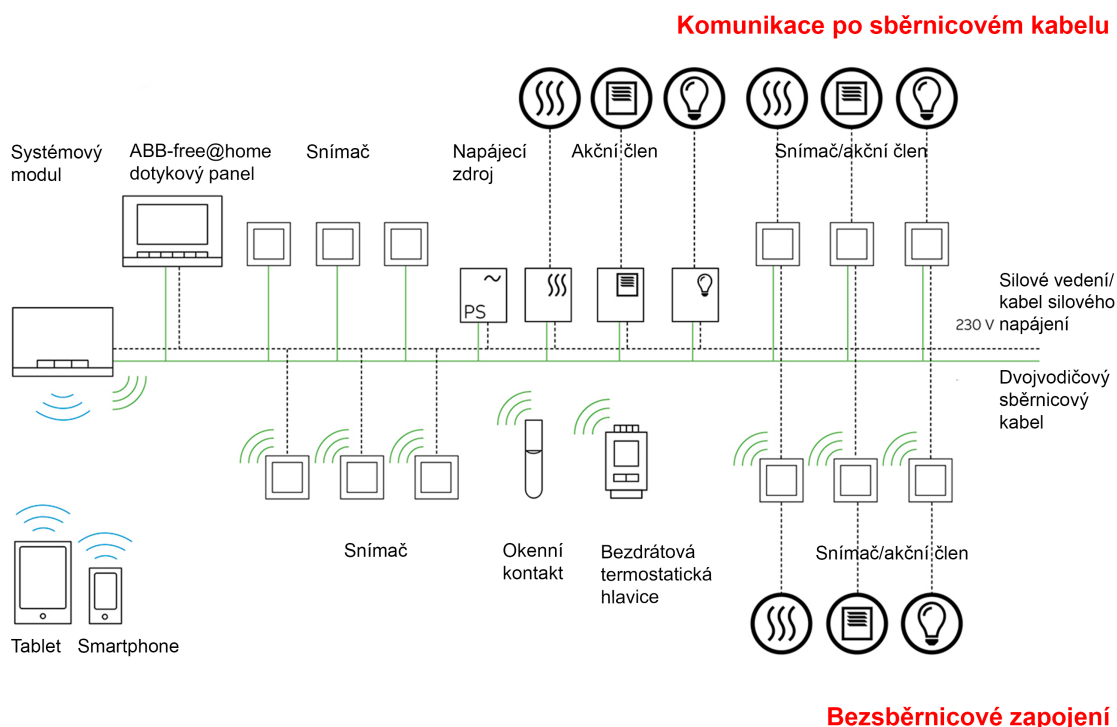
## Creston

Dalším systémem využívaným pro systém chytré domácnosti je řešení od americké společnosti Creston. Ta se zabývá automatizací více než padesát let a kromě inteligentních domů nabízí řízení větších budov jako jsou mrakodrapy nebo vládní budovy. Stejně jako v systémech od ABB či Siemens se jedná o uzavřený systém, pro který lze využít zařízení jako je osvětlení, ovládání rolet a závěsů, termostaty, závlaha, zabezpečení domu a další. Oproti předchozím dvěma zmíněným řešením nabízí Creston o mnoho více zařízení, které lze pomocí tohoto systému ovládat. Samozřejmostí v tomto případě je mobilní aplikace pro snadný přístup k systému a jeho ovládání, stejně jako vytváření scénářů pro domácí automatizaci pro snížení výdajů za energie, avšak jakákoliv další uzpůsobení chodu domácnosti možná nejsou.

## Homey

Další z řešení je systém Homey, který je možné pořídit ve verzi Homey či Homey Pro viz obrázek 3.2. Počáteční investice v případě Homey činí 100 dolarů a následně 2,99 dolarů každý měsíc, zatímco Homey Pro je možné pořídit za jednorázový poplatek 399 dolarů. Díky systému Homey, který je možné chápat jako hub pro integraci ostatních platform jako je Philips Hue, Spotify, Aqara nebo IKEA Trådfri, lze sjednotit správu všech chytrých zařízení v domácnosti. Uživatelé mohou svoji chytrou domácnost ovládat pomocí aplikace

<sup>1</sup>[https://www.home-assistant.io/integrations/home\\_connect/](https://www.home-assistant.io/integrations/home_connect/)



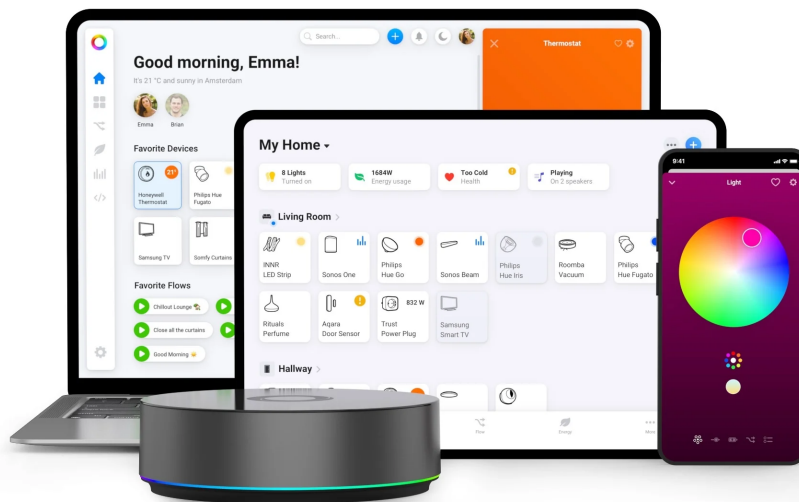
Obrázek 3.1: Příklad instalace a komunikace jednotlivých prvků řešení ABB-free@home. Převzato z [1].

v chytrém telefonu či tabletu, pomocí přednastavených scénářů či dokonce svými vlastními složitějšími skriptami psanými v JavaScriptu pro sofistikovanější kontrolu nad domácností. Homey tak nabízí univerzální a stabilní systém pro řízení chytré domácnosti, kdy uživatelé nejsou odkázáni jen na jednoho výrobce chytrých zařízení a mohou si tak vybírat napříč velkým množstvím integrací, jejichž počet se neustále rozrůstá [19].

## Home Assistant

Posledním z rozebíraných systémů chytré domácnosti je Home Assistant. Jedná se o software pro domácí automatizaci s otevřeným zdrojovým kódem, který je navržen tak, aby mohl být použit jako centrální řídicí systém pro chytrá zařízení v chytré domácnosti. Jeho vývoj byl započat v roce 2013 a v roce 2017 byl představen operační systém z názvem Home Assistant OS (dříve Hass.io), který umožňuje snadnější použití na jednodeskových počítačích typu Raspberry Pi<sup>2</sup>.

<sup>2</sup>Raspberry Pi je cenově dostupný jednodeskový počítač, který obsahuje procesor, paměť RAM, rozhraní pro periferie jako USB, HDMI, Ethernet, a GPIO piny pro připojení elektroniky. Je využíván pro různé projekty v oblasti elektroniky, robotiky, domácí automatizace a vývoje software. Je malý, energeticky úsporný a flexibilní, což ho činí populárním vývojovým nástrojem. Oficiální stránky výrobce: [www.raspberrypi.org](http://www.raspberrypi.org)



Obrázek 3.2: Systém Homey Pro s ukázkou uživatelského prostředí aplikace. Převzato z [19].


### Instalace a provoz systému Home Assistant

Home Assistant lze provozovat v několika formách instalací. První možností je využití Home Assistant OS, který může běžet na připravených řešení přímo od společnosti Home Assistant jako je například produkt Green, který již z výroby obsahuje tento operační systém. Další možností je využití instalace Home Assistant OS na vlastní jednodeskový počítač Raspberry Pi, který lze rozšířit díky produktu Home Assistant Yellow, který přináší slot pro paměť M.2 nebo modul Zigbee viz obrázek 3.3.

Uživatelé se ovšem nemusí omezovat jen na produkty od společnosti Home Assistant či Raspberry, ale mohou rovněž využít zařízení jako je Odroid<sup>3</sup> nebo zařízení jako počítače a servery založené na architektuře procesorů x86-64. Druhou možností instalace je využití Home Assistant Supervised. Tato varianta umožňuje použití dodatečných doplňků a rozšíření, ale vyžaduje složitější správu a konfiguraci.

Dalším přístupem může být využití kontejnerizace, kdy je instance systému Home Assistant spuštěna v rámci kontejneru služby Docker. Tato verze poskytuje izolované prostředí pro běh, což usnadňuje jeho správu a nasazení, avšak neposkytuje možnost oficiálních do-

<sup>3</sup>Odroid je série výkonných jednodeskových počítačů podobných Raspberry Pi, vyráběných společností Hardkernel. Nabízí rozšířené možnosti rozšíření a jsou vhodné pro náročnější projekty, jako jsou multimediální centra nebo serverové aplikace. Oficiální stránky výrobce: <https://www.hardkernel.com/>



Obrázek 3.3: Základní deska zařízení Home Assistant Yellow. Převzato z [18].

plňků či režimu Supervisor pro centrální správu aplikací a doplňků spuštěných v rámci Home Assistant.

Poslední verze - Home Assistant Core - umožňuje chod tohoto systému s využitím Python virtuálního prostředí. Tato základní verze poskytuje jádro systému Home Assistant bez dalších nadstaveb nebo správce doplňků. Je vhodná pro uživatele, kteří se spokojí pouze se základní funkcionalitou.

### **Integrace služeb třetích stran**

Home Assistant nabízí v rámci všech druhů instalací možnost integrace služeb třetích stran. To umožňuje tento systém propojit a komunikovat s různými zařízeními, službami nebo platformami, díky čemuž lze získávat data o zařízeních nebo ovládat jejich funkce. Jako příklad lze uvést integrace pro chytrá světla, termostaty, kamery, senzory, chytré asistenty jako Amazon Alexa nebo Google Assistant. Každá integrace pak slouží jako most mezi systémem Home Assistant a zařízením či službou, které podporuje. Jakmile je integrace nastavena a nakonfigurována, umožňuje monitorovat, ovládat a automatizovat zařízení či služby propojené touto integrací. To může zahrnovat zobrazení stavu zařízení, sběr dat ze senzorů, spouštění akcí nebo tvorbu automatizací na základě událostí z těchto zařízení či služeb. Integrace jsou základním prvkem systému Home Assistant, který umožňuje propojení a správu širokého spektra chytrých domácích zařízení a služeb, vytvářející jednotný a centralizovaný systém pro uživatele.

## Doplňky pro Home Assistant

Doplňky jsou jednotlivé softwarové balíčky nebo aplikace, které rozšiřují funkcionalitu samotného systému Home Assistant. Tyto doplňky jsou vytvořeny tak, aby byly snadno integrovatelné a poskytovaly uživatelům rozmanité možnosti. Může se jednat o databáze, firewally, proxy servery nebo nástroje pro zálohování. Každý doplněk je obvykle distribuován jako kontejnerizovaná aplikace, což znamená, že je zapouzdřený do kontejneru s vlastními závislostmi a konfigurací, oddělený od ostatních aplikací nebo služeb. Home Assistant Supervisor, který spravuje doplňky a běh Home Assistant, následně zajišťuje jednotné uživatelské rozhraní pro správu všech nainstalovaných doplňků a jejich běh v kontejnerech.

Doplňky mohou přidávat nové funkce, které nejsou součástí základní instalace Home Assistant. To může zahrnovat nové služby pro integraci s různými platformami chytrých zařízení, zabezpečení, monitorování a další. Tyto doplňky jsou poskytovány v rámci komponentu Supervisor, který spravuje instalaci a běh Home Assistant. Umožňují uživatelům rychle a snadno přidávat a spravovat různé aplikace a funkce, které rozšiřují možnosti a využití Home Assistant. Ke správě jednotlivých doplňků slouží jednoduché uživatelské rozhraní, které kromě nastavení umožňuje také sledovat aktuální stav doplňku viz obrázek 3.4.

Platforma Home Assistant nabízí jejím uživatelům také možnost vytvoření vlastního doplňku. K tomu jim pomůže již vytvořená šablona doplňku s veškerým potřebným nastavením. Uživatelé si tak mohou vytvořit libovolnou aplikaci a nemusí se spoléhat pouze na vytváření scénářů či jeden konkrétní programovací jazyk pro tvorbu skriptů.

**InfluxDB** ●  
Current version: 4.8.0 ([Seznam změn](#))

[Hodnocení](#) [Ověření](#) [Ingress](#) [Podepsáno](#)

Scalable datastore for metrics, events, and real-time analytics.  
Další podrobnosti naleznete na stránce [InfluxDB](#)

**InfluxDB**

**Spustit při spuštění**  
Spustit doplněk při spuštění systému

**Hlídací pes**  
Toto spustí doplněk, pokud dojde k jeho selhání

**Automatická aktualizace**  
Automaticky aktualizovat doplněk, pokud je k dispozici nová verze

**Zobrazit v postranním panelu**  
Přidejte si tento doplněk na svůj postranní panel

**Název hostitele**  
a0d7b954-influxdb

**Využití procesoru doplňkem**  
0.1 %

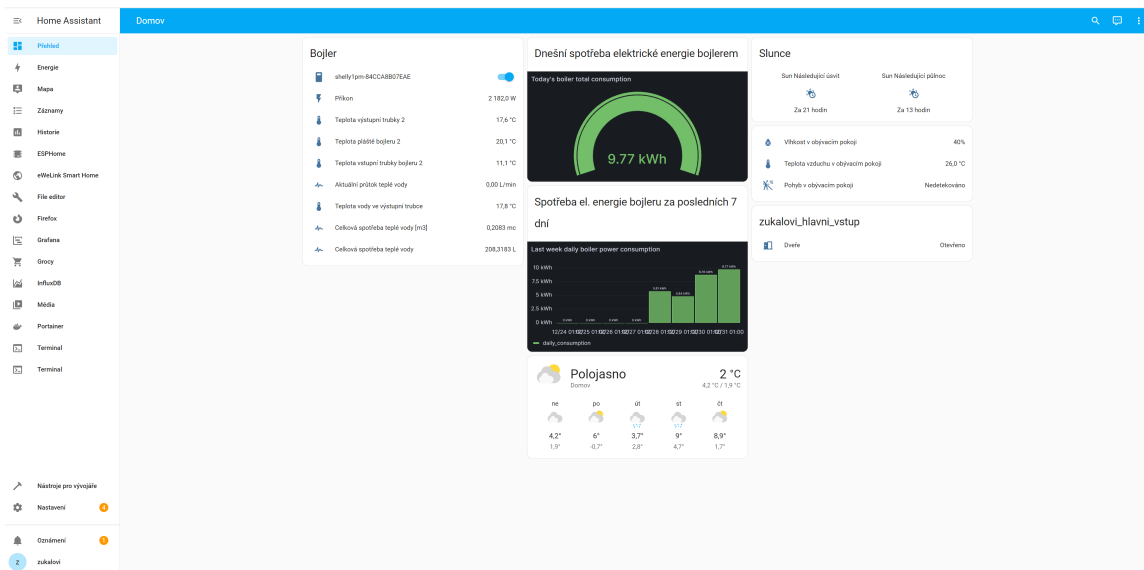
**Využití paměti RAM doplňkem**  
8.8 %

Obrázek 3.4: Snímek obrazovky z uživatelského rozhraní systému Home Assistant s informacemi o stavu doplňku databáze InfluxDB.

## Uživatelské rozhraní

Uživatelé mají možnost využít ke sledování a správě systému chytré domácnosti webovou aplikaci viz obrázek 3.5, která poskytuje možnost kontroly nad celým systémem. Dále pak lze využít mobilní aplikace Home Assistant jak pro iOS tak i pro Android. Další možností správy je využití hlasových asistentů jako je Amazon Alexa, Google Assistant nebo Apple HomeKit pro získávání informací o stavu domácnosti, spouštění scénářů nebo ovládání

jednotlivých zařízení. K přístupu k Home Assistantovi mimo lokální síť lze využít několika cest, kdy nejjednodušší je využití předplatného cloudu Nabu Casa, který stojí 7 dolarů měsíčně nebo 70 dolarů za rok. To zaručuje zákazníkům bezpečné připojení k jejich instanci systému Home Assistant.



Obrázek 3.5: Snímek obrazovky z úvodního uživatelského rozhraní systému Home Assistant.

Systém Home Assistant tak může být univerzálním a dlouhodobým řešením pro chytré domácnosti díky výše zmíněným vlastnostem jako je cenová dostupnost, velké množství podporovaných zařízení a integrací, různé formy instalace podle potřeb uživatelů, nebo možnost vytváření vlastních doplňků v podobě kontejnerových aplikací. Velká komunita vývojářů a uživatelů slibuje dlouhodobou podporu a údržbu systému jako takového [18].

## 3.2 Chytré osvětlení

Při snaze o dosažení úspory energií při svícení uživatelé nejdříve postupují tak, že sníží energetickou náročnost osvětlení v domě výměnou starších neúsporných žárovek za novější úsporné, které dokáží ušetřit až 85 % nákladů za energie viz tabulka 3.1.

Tabulka 3.1: Srovnání úspor jednotlivých druhů žárovek. Převzato z [13]

Typ svítidla	Cena [Kč]	Životnost [h]	Spotřeba [W]
Tradiční wolframová žárovka	15	1 000	60
Halogenová žárovka	85	2 000	40
LED žárovka	99	15 000	9

Po výměně neúsporného osvětlení za úsporné lze cílit snahu na to, aby světla svítala pouze tehdy, kdy jejich svitu může někdo využít. K tomu kromě vypínačů lze využít pohybových nebo světelných čidel, které po zaznamenání pohybu či změně světelných podmínek rozsvítí vybrané osvětlení. Pokud bychom chtěli ovládat světla i jinak než vypínači, pohybovými či světelnými senzory, lze využít výhod začlenění osvětlení do systému chytré domácnosti. V případě instalace chytrého osvětlení lze volit z několika forem přístupů.

Prvním z nich je využití chytrých zásuvek či relé, které lze použít ke spínání jednotlivých zařízení nebo světelných okruhů, ke kterým jsou připojena světla. Druhou možností je využití přímo chytrých světel a žárovek bez nutnosti zasahování do elektroinstalace domu jako je například řešení Hue od společnosti Philips či chytré žárovky Sonoff.

Při začlenění chytrých svítidel do některého ze systému chytrých domácností lze dosáhnout energetické úspory nastavením scénářů, které zajistí například to, že v případě nepřítomnosti žádné osoby v domácnosti budou všechna světla vypnuta, případně během dne, kdy není potřeba mít některá světla zapnuta, bude zajištěno jejich vypnutí.

### 3.3 Chytré vytápění

Vytápění tvoří v českých domácnostech v průměru dvě třetiny všech výdajů za energii [49]. Je tak zřejmé, že i malé procentuální snížení nákladů na vytápění může přinést významný finanční efekt. K vytápění stejně jako jeho regulaci se v domácnostech využívá několika přístupů. V následujících odstavcích proto budou jednotlivé přístupy podrobněji rozebrány spolu s možnostmi úspory vlivem chytrého vytápění s využitím strojového učení.

#### Kotle na tuhá paliva

Prvním ze způsobů vytápění je využití kotle na tuhá paliva jako je dřevo, uhlí, nebo pelety. Spalování těchto paliv generuje teplo, které ohřívá vodu v teplovodním systému, který zajišťuje vytápění prostor domácnosti. Regulovat teplotu v jednotlivých místnostech lze pomocí termostatických hlavic umístěných na radiátorech, které omezují průtok teplé vody daným radiátorem. Spalování může být regulováno množstvím dodávaného vzduchu, čímž lze zrychlit nebo zpomalit proces spalování podle potřeby. Do kotlů je však zapotřebí dodávat nové palivo ke spálení, kdy tento proces není ve většině domácnostech automatizován a děje se tak převážně manuálně. Výjimkou bývají kotle na pelety, které mohou mít automatizovaný systém příkládání. Integrací senzorů a chytrých termostatů lze dosáhnout lepší regulace spalování a vytápění, nicméně lze narazit na několik problémů jako je nemožnost regulace daného kotle, dlouhá odezva na regulaci, jelikož v systémech na tuhá paliva trvá déle, než se palivo rozhoří nebo vychladne, což může znamenat, že systém nebude schopen rychle reagovat na změny teploty v místnosti. V neposlední řadě pak zmíněná potřeba manuálního zásahu při příkládání nového paliva. V moderních instalacích takovýchto kotlů se využívá ohřevu vody v akumulacích nádržích. Využití akumulacích nádrží umožňuje spálení veškerého naloženého paliva při maximální účinnosti spalování. Odpadá tak nutnost příkládat přes noc, neboť dodané teplo se následně z akumulacích nádrží čerpá libovolně podle potřeb uživatelů.

#### Plynové kotle

V případě kotlů na plyn je princip ohřívání vody v teplovodním systému identický jako v předchozím případě. Účinnost těchto řešení se pohybuje v rozmezí 80–90 %. Výhodu však mají tyto systémy v tom, že se dají snadněji regulovat, bez zásahu člověka. Tyto kotle tak pracují zcela automaticky podle informací z termostatů. Jsou proto vhodné při využití termostatů v systémech chytré domácnosti, kdy na základě nastavené teploty v termostatu ohřívají vodu v soustavě či nikoliv.

## Elektrické vytápění

Elektrické vytápění lze rozdělit do několika skupin. Tou první je použití elektrického kotle, který stejně jako v předchozích případech ohřívá vodu v teplovodní soustavě. Druhou možností jsou radiátory s elektrickým topným tělesem, různé infračervené topné panely nebo přímotopy. Další možností je elektrické odporové topení, které lze umístit do podlahy, na stěny nebo i na strop. Regulace u těchto druhů elektrického vytápění je poměrně snadná a optimálního tepelného komfortu lze dosáhnout použitím termostatů či plynulou regulací.

## Tepelná čerpadla

V poslední době se v domácnostech stále více využívají k vytápění tepelná čerpadla. Těch existuje mnoho druhů podle způsobu získávání a odevzdávání tepla. Pokaždé však jde o to, že tepelné čerpadlo s využitím principu tepelného transferu přesune teplo z jednoho místa na druhé, zpravidla ze zdroje s nižší teplotou do místa s vyšší teplotou. To se děje pomocí kompresního cyklu, kde chladicí médium absorbuje teplo z venkovního zdroje (vzduchu, vody nebo země), je stlačeno, což zvyšuje jeho teplotu, a poté je toto teplo přeneseno do vytápěného prostoru pomocí tepelného výměníku, kdy je ohřívána buď voda nebo přímo vzduch. Tento proces dosahuje vysoké účinnosti, kdy je čerpadlo schopné vyrobit až pětinásobek dodané energie. Chod tepelného čerpadla pro vytápění je regulován za pomoci termostatů, které lze pohodlně integrovat do systému chytré domácnosti a následně automaticky řídit vytápění.

## Termostaty s chytrými funkcemi

Tradiční termostaty lze v současné době nahradit termostaty chytrými, které nabízejí sofistikovanější a energeticky efektivnější řešení vytápění. Tato část se proto zaměří na termostaty s chytrými funkcemi, které vedou ke snížení výdajů za energii při zachování či zvýšení tepelného komfortu uživatelů.

### Amazon Smart Thermostat

Tento chytrý termostat postavený na technologii Honeywell Home poskytuje funkce chytrého ohřevu na základě chování uživatelů s využitím geofencingu<sup>4</sup>. K ovládní termostatu slouží kromě manuálního ovládní přímo na termostatu také mobilní aplikace Alexa. Bohužel však kvůli nemožnosti propojení s více čidly neposkytuje zónové řízení vytápění v jednotlivých místnostech. To lze díky nízké ceně, která činí v přepočtu 1000 Kč, obejít instalací více takových termostatů v rámci jedné domácnosti, nicméně v tomto případě bude chytré vytápění fungovat pouze u jednoho. Zbylé pak lze řídit pouze na základě rozvrhů vytápění pro jednotlivé zóny [3].

### Ecobee Smart Thermostat Premium

Je vybaven funkcí detekce přítomnosti pro automatické nastavení teploty a kompatibilní s různými typy vytápění a chlazení. Uživatelům také poskytuje funkce kontroly kvality vzduchu. Lze jej ovládat hlasem díky vestavěnému hlasovému asistentovi Alexa. Rovněž jej umožňuje využít i v ostatních systémech pro chytrou domácnost jako je Home Assistant,

<sup>4</sup>Geofencing je technologie, která využívá geografické informace k vytváření virtuálních oblastí a spouštění akcí na základě vstupu nebo výstupu zařízení z těchto oblastí.

Google Assistant, Apple HomeKit nebo Samsung SmartThings, pro ovládání skrze mobilní aplikaci odkudkoliv. Výrobce udává roční úsporu z nákladu na vytápění a klimatizaci až 26 % [12]. Pořizovací cena tohoto termostatu na zahraničních e-shopech činí v přepočtu 7300 Kč.

### **Honeywell Home T10+ Smart Thermostat**

Tento termostat umožňuje sledování teploty, vlhkosti a kvality vzduchu v jednotlivých místnostech s využitím externích senzorů RedLINK. Integrovaná chytrá technologie se přizpůsobuje životnímu stylu uživatele na základě jeho výskytu v jednotlivých místnostech a umožňuje dálkové ovládání skrze mobilní aplikaci. Lze jej rovněž začlenit do služeb jako je Apple HomeKit, Samsung SmartThings, Google Assistant, Amazon Alexa nebo právě Home Assistant [20]. Výrobce na svých stránkách bohužel neuvádí potenciální úsporu díky chytrému ohřevu. Toto zařízení lze pořídit v přepočtu za 4500 Kč.

### **Johnson Controls GLAS Smart Thermostat**

Tento termostat vyniká moderním designem s dotykovým displejem. Podporuje hlasové ovládání pomocí integrovaného asistenta Amazon Alexa a nabízí sledování kvality ovzduší a chytré vytápění i klimatizaci. Kromě vytápění a klimatizace zvládá řídit také ventilátory, zvlhčovače nebo odvlhčovače. Sledováním přítomnosti dokáže optimalizovat řízení vytápění a klimatizace s cílem úspory za elektrickou energii, nicméně výrobce neudává o jaké procento úspor se jedná [9]. Tento chytrý termostat však v uživatelských recenzích dosahuje nevalného skóre, které snižuje poměrně vysoká cena, která činí v přepočtu 6800 Kč.

### **Nest Learning Thermostat**

Tento termostat od společnosti Google (viz obrázek 3.6) je známý svou schopností automaticky se učit z rutin uživatele a optimalizovat nastavení pro energetickou účinnost. Nabízí funkcionalitu Eco Mode pro energeticky efektivní provoz a umožňuje dálkové ovládání přes mobilní aplikaci. Samotný výrobce slibuje úsporu v případě vytápění od 10 do 12 % a v případě klimatizace až 15 % [16]. Tento termostat je integrovatelný s dalšími zařízeními v rámci ekosystému Google. Aktuální česká verze tohoto zařízení však nedisponuje možností ovládání klimatizace a lze ji pořídit za 6499 Kč.

### **Tado Smart Thermostat**

Termostat Tado se automaticky přizpůsobuje přítomnosti osob v domě pomocí geofencingu pro úsporu energie. Umožňuje dálkové ovládání teploty pomocí mobilní aplikace a může se integrovat se systémy chytrého vytápění a chlazení. Díky chytrému vytápění a klimatizaci výrobce udává úsporu až 28 %. Tento termostat je rovněž kompatibilní s Apple HomeKit, Google Assistant i Alexou od Amazonu. Dále pak lze využít integrace pro Home Assistant, která poskytuje uživateli informace o stavu termostatu a vytápění [37]. Základní sadu chytrého termostatu Tado lze pořídit za 5800 Kč.

## **3.4 Chytrý ohřev vody**

Ohřev vody bývá druhým největším konzumentem energií v domácnostech, kdy náklady na něj činí v průměru 16 % výdajů domácnosti za energie. Proto se i v oblasti ohřevu



Obrázek 3.6: Nest Learning Thermostat pro řízení chytrého vytápění. Převzato z [16].

teplé vody objevují řešení, která cílí na optimalizaci ohřevu teplé vody. V této části tak budou rozebrány způsoby ohřevu teplé vody, principy dosažení úspory chytrým ohřevem a porovnání existujících řešení.

### Způsoby ohřevu teplé vody

V domácnostech, které si ohřev vody zajišťují samy, můžeme narazit na dva typy ohřevu. První z nich využívá pro ohřev teplé vody stejný zdroj jako pro vytápění. Lze tak narazit na ohřev pomocí kotlů na tuhá paliva, na elektřinu či plyn, nebo na ohřev pomocí tepelných čerpadel. Druhou kategorií představuje ohřev v rámci samostatného zařízení, které není závislé na systému vytápění v domácnosti. K tomu se nejčastěji využívá elektrické energie, plynu, či jejich kombinace. Tento přístup lze následně dělit na ohřev akumulární a průtokový, kdy každý má své výhody i nevýhody.

Průtokové ohříváče nalézají uplatnění v místech, kde nedochází k odběru velkého množství teplé vody, nebo v případě nedostatku místa pro umístění akumulární nádrže. Výhodou může být také kratší doba potřebná k ohřátí vody a fakt, že nahřátá voda nechladne v zásobníku nebo v rozvodném systému. Nevýhodou je pak fakt, že v případě většího odběru nemusí průtokové ohříváče být pro domácnosti s více uživateli vhodné. Využití tak nalézají v rekreačních objektech kdy je snížený tepelný komfort akceptován nebo například jako zdroje teplé vody pro dřezy a umyvadla, kdy je malý objem teplé vody potřebný okamžitě.

Naopak akumulární forma ohřevu, kdy je voda nahřívána dopředu, je vhodná pro zásobování koupelen, kdy je očekáván větší odběr teplé vody. Nevýhodou akumulární formy ohřevu je fakt, že po nahřátí voda v nádrži vlivem rozdílu její teploty a teploty okolí ne-



tepelná ztráta v ohřivači o objemu 160 l při teplotě vody 65 °C a teplotě okolí 20 °C 1,33 kWh za den. Pro snížení tepelných ztrát lze využít dvou druhů přístupů. První z nich je pasivní, kdy zajistíme co nejlepší izolaci teplovodní soustavy včetně nádoby bojleru. K tomu lze využít přídavných pouzder, do kterých se bojler vloží. Toto řešení se však nabízí většinou pro bojler o objemu 300 l a více. Druhý přístup je aktivní, kdy je cíleně kontrolou teploty, na kterou se bojler nahřívá, zaručeno, že v časy, kdy je minimální odběr teplé vody z bojleru, je voda v bojleru udržována na co nejnižší teplotě. Naopak ve chvílích, kdy je očekáván odběr většího množství tepla z bojleru, je do bojleru s předstihem dodáno teplo tak, aby uživatel nepocítil teplotní diskomfort. Pokud bychom snížili denní průměrnou teplotu v bojleru o 20 °C, denní ztráta by klesla na 0,74 kWh za den, což by při současné ceně za kilowatthodinu kolem 8 Kč znamenalo roční úsporu 1722,8 Kč.

Kromě optimálního ohřevu na základě režimu jeho uživatelů lze v rámci chytrého ohřevu využít funkcí jako je:

- režim „dovolená“, kdy v uživatelem nastaveném časovém období není voda v bojleru nahřívána vůbec,
- ochrana proti zamrznutí, kdy termostat hlídá, aby teplota vody neklesla pod 5 °C,
- antilegionella<sup>5</sup>, kdy bojler ohřevem vody nad 60 °C jednou za 2-3 týdny eliminuje výskyt této nebezpečné bakterie,
- detekce poruch, kdy bojler upozorní uživatele na únik vody či nízký výkon ohřevu
- plánování ohřevu, kdy si uživatelé mohou vyžádat určité množství teplé vody na konkrétní čas mimo jejich běžný denní rytmus.

Tyto funkce lze nalézt v mnoha současných řešeních, které jsou popsány v následující části.

## Existující řešení chytrého ohřevu vody

Pokud uživatelé touží po chytrém ohřevu, mají hned několik možností. První z nich je volba bojleru takového, který již z výroby obsahuje funkci chytrého ohřevu. Taková řešení pak pracují tak, že se z historických dat naučí režim jejich uživatelů a optimalizují nahříváním vody v časy před očekávanou spotřebou. Uživatelům je umožněno ovládat bojler skrze mobilní aplikaci výrobce pomocí Bluetooth či Wi-Fi. Díky tomu mohou na dálku bojler spínat nebo nastavovat časové úseky, kdy bojler nemá vodu ohřívát vůbec. Nevýhodou těchto řešení je to, že jejich integrace do dalších systémů chytré domácnosti je značně omezená, kdy lze například získat data pouze o aktuálním stavu, ale ovládání samotného ohřevu bez nutnosti využití aplikace je omezené či nemožné<sup>6</sup> a musí tak být provedeno přímo z aplikace výrobce ze zařízení umístěného v rámci domácí sítě.

Dalším možným řešením chytrého bojleru je proměna klasického bojleru na chytrý přidáním dodatečných čidel, spínačů ohřevu a logiky chytrého ohřevu. V současné době lze nalézt několik takových řešení.

---

<sup>5</sup>Zásobníkový ohřev může vést k rozmnožení bakterie Legionelly. Tato bakterie se množí v teplé vodě o teplotě 25–55 °C. V USA se ročně touto bakterií nakazí 600 tisíc lidí [28], kteří se potýkají s příznaky podobnými zápalu plic. Udržováním teploty vody nad 60 °C lze zabránit jejímu rozmnožování.

<sup>6</sup>Příklad integrace chytrého bojleru Dražice OKHE SMART do systému Home Assistant: <https://github.com/LubosD/esphome-smartboiler>

## iQtech SmartLife GCLW-B

Prvním z nich je produkt iQtech SmartLife GCLW-B<sup>7</sup>, díky kterému lze začlenit klasický bojler do systému chytré domácnosti SmartLife. Uživatelé si pak mohou pomocí aplikace nastavovat teplotu vody v bojleru nebo období, kdy nebudou doma a bojler tak není potřeba vytápět. Řešení však neposkytuje nahřívání podle denních režimů uživatelů, což by mohlo mít za následek zvýšení úspory a komfortu uživatelů.

## Aquanta

Takové služby nabízí společnost Aquanta, která na americkém trhu prodává jejich stejnojmenný produkt. Díky němu lze proměnit klasický elektrický nebo plynový bojler na chytrý pomocí přídavných teplotních čidel a řídicího zařízení viz obrázek 3.8. Toto zařízení se připojí k původnímu zdroji elektrické energie bojleru a umožňuje napájení bojleru přes zařízení Aquanta. Po připojení zařízení k lokální Wi-Fi síti umožňuje ovládání z jakéhokoli místa v domácnosti prostřednictvím aplikace, což zahrnuje možnost nastavovat ohřev vody nebo vytvářet časové plány pro jeho provoz. Zařízení se dokáže adaptovat na režimy domácnosti díky své schopnosti průběžného učení, což umožňuje optimalizaci ohřevu vody. Lze jej rovněž začlenit do systému chytré domácnosti Home Assistant pomocí neoficiálního rozšíření<sup>8</sup>, které jeho uživatelům umožňuje sledování aktuálního stavu bojleru a jeho vypnutí či zapnutí.

Zařízení Aquanta se na americkém trhu prodává za cenu přibližně čtyř tisíc korun, přičemž za příplatek 300 Kč je možné pořídit i senzor úniku vody, což je užitečná bezpečnostní funkcionality.

## Další řešení chytrého ohřevu

Kromě využití komerčních řešení lze klasický bojler přeměnit na chytrý i svépomocí. Pokud uživatelům stačí pohodlná integrace informací o sepnutí bojleru a teplotě vody uvnitř do systému chytré domácnosti, lze využít například chytrého relé Shelly 1PM s rozšířením pro teplotní čidla. To nabízí jednoduchou integraci pro systém Home Assistant, nad kterou pak lze již poměrně jednoduše vytvářet automatizace pro chod bojleru. Toto řešení však postrádá možnost učení návyků uživatelů a logiku spínání ohřevu si musí uživatel nastavovat manuálně. Řešením může být vytvoření algoritmu, který na základě historických dat dokáže predikovat spotřebu teplé vody pro optimální ohřev vody v bojleru. Takovou přeměnou klasického bojleru na chytrý jsem se zabýval v rámci mé bakalářské práce [17], kdy jsem pomocí chytrého relé Shelly 1PM a dvou teplotních čidel sestrojil zařízení, které ve spolupráci s InfluxDB databází a skriptem v jazyce Python implementovalo chytrý ohřev. Ten vycházel z dlouhodobého průměru teploty na výstupní trubce bojleru a z následného odhadu teploty, na kterou má být voda v bojleru před předpokládaným odběrem nahřívána. Tímto řešením se mi ve dvou testovaných instalacích podařilo dosáhnout úspory kolem 30 %. Chytrým ohřevem s využitím strojového učení se zabývá také práce [27], kdy s využitím dat z teplotních čidel a chytrého relé byla natrénována neuronová síť typu LSTM pro předpověď odběru teplé vody. Díky tomu došlo ve dvou testovaných domácnostech k dosažení úspory 20–24 %. V rámci mé diplomové práce se chci proto zaměřit na zdokonalení těchto systémů

<sup>7</sup>Odkaz na e-shop: <https://www.alza.cz/iqtech-smartlife-gclw-b-wifi-termostat-pro-bojlery-a-kotle-s-bezpotencialovym-spinanim-cerny-d5821746.htm>

<sup>8</sup>Veřejný GitHub repozitář neoficiální integrace zařízení Aquanta do systému Home Assistant: <https://github.com/bmcclore/ha-aquanta>



Obrázek 3.8: Zařízení Aquanta sloužící k předělání hloupého bojleru na chytrý. Převzato z [4].

rozšířením o více sledovaných veličin pro přesnější predikci odběru tepla z bojleru, zvýšení tepelného komfortu uživatelů a snížení nákladů.

### **Využití přebytků z fotovoltaiky pro optimální ohřev teplé vody**

Využití fotovoltaických elektráren (FVE) v kombinaci s ohřevem teplé vody představuje cestu k efektivnímu využití obnovitelné energie pro běžné domácnosti. Díky tomu lze vytvořit systém, který nejenže snižuje závislost na tradičním zdroji energie pro ohřev vody, ale také maximalizuje využití solární energie pro pokrytí tepelných potřeb domácnosti. Tato sekce se proto zaměří na strategie, výhody a optimalizaci využití FVE ve spojení s ohřevem teplé vody, přičemž se zaměří na nejefektivnější metody integrování solárních zdrojů do systému ohřevu vody pro dosažení ekonomických a ekologických výhod, současná řešení i návrh pro zlepšení.

Fotovoltaická elektrárna se realizuje v několika typech instalací. První z nich nese označení ostrovní, kdy je vyrobená elektřina spotřebována a případnými přebytky je nabíjena baterie, která slouží jako zdroj energie v okamžiku jejího nedostatku. Dalším druhem je FVE s připojením k síti, kdy se vzniklé přebytky prodávají do sítě. Třetí možností je kombinace předchozích dvou, kdy lze zvolit, jakým způsobem bude se vzniklými přebytky zacházeno.

Jelikož prodej přebytků zpět do sítě není moc výhodný (výkupní cena se pohybuje od 2 do 4,5 Kč za kWh), je snaha o jiné využití této energie. V okamžiku, kdy se přebytek nabíjí i záložní baterie, lze tuto energii využít k ohřátí vody v bojleru.

Na optimální využití přebytků z FVE se zaměřuje projekt EMHASS<sup>9</sup>, který lze nalézt jako doplněk pro Home Assistant. Ten na základě historických dat o spotřebované energii v domácnosti, predikce vyrobené elektřiny FVE, údajům o kapacitě baterií a nákupní a prodejní ceně elektřiny, dokáže vytvořit plán optimalizující využití energie pro chod energeticky náročných spotřebičů, nabíjení baterie a odprodej zpět do sítě. Uživatelé si mohou následně na základě tohoto plánu vytvořit automatizace v rámci systému Home Assistant, které řídí samotné spotřebiče.

---

<sup>9</sup><https://emhass.readthedocs.io/>

## Kapitola 4

# Návrh řešení pro úsporu energií v chytré domácnosti

Tato kapitola se věnuje návrhu řešení pro úsporu energie v chytré domácnosti, s popisem řídicích komponent a čidel spolu se softwarovou částí a architektury výsledného systému.

Výsledné řešení by mělo být aplikovatelné v domácnostech s akumulacním ohřevem vody pomocí bojleru, který lze snadno spínat chytrým relé či zásuvkou. Konstrukce bojleru by měla rovněž umožňovat přístup k nádrži s teplou vodou pro odečet aktuální teploty. Pro přesný odečet odebraného tepla plánuji instalaci průtokoměru na výstupní trubku bojleru. Dále předpokládám, že v domácnosti je k dispozici Wi-Fi síť pro komunikaci chytrých zařízení a alespoň někteří její členové disponují chytrým telefonem nebo osobním počítačem.

### 4.1 Řídicí komponenty a čidla

V této části se zaměřím na popis požadavků na řídicí jednotku, senzory a řídicí prvky, které poslouží pro sběr dat a řízení ohřevu vody v bojleru s cílem dosáhnout úspory energie při zachování komfortu obyvatel domácnosti.

#### Domácí server chytré domácnosti

Chod celého systému chytré domácnosti bude řízen centrálně z domácího serveru, na kterém bude spuštěna instance systému Home Assistant. Tento server by měl poskytovat dostatečný výkon nejen pro chod systému samotného, ale také pro zvládnutí trénování neuronové sítě, vytváření predikcí a řízení ohřevu. Navíc by měl disponovat dostatečně velkým uložištěm, které bude sloužit kromě chodu systému samotného také k ukládání velkého množství dat sesbíraných z chytrých čidel a systému chytré domácnosti. V neposlední řadě toto zařízení musí umožňovat připojení do místní internetové sítě, ideálně pak pomocí LAN pro stabilní připojení.

#### Sledování stavu domácnosti a řízení ohřevu

Pro sběr dat o stavu domácnosti budou v této části popsány veličiny, které bude zapotřebí sledovat. Dále také budou upřesněny požadavky na zařízení pro řízení elektrického bojleru.

## Teplota

Sledování teploty v domácnosti slouží ke dvěma účelům. Prvním z nich je odhad spotřeby na základě vývoje teploty na vstupní a výstupní trubce z bojleru spolu s množstvím odebrané vody. Druhým je pak řízení ohřevu, kdy se na základě teploty vody v bojleru rozhoduje, jestli je potřeba nahřívat či nikoliv. V rámci mé práce jsem se rozhodl sledovat teplotu na těchto místech:

- v plášti bojleru – pro odhad teploty vody v bojleru,
- na vstupní trubce – pro detekci spotřeby a její odhad,
- na výstupní trubce – pro detekci spotřeby a její odhad,
- v okolí bojleru – pro přepočítání naměřené teploty v plášti na teplotu vody v bojleru.

Data z těchto senzorů bude zapotřebí získávat v reálném čase pro ukládání do databáze a vyhodnocování aktuálního stavu při řízení ohřevu. Tyto senzory by proto měly být integrovány do systému chytré domácnosti Home Assistant pomocí integrace pro již existující zařízení, nebo pomocí některého z doplňků pro integraci vlastních čidel.

## Průtok vody na výstupu bojleru

Pro co nejpřesnější informace o spotřebě tepla z bojleru v podobě teplé vody jsem se rozhodl osadit výstupní trubku bojleru průtokoměrem. Díky tomu budu schopen přesně určit, jaké množství tepla bylo v který okamžik odebráno a následně přesněji predikovat, kolik tepla bude potřeba dodat, aby byl zachován tepelný komfort uživatelů domácnosti. Z řešení, která umožňují získávání dat pomocí vzdáleného přístupu, připadá do úvahy sestavení vlastního zařízení sestávajícího se z čidla monitorujícího průtok a mikrokontroléru, který bude zpracovávat informace z čidla a umožní integraci tohoto čidla do systému chytré domácnosti.

## Informace o počasí

Další sledovanou veličinou bude informace o aktuálním počasí. Konkrétně pak bude sledována venkovní teplota, vlhkost a rychlost větru. Kromě fyzických zařízení pro monitorování těchto veličin je možné využít také data z veřejného API poskytovatelů předpovědi počasí v dané oblasti.

## Výskyt osob v domácnosti

Pro predikci chování uživatelů chytré domácnosti může být důležitou veličinou informace o výskytu osob v domácnosti. K tomu lze použít například čidla pohybu, nebo přítomnosti, informace o přesné poloze uživatelů nebo informace o připojených zařízeních k místní Wi-Fi síti.

## Řízení ohřevu a sledování spotřeby energie

K řízení ohřevu a sledování spotřeby elektrické energie lze využít chytrých zásuvek nebo relé, které umí spínat vysokoodběrový spotřebič a zároveň monitorovat spotřebu elektrické energie. Toto zařízení by mělo umožňovat připojení k lokální Wi-Fi síti a ideálně i možnost začlenění do systému pro chytré domácnosti Home Assistant.

## 4.2 Softwarová část

Pro úspěšný chod algoritmu, který má za cíl snížení výdajů za energie pomocí strojového učení, je potřebné navrhnout algoritmus chytrého ohřevu v rámci architektury systému chytré domácnosti. Tato část se proto zaměřuje na softwarovou část návrhu řešení pro chytrý ohřev v domácnosti, které může být integrováno do prostředí Home Assistant. V první části budou popsány funkce, které bude chytrý ohřev poskytovat a následně budou navrženy jednotlivé části systému potřebné pro chytrý ohřev.

### Sběr dat

Pro možnost pohodlného sbírání dat z různých typů chytrých zařízení v rámci chytré domácnosti jsem se rozhodl využít platformy Home Assistant viz 3.1. Ta poskytuje řešení pro odečet veličin z čidel integrovaných do této platformy a jejich uložení do databáze. V rámci mého řešení plánuji využít databázi InfluxDB, jež je optimalizována pro ukládání časových řad, které v mém případě tvoří data ze senzorů v domácnosti. Z této databáze budou následně získávána data pro další zpracování a použití v algoritmu chytrého ohřevu.

### Funkce chytrého ohřevu

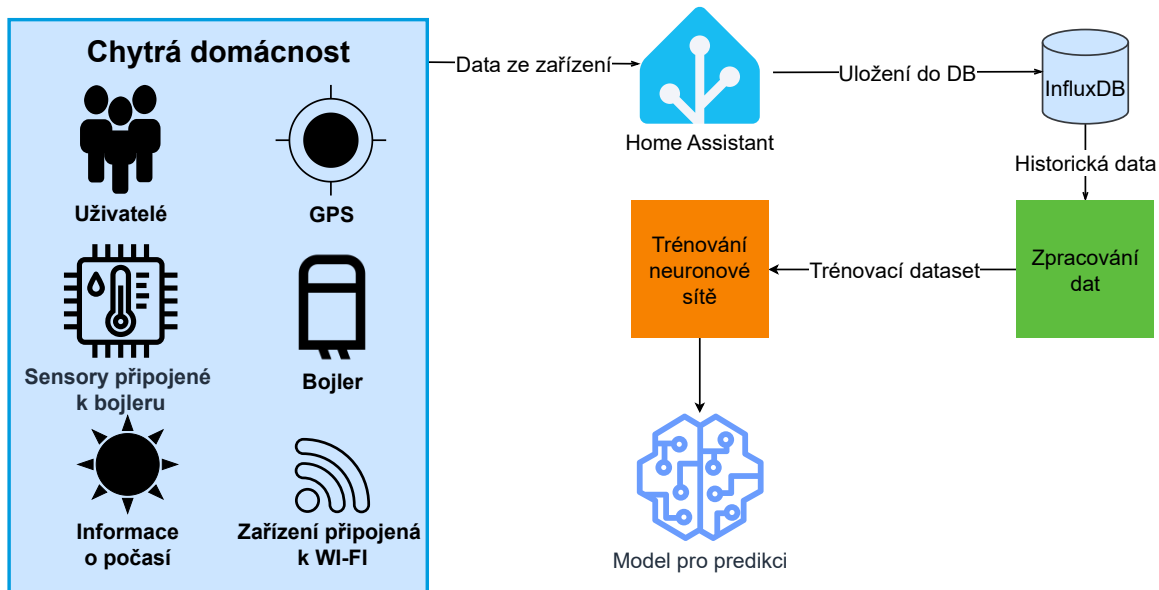
Chytrý ohřev v rámci mého řešení si klade za cíl poskytnout jeho uživatelům řešení, které jim sníží výdaje spojené s ohřevem teplé vody. Kromě toho bude poskytovat další rozšíření, které zaručí ochranu zdraví jeho uživatelů i teplovodní soustavy díky funkcím antilegionella či ochraně proti zamrznutí. Chytrý ohřev by měl fungovat naprosto autonomně s minimální potřebou interakce s uživatelem. V následujících řádcích proto navrhnu funkce, kterými bude výsledné řešení disponovat.

### Optimalizace ohřevu teplé vody

Z nasbíraných dat uložených v databázi InfluxDB bude po jejich zpracování natrénován model, který bude schopný predikce spotřeby tepla v čase na základě historických dat. K tomu bude využito modelu neuronové sítě s LSTM vrstvou viz 2.1, který bude postupně predikovat množství odebraného tepla za hodinu. Díky této predikci bude vytvořena předpověď očekávané spotřeby na následujících šest hodin, kterou se bude řídit navržený algoritmus pro chytrý ohřev. Model bude předtrénovaný na datech sledovaných domácností a následně dotrénován na konkrétní instalaci. Tím bude zaručeno to, že pro nové instalace bude stačit nasbírat poměrně malé množství dat v řádu jednotek týdnů, na kterém se připravený model pro konkrétní domácnost dotrénuje. Proces sběru dat a trénování modelu pro predikci spotřeby lze vidět na obrázku 4.1.

Díky predikci spotřeby bude docházet k nahřátí vody v bojleru na vyšší než pohotovostní teplotu 40 °C až těsně před očekávanou spotřebou. Do bojleru tak bude dodáno právě tolik tepla, kolik bylo predikováno, že bude v daný čas odebráno. Po odběru se tak teplota vody opět ustálí na pohotovostní teplotě. Díky udržování teploty vody v bojleru na co nejnižší hodnotě pak bude dosaženo úspory, neboť díky nižší teplotě bude chladnout pomaleji.

V rámci algoritmu bude rovněž počítáno s domácnostmi disponujícími fotovoltaickou elektrárnou. Zde se totiž naskytuje možnost využití akumulace přebytků energie ohřevem vody v bojleru, namísto prodávání do distribuční sítě.



Obrázek 4.1: Proces sběru dat a trénování modelu pro predikci spotřeby teplé vody.

### Režim dovolená

Ohřev vody v bojleru bude možné pozastavit na delší časové období díky funkci dovolená. To zaručí, že voda v bojleru nebude udržována na pohotovostní teplotě. Díky tomu nebude voda zbytečně nahřívána a budou minimalizovány teplotní ztráty. Toto období bude rovněž vyznačeno při trénování modelu pro predikci spotřeby teplé vody.

### Antilegionella

V případě chytrého ohřevu, kdy se teplota vody v bojleru pohybuje dlouhodobě v rozmezí 25–55 °C, hrozí zvýšený výskyt bakterie Legionella, která může způsobovat vážné onemocnění. Z tohoto důvodu v rámci výsledného řešení implementuji mechanismus, díky kterému bude zajištěno, že minimálně jednou za tři týdny dojde k nahřátí vody v bojleru nad 60 °C, čímž budou zlikvidovány potenciálně přítomné bakterie Legionelly.

### Ochrana proti zamrznutí

V případě, kdy je ohřev vody v bojleru pozastaven například z důvodu režimu dovolená, může v zimních měsících klesnout teplota vody v bojleru umístěném v nevytápěných prostorech pod bod mrazu. To by mohlo způsobit nenávratné poškození bojleru a vážné škody na majetku v podobě vytopení objektu unikající vodou. K zamezení takových případů bude algoritmus udržovat teplotu vody v bojleru nad hranicí 5 °C.

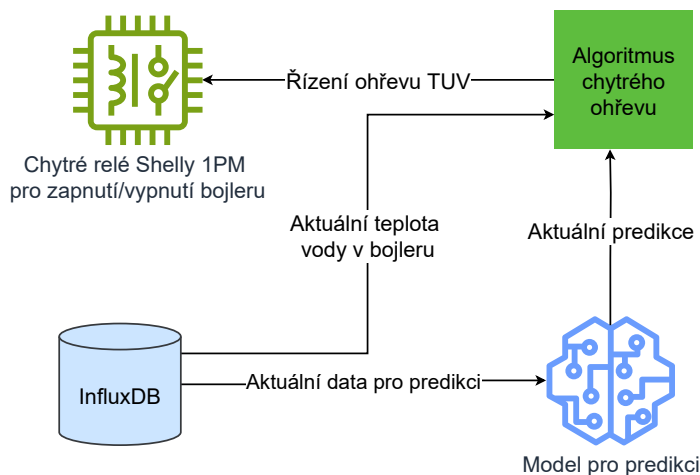
### Detekce vysokého tarifu

Některé domácnosti využívají výhod vysokého a nízkého tarifu elektřiny pro jejich chod. Během nízkého tarifu je elektřina pro domácnost levnější, čehož je využíváno v domácnostech s elektrickým bojlerem, topením nebo tepelným čerpadlem, jejichž běh může být upřednostňován během nízkého tarifu. Funkce detekce vysokého tarifu může v případě chytrého ohřevu uzpůsobit ohřev vody tak, aby začal nahřívát s dostatečným předstihem, pokud

předpokládá, že by kvůli vysokému tarifu nestihl vodu nahřát do doby očekávané spotřeby. Chytrý ohřev by mohl informace o dobách nízkého tarifu získávat na základě stavu chytrého relé připojeného do obvodu spínaném nízkým tarifem, manuálním zadáváním časů od uživatelů, případně s využitím speciální komponenty<sup>1</sup> pro Home Assistant.

### 4.3 Algoritmus chytrého ohřevu TUV

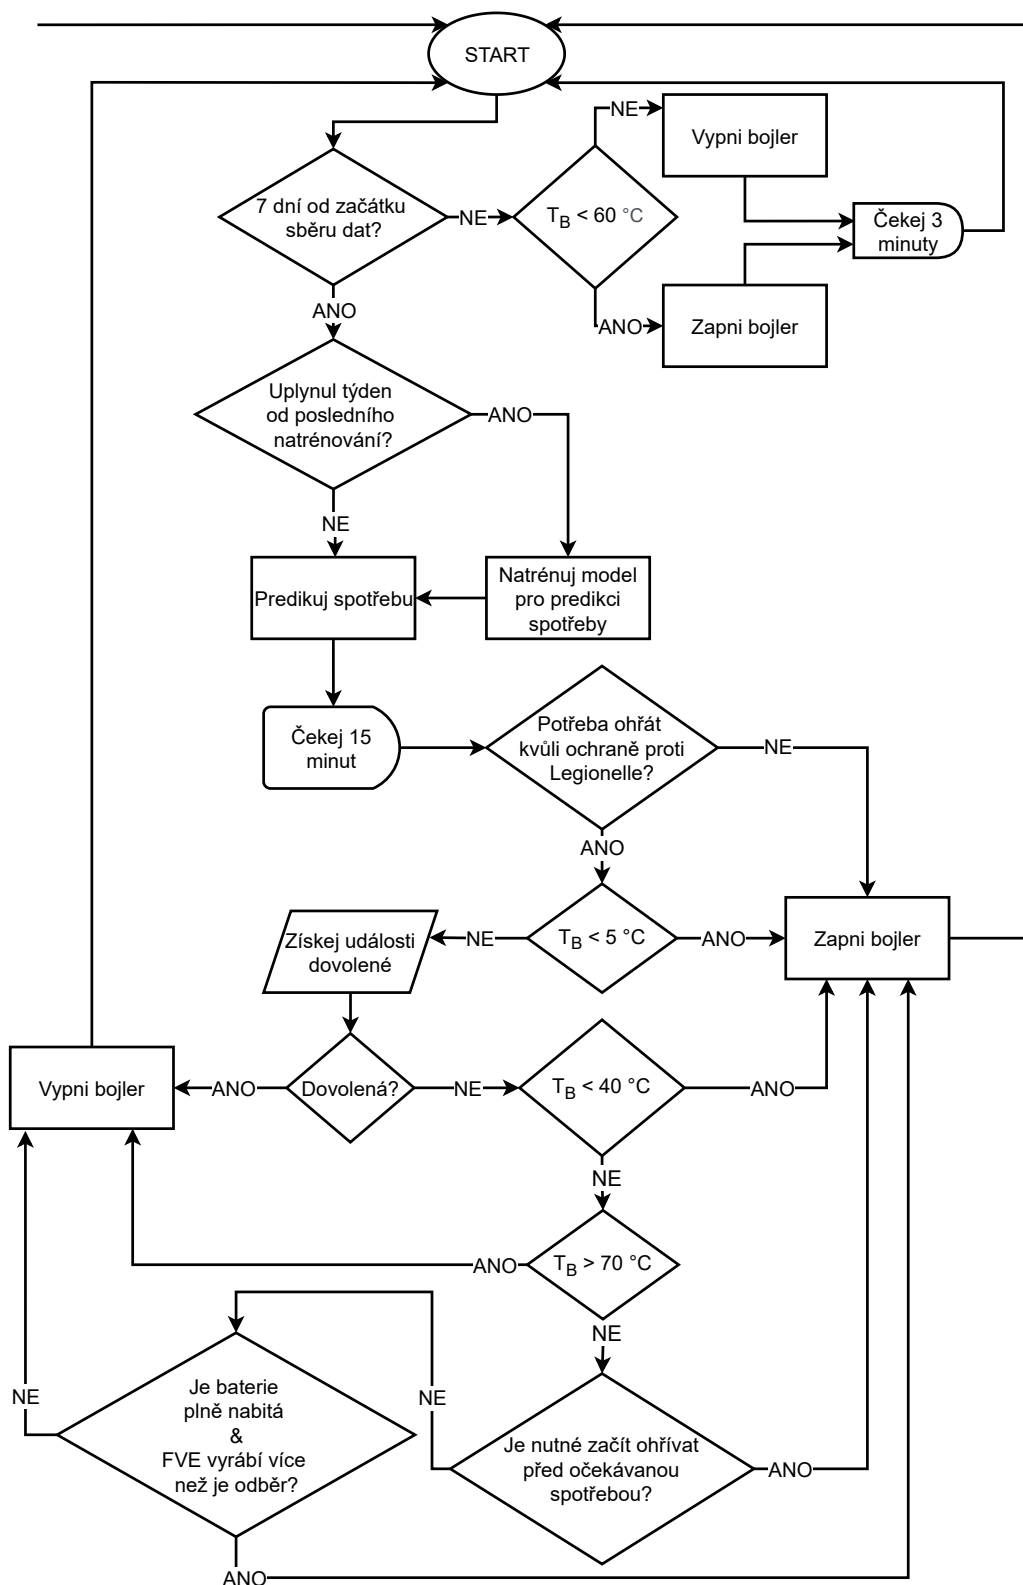
Na základě navržených funkcí chytrého ohřevu jsem navrhl algoritmus pro řízení ohřevu TUV. Algoritmus chytrého ohřevu TUV bere v potaz předpověď odběru teplé vody, přebytečnou energii ze solárních panelů, režim dovolených, či ochranné funkce proti zamrznutí a šíření bakterie Legionelly. Algoritmus využívá predikce spotřeby teplé vody vytvořené modelem, který byl natrénován na základě historických dat o chodu domácnosti. Díky tomu bude každých 15 minut vytvářen nový plán chytrého ohřevu na základě aktuálních informací jako jsou informace o počasí či poloha uživatelů. Navíc každý týden bude model dotrénován aktualizovanou datovou sadou s nejnovějšími nasbíranými hodnotami, čímž dokáže reagovat na změny v chování jeho uživatelů. Proces řízení ohřevu na základě predikce spotřeby lze vidět na obrázku 4.2.



Obrázek 4.2: Proces řízení ohřevu vody v bojleru pomocí chytrého relé na základě predikce spotřeby.

Tento algoritmus bude implementován v rámci doplňku pro systém Home Assistant v jazyce Python. Tento doplněk bude zajišťovat extrakci dat z databáze, jejich zpracování, natrénování modelu pro predikci spotřeby teplé vody z bojleru, a vytvoření aktuální predikce, která bude použita pro rozhodování v rámci algoritmu, který lze vidět na obrázku 4.3.

<sup>1</sup>GitHub repozitář komponenty pro získání dob nízkého tarifu: <https://github.com/Antrac1t/HomeAssistant-EGDdistribuce>



Obrázek 4.3: Diagram algoritmu chytrého ohřevu s cílem snížení výdajů za energie. Pro-  
měnná  $T_B$  označuje aktuální teplotu vody v bojleru.

## Kapitola 5

# Implementace ohřevu TUV s využitím strojového učení

V této části bude popsána implementace hardwarových a softwarových částí potřebných pro chytrý ohřev teplé užitkové vody pomocí elektrického bojleru. K implementaci hardwarové části bude využito chytrých zařízení začleněných do systému Home Assistant, pro který bude v rámci softwarové části vytvořen doplněk pro chytré řízení elektrického bojleru. Díky tomu bude vytvořen jednotný celek, který bude možné jednoduše nasadit i v dalších instalacích.

V rámci hardwarové části bylo zapotřebí zkompletovat chytrá čidla pro záznam veličin z chytré domácnosti, kdy nasbíraná data z těchto čidel lze následně využít pro natrénování modelu pro predikci spotřeby teplé vody a výskytu osob v domácnosti. Aktuální data z těchto senzorů pak slouží pro řízení ohřevu s cílem snížení ztrát a úspory z toho plynoucí.


Po sestavení a instalaci čidel pro sběr dat o stavu chytré domácnosti bylo zapotřebí vytvořit softwarovou část, která zajistí odečet naměřených hodnot z těchto čidel, jejich uložení do databáze časových řad, jejich následná zpracování, natrénování modelu pro predikci a následné řízení ohřevu na základě predikce spotřeby.

Jelikož jsou spolu hardwarové a softwarové části výsledného řešení úzce spojeny, zaměřím se v této kapitole na implementaci jednotlivých částí jak z pohledu hardwaru, tak i softwaru.

### 5.1 Domácí server pro chod systému chytré domácnosti

Pro samotný chod systému chytré domácnosti zajišťující sběr a ukládání dat, jejich vyhodnocení i samotné řízení, jsem v první domácnosti použil jednodeskový počítač Raspberry Pi 4 s 8 GB operační paměti RAM a přídatným externím SSD diskem (viz obrázek 5.1), na kterém bude spuštěn operační systém Home Assistant OS s databází a programem pro řízení ohřevu. Tento počítač je hojně využíván pro různé projekty, včetně chytrých domácností, IoT aplikací, robotiky, trénování neuronových sítí a dalších. Raspberry Pi má malé rozměry, nízkou spotřebu energie a je cenově dostupný, což ho činí ideálním pro využití v široké škále aplikací. Jelikož hodlám tento počítač využít jak pro chod systému Home Assistant spolu s databází InfluxDB pro časové řady, tak i pro trénování modelu časových řad pro predikci vývoje spotřeby teplé vody, rozhodl jsem se využít nejvýkonnější verzi s 8 GB operační paměti. To by mělo spolu se čtyřjádrovým procesorem ARM Cortex-A72 s frekvencí 1,5

GHz, umožnit zpracovávání velkého množství dat [30]. Cena na českém trhu se pohybuje lehce nad dvěma tisíci korun<sup>1</sup>.



Obrázek 5.1: Počítač Raspberry Pi 4 Model B s 8 GB RAM a externím SSD diskem určený pro chod systému chytré domácnosti Home Assistant.

Z důvodu nespolehlivosti druhého kusu Raspberry Pi, který jsem měl k dispozici, a také pro ověření přenositelnosti mého řešení jsem pro druhou instalaci použil vysloužilý notebook Lenovo IdeaPad s procesorem Intel i5 a 8 GB RAM. Využití starších laptopů nebo mini počítačů<sup>2</sup> se ukazuje jako vhodné pro tento typ úloh. Kromě velkého množství portů lze například u vysloužilých notebooků využít vestavěnou klávesnici, monitor nebo baterii, která slouží jako záložní zdroj v případě krátkodobějších výpadků elektrické energie.

Na tato zařízení jsem následně nainstaloval operační systém Home Assistant, který umožňuje využití doplňků třetích stran, které spolu mohou spolupracovat. Pro chod doplňků

<sup>1</sup>Cena k 13. 1. 2024 na e-shopu <https://rpishop.cz/raspberry-pi-4/2611-raspberry-pi-4-model-b-8gb-ram-0765756931199.html>.

<sup>2</sup>Mini počítač (anglicky „mini computer“) je typ počítače, který se vyznačuje menšími rozměry a často i nižšími náklady ve srovnání s klasickými stolními počítači. Uživatelům však poskytuje dostatečný výkon na běžné činnosti.

je využít princip kontejnerizace<sup>3</sup>, kdy Home Assistant pro jednotlivé kontejnery vytváří rozhraní pro jejich správu.


Pro ukládání nasbíraných dat z chytré domácnosti jsem využil doplnku databáze pro časové řady InfluxDB pro Home Assistant.

## 5.2 Zařízení pro sběr dat a řízení bojleru

Pro možnost sledování veličin a ovládání chytré domácnosti bylo zapotřebí pořídit či vyrobit chytrá zařízení, která lze začlenit od systému chytré domácnosti. V této části proto popíši jednotlivá zařízení, která jsem v rámci mé práce využil pro řízení ohřevu a sběr dat o domácnosti.

Pro možnost spínání ohřevu teplé vody v bojleru a pro získání informací o odebrané elektrické energii jsem využil chytré relé Shelly 1PM. To disponuje REST API pro lokální řízení, je schopno monitorovat spotřebu, a maximální zátěž, kterou snese, je až 3500 W a 16 A.

Toto relé je napájeno ze zásuvky, do které byl bojler původně připojen. Přívod elektrické energie do bojleru jsem nově zapojil do tohoto relé viz obrázek 5.2.



Obrázek 5.2: Schéma zapojení chytrého relé Shelly 1 PM pro spínání bojleru.


<sup>3</sup>Jedná se o nižší úroveň virtualizace. Procesy jsou reprezentovány jako kontejnery a sdílí mezi sebou jádro operačního systému. Tím jsou jednotlivé procesy navzájem izolované bez potřeby celého operačního systému. Tím je dosaženo nižších hardwarových nároků a snadné přenositelnosti.

Po připojení tohoto relé k lokální Wi-Fi síti jsem jej pomocí integrace pro zařízení Shelly<sup>4</sup> začlenil do systému Home Assistant, což mi poskytlo přehled o aktuálně odebíraném množství elektrické energie a možnost spínání skrze jeho REST API.

Následně bylo zapotřebí vyrobit vlastní chytré zařízení, pro sledování veličin v okolí bojleru s využitím teplotních čidel a mikrokontroléru.

Pro sběr dat fyzických veličin v domácnosti jsem se rozhodl sestavit své vlastní zařízení postavené na mikročipu ESP8266, který je schopný komunikovat s ostatními zařízeními pomocí Wi-Fi sítě. Jeho jádro tvoří 32bitový RISC procesor Tensilica L106, který dosahuje velmi nízké spotřeby energie a maximální taktovací frekvence 160 MHz. Vyniká svou nízkou energetickou náročností i cenou, lze jej rozšířit o další komponenty, díky čemuž je oblíbený u IoT komunity. Objevuje se v nespočtu mikrokontrolérů od různých výrobců.

Nejpoužívanější mikrokontroléry osazené ESP 8266 jsou ESP-01, ESP-12E NODEMCU a WeMos D1 mini, všechny s cenou do 110 Kč<sup>5</sup>. Ve své práci jsem se rozhodl využít mikrokontrolér od společnosti WeMos (viz obrázek 5.3) pro jeho malou velikost [36, 33]. Napájen bude pro stálost přímo ze zásuvky, nicméně pro instalace bez možnosti zapojení do zásuvky jej lze rozšířit o modul umožňující napájení pomocí tužkových baterií.



Obrázek 5.3: Mikrokontrolér WeMos D1 mini s popisem jednotlivých pinů. Převzato z [42].

Prvním použitým čidlem je digitální teplotní senzor Dallas DS18B20 vyráběný firmou Maxim Integrated s jednoduchým digitálním rozhraním a unikátní adresou pro každý senzor. Nabízí široký teplotní rozsah od  $-55\text{ }^{\circ}\text{C}$  do  $+125\text{ }^{\circ}\text{C}$  a díky nízké spotřebě je často využíván v čidlech v chytrých domácnostech. Použita byla jeho voděodolná varianta, která byla umístěna do pláště bojleru pro získání informace o aktuální teplotě vody v bojleru. Jelikož naměřená teplota v plášti bojleru byla vlivem okolí nižší než skutečná teplota vody

<sup>4</sup><https://www.home-assistant.io/integrations/shelly>

<sup>5</sup>Ceny k 13. 1. 2024 podle e-shopu [Aliexpress.com](https://www.aliexpress.com)

v bojleru, bylo zapotřebí provést přepočítání naměřené teploty. K tomu jsem využil vzorec 5.1:


$$t_{real} = \frac{t_{mea} - t_{area}}{t_{max} - t_{area}} * (t_{set} - t_{area}) + t_{area} \quad (5.1)$$

, kde :

- $t_{real}$  je skutečná teplota vody v bojleru,
- $t_{mea}$  je naměřená teplota v plášti bojleru,
- $t_{area}$  je teplota okolí bojleru zadaná uživatelem,
- $t_{max}$  je maximální naměřená teplota teplotním čidlem,
- $t_{set}$  je nastavená maximální teplota vody v bojleru.

Druhým použitým čidlem je mosazný průtokoměr se zabudovaným termistorem, který byl umístěn ve výstupní trubce bojleru. Průtokoměr využívá Hallův senzor pro čítání pulsů rotoru umístěného uvnitř průtokoměru. Tyto pulsy lze následně přepočítat na litry za minutu. Spolu s aktuální teplotou vody na vstupu a výstupu toto čidlo poskytuje údaj o odebraném teple v čase.

Tyto senzory byly s využitím nepájivých polí zapojeny k pinům mikrokontroléru WeMos D1 mini, čímž bylo vytvořeno výsledné zařízení pro monitorování spotřeby teplé vody a teploty vody v bojleru viz obrázek 5.4.



Obrázek 5.4: Zařízení pro sběr dat vytvořené z mikrokontroléru WeMos D1 mini, teplotního čidla Dallas DS18B20 a průtokoměru YF-B6 s termistorem, poskytující informace o aktuální spotřebě teplé vody.

Po sestrojení zařízení pro sběr dat o chodu bojleru bylo zapotřebí do něj nahrát program, který zajistí připojení čidla do Wi-Fi sítě, správný odečet hodnot z čidel a spojení s Home Assistantem. Celý tento proces usnadňuje řešení ESPHome, které umožňuje vytvoření vlastního chytrého zařízení pomocí konfiguračního souboru ve formátu YAML viz 5.1.

---

```
1  – platform: ntc
2  sensor: resistance_sensor
3  id: ntc_sensor
4  name: NTC Temperature B Constant
5  calibration:
6    b_constant: 3950
7    reference_temperature: 25
8    reference_resistance: 50kOhm
```

---

Výpis 5.1: Příklad YAML kódu pro přidání termistoru sloužícího pro odečet teploty vody na výstupu z bojleru.

Po nahrání programu do mikrokontroléru došlo k jeho připojení na lokální Wi-Fi síť, což umožnilo integraci těchto senzorů do systému Home Assistant skrze zmiňovaný doplněk ESPHome. Toto zařízení bylo následně nainstalováno jako mezičlánek do výstupní trubky bojleru, což lze vidět na obrázku 5.5.



Obrázek 5.5: Čidlo pro sledování teploty a průtoku teplé vody instalované jako mezičlánek ve výstupní trubce bojleru.

K získávání informací o aktuálním stavu počasí jsem využil rozšíření AccuWeather<sup>6</sup> pro Home Assistant, které umožňuje získávání údajů o aktuálním počasí.

Testování pohybových senzorů pro získání informací o výskytu osob v domácnosti ukázalo, že použitá čidla neposkytují dostatečně přesné informace o tom, kolik osob se v domácnosti ve skutečnosti nachází, což by nemuselo vést ke zpřesnění predikce mého modelu. Proto jsem pro získání informací o výskytu osob v domácnosti využil jiných údajů, které lze v rámci chytré domácnosti získat. Díky nainstalované aplikaci Home Assistant v mobilních telefonech obyvatelů domácnosti lze získat informace o místě výskytu uživatelů.

---

<sup>6</sup><https://www.home-assistant.io/integrations/accuweather/>

Nevýhodou sledování polohy těchto uživatelů pomocí aplikace je to, že ne každý uživatel chce sdílet informace o své poloze. Proto jsem v mém řešení využil také informace z doplňku Nmap Tracker<sup>7</sup>, který pravidelným skenováním domácí Wi-Fi sítě získává informace o počtu připojených zařízení.

### 5.3 Tvorba trénovací sady dat

Aby bylo možné predikovat chování uživatelů domácnosti a následně řídit domácnost s cílem snížit spotřebu energie, je zapotřebí nasbíraná data z chytré domácnosti zpracovat. V této části se proto zaměřím na proces získávání dat v jednotlivých částech výsledného systému.

Nasbíraná data jsem následně získal z databáze a upravil je tak, aby mohla být použita při trénování modelu pro predikci spotřeby a vyhodnocování aktuálního stavu pro řízení ohřevu.

Z nasbíraných dat jsem pro chod mého modelu využil data o průtoku a teplotě vody ve výstupní trubce bojleru, počtu připojených zařízení k místní Wi-Fi síti, GPS poloze uživatelů, venkovní teplotě, vlhkosti, rychlosti větru a času. Tato data jsem následně transformoval do výsledné datové sady použité pro trénování modelu, jehož cílem byla predikce odebrané energie z bojleru v čase. Ze získaných dat jsem proto vypočítal cílovou hodnotu množství odebraného tepla. Z té jsem dále získal standardní odchylku a koeficient šikmosti jejího rozdělení pro stejný čas a den v týdnu za poslední tři týdny. Dále jsem pak z údajů o poloze uživatelů, kteří souhlasili se sledováním jejich výskytu, vypočítal informace o jejich vzdálenosti od domova, rychlosti jejich přibližování k domovu, a sinu a cosinu azimutu jejich aktuální polohy a polohy domácnosti. Z časového údaje jsem poté využil informaci o aktuálním dnu v týdnu a hodině, kdy tyto údaje byly rovněž převedeny na sinus a cosinus z této hodnoty. Transformace na sinus a cosinus některých hodnot je využívána v neuronových sítích pro modelování cyklických dat. Tento přístup tak umožňuje zachytit periodický charakter času, neměnnost vůči posunutí a jednoduchou reprezentaci dat, což vede k lepšímu výkonu modelů při práci s časovými vzorci.

Takto získaná data jsem poté agregoval po hodině. Hodnoty pro cílovou veličinu množství odebraného tepla, která byla měřena po minutě, jsem sečetl a následně vytvořil tříhodinové průměrovací plovoucí okno. Hodnoty ostatních veličin jsem zprůměroval. Tato hodinová agregace poskytuje dostatečnou jemnost informací pro algoritmus chytrého ohřevu při zachování komfortu uživatelů a zároveň minimalizuje potřebu vyššího výpočetního výkonu při trénování a tvorbě predikce způsobenou větším množstvím dat. Tímto postupem jsou také sloučeny podobné časové intervaly bez ztráty důležitých informací pro predikci a řízení ohřevu, což významně usnadňuje trénování modelů a zvyšuje efektivitu výpočtu. Vývoj vybraných veličin v období jednoho týdne lze vidět na grafu 5.6.

---

<sup>7</sup>[https://www.home-assistant.io/integrations/nmap\\_tracker/](https://www.home-assistant.io/integrations/nmap_tracker/)



Obrázek 5.6: Vývoj spotřeby tepla za hodinu, vzdálenosti zařízení od domova, rychlost přibližování směrem k domovu a počet zařízení připojených k Wi-Fi síti během jednoho týdne.

Při přípravě dat před trénováním neuronové sítě jsem provedl rovněž normalizaci pomocí robustního škálování (třída `RobustScaler` z knihovny `sklearn`). Významem této transformace je zajištění robustní normalizace vůči odlehlým hodnotám, které by mohly ovlivnit trénování modelu. Normalizace vstupních dat na stejný rozsah pomáhá konvergenci modelu během trénování a zlepšení jeho výkonu.

Pro vytvoření datové sady pro trénování neuronové sítě s LSTM vrstvou, která bude popsána v další části, bylo nutné získaná data transformovat do podoby vhodné pro neuronovou síť. V průběhu implementace a testování jsem narazil na neduh predikce v případě, že má model pro odhad cílové proměnné k dispozici její minulé hodnoty. Výsledný model pak pouhým zkopírováním cílové hodnoty z předchozího měření dosahoval vysoké úspěšnosti. To je však nevhodné ve většině reálných aplikací včetně tohoto případu, kdy spotřeba byla

predikována až v okamžiku, kdy k nějaké došlo. Pro generování datové sady pro neuronovou síť jsem proto využil funkci `generator`, která slouží k vytváření dávek dat pro trénování modelů strojového učení z časových řad [24]. Nejprve ze vstupního DataFramu odstraní sloupec s cílovou hodnotou a převede data na formát `numpy.float32`. Pro každou dávku pak vytváří sekvenci historických dat z posledních 32 záznamů.

V další části popíši proces tvorby modelu a jeho trénování na nasbíraných datech.

## 5.4 Tvorba modelu a predikce spotřeby

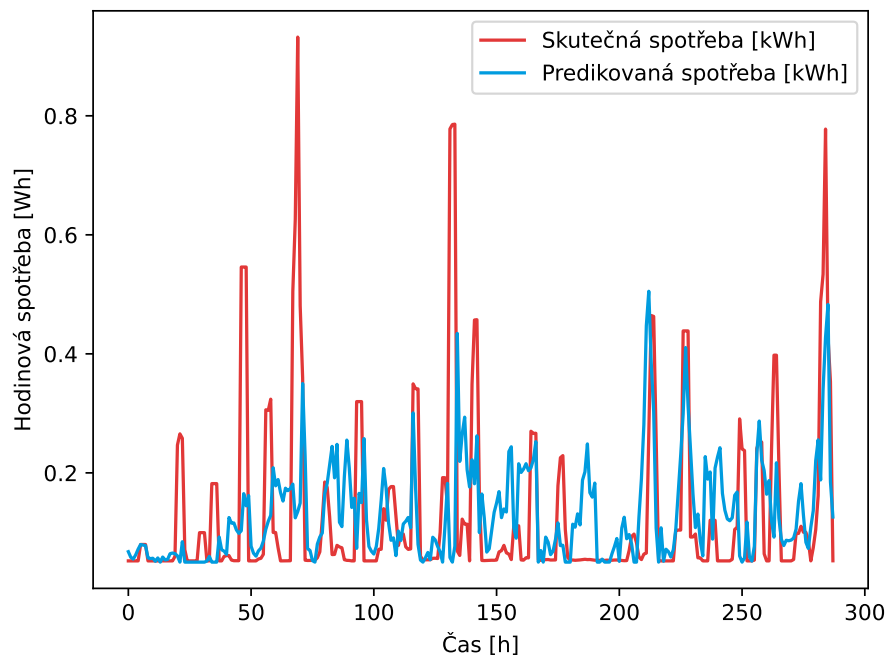
Při tvorbě modelu bylo podstatné určit, jakými daty dokáže systém chytré domácnosti disponovat v reálném čase, aby bylo možné predikovat množství odebraného tepla. To umožní algoritmu efektivně plánovat ohřev nad minimální teplotu právě o tolik tepla, kolik z něj bude v daný čas odebráno. Pro predikci odebraného tepla v čase jsem se rozhodl využít knihovny Keras pro jazyk Python. Výsledný model typu Sequential obsahuje jednu vrstvu typu LSTM s tanh aktivační funkcí, obsahující 100 skrytých neuronů, a jednu výstupní plně propojenou Dense vrstvu s jedním neuronem. Jako ztrátovou funkci jsem použil funkci počítající průměrnou ztrátu pro kvantily 0,1, 0,3, 0,5, 0,7 a 0,9. Pro optimalizaci jsem vybral algoritmus Adam s rychlostí učení 0,001. Pro řízení procesu trénování modelu jsem využil zpětných volání ModelCheckpoint a EarlyStopping. ModelCheckpoint bylo využito k ukládání nejpřesnější verze modelu, zatímco EarlyStopping sloužilo k včasnému zastavení trénování modelu, aby nedošlo k jeho přetrénování nebo plýtvání výpočetním výkonem.

Pro trénování modelu jsem vytvořenou datovou sadu rozdělil na množiny trénovacích, validačních a testovacích dat v poměru 7:2:1. Model byl nejprve trénován na trénovacích a validačních datech z obou testovacích domácností s dávkou o velikosti 16. Posléze byl tento model dotrénován na datech pro konkrétní domácnost. Trénování obsahovalo 100 epoch s tím, že díky nastavení EarlyStopping nemusely všechny epochy proběhnout.

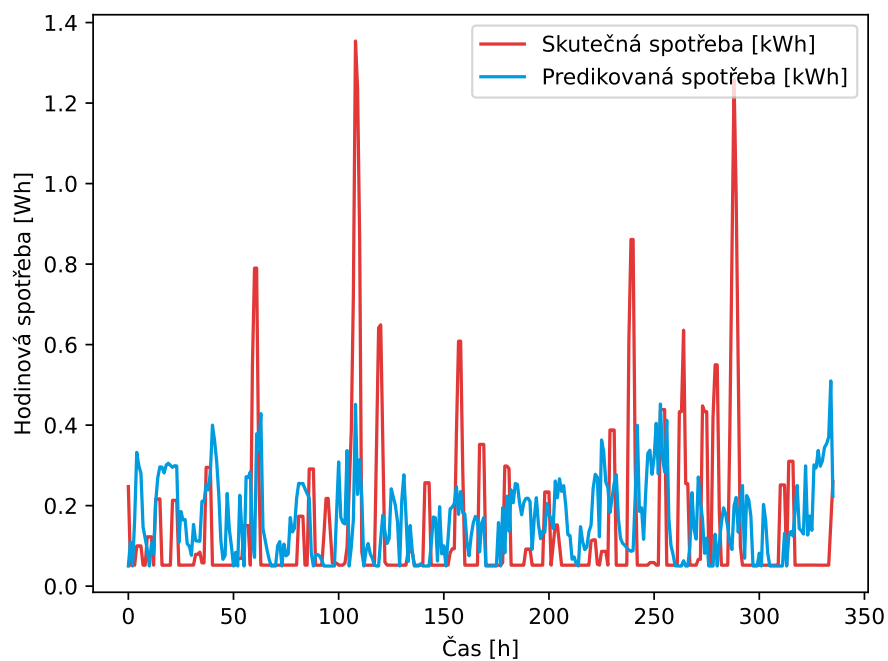
## 5.5 Úspěšnost predikce

Pro efektivní ohřev na základě predikovaného odběru teplé vody z bojleru je zapotřebí, aby predikovaná spotřeba byla co nejpřesnější. Model byl nejdříve natrénován na datech ze dvou domácností za posledních 6 měsíců. Následně byl pro každou domácnost dotrénován na datech za poslední měsíc z konkrétní domácnosti. Na následujících grafech 5.7 a 5.8 lze vidět úspěšnost predikce a skutečného odběru ze dvou testovacích domácností za dva týdny.

U první domácnosti úspěšnost predikce dosáhla hodnoty RMSE 0,17, zatímco u druhé domácnosti to bylo 0,22. Kromě RMSE je důležitým ukazatelem také to, zda množství odebraného tepla se blíží tomu predikovanému. To lze porovnat součtem predikovaných a skutečných hodnot odebraného tepla, který poskytuje informaci o tom, zdali predikce nepodhodnocuje množství odebraného tepla, což by mohlo vést ke snížení tepelného komfortu obyvatel domácnosti. Pokud by naopak predikoval větší množství odebraného tepla než skutečně bylo, docházelo by ke zbytečnému ohřívání vody v bojleru, což by způsobilo zvýšení tepelných ztrát a snížení úspory. U první domácnosti model predikoval pro období dvou týdnů zhruba o 7,5 % procent více odebraného tepla než tomu bylo ve skutečnosti. V případě druhé domácnosti činil procentuální rozdíl 7,1 %, kdy model naopak predikoval méně odebraného tepla.



Obrázek 5.7: Skutečná a predikovaná hodinová spotřeba tepla z bojleru v první domácnosti.



Obrázek 5.8: Skutečná a predikovaná hodinová spotřeba tepla z bojleru ve druhé domácnosti.

## 5.6 Doplněk chytrého ohřevu pro Home Assistant

Pro využití predikce spotřeby tepla v podobě teplé vody bylo zapotřebí sestrojít algoritmus, který dokáže tyto informace transformovat v efektivní ohřev vody v bojleru pro dosažení úspory elektrické energie při zachování tepelného komfortu obyvatelů domácnosti. Jelikož jsem si od začátku kladl za cíl umožnit široké veřejnosti použití mého řešení, rozhodl jsem se mé řešení implementovat jako doplněk pro systém Home Assistant. V této části proto popíši jednotlivé části doplňku, který si může nainstalovat každý, kdo disponuje tímto systémem chytré domácnosti.

Pro vytvoření doplňku jsem vycházel z veřejného GitHub repozitáře `addons-example`<sup>8</sup> od tvůrců systému Home Assistant, který slouží jako návod pro tvorbu vlastních doplňků. V rámci doplňku je možné v konfiguračním souboru `config.yaml` definovat práva doplňku v kontextu celého systému, architektury, které doplněk podporuje, či proměnné, které uživatel může doplňku poskytnout. Toho jsem využil pro pohodlné předání programu informací o přístupových údajích k databázi, identifikátoru sledovaných entit, parametrech bojleru a domácnosti, či informaci, zda je bojler připojen k nízkému tarifu.

Zdrojové kódy mého řešení jsou zveřejněny jako knihovna `smartboiler`<sup>9</sup> v rámci repozitáře balíčků PyPI. Samotný doplněk pro Home Assistant pak díky instrukcím v souboru `Dockerfile`<sup>10</sup> zkopíruje do programového prostředí potřebné soubory, nainstaluje potřebné knihovny specifikované v souboru `requirements.txt` a spustí skript `controller.py` z knihovny `smartboiler`.

Po zavolání skriptu `controller.py` dojde k načtení uživatelem zadaných proměnných ze souboru `options.json`, který je automaticky vytvořen ze zadaných hodnot v rámci prostředí doplňku pro Home Assistant. Na základě těchto údajů jsou vytvořeny instance tříd `Controller`, která slouží jako jádro celého chytrého ohřevu, `Boiler` pro výpočty pro chytrý ohřev, `Socket` pro komunikaci s chytrým relé pro ovládání ohřevu teplé vody, `Datahandler` pro zpracování dat, `Forecast` pro trénování modelu a získávání predikcí, a `EventChecker` pro práci s Google kalendářem. Následně je zahájen algoritmus ohřevu, který v prvních čtyř týdnech pouze sbírá data o návycích uživatelů a udržuje teplotu vody v bojleru na konstantní teplotě. Po uplynutí čtyř týdnů dojde s využitím dat z konkrétní domácnosti k dotrénování modelu na předtrénovaném modelu z mých testovacích domácností, kdy si uživatel může vybrat mezi modelem z větší nebo menší domácnosti. Poté je vytvořena predikce spotřeby tepla z bojleru na následujících šest hodin a získána informace o aktuální teplotě vody v bojleru. Algoritmus poté postupně vyhodnocuje, zdali má dostatečný čas na nahřátí vody do předpokládané spotřeby. Cílem algoritmu je dodat do bojleru právě tolik tepla nad pohotovostní teplotu vody v bojleru, která činí 40 °C, kolik je předpovězeno, že bude spotřebováno. Jakmile je již nutné začít ohřívat vodu v bojleru před předpokládanou spotřebou, je sepnuto chytré relé a zahájen ohřev.

Chytrý ohřev umožňuje jeho uživatelům také vytvořit v Google kalendáři událost označující dovolenou, kdy po dobu jejího trvání nebude vůbec docházet k ohřevu vody v bojleru. Jako ochrana proti množení bakterie *Legionella*, které je v poslední době pozorováno více kvůli snižování teploty vody v bojlerech pro účely úspory energie, je implementována funkce `antilegionella`. Tato funkce pravidelně, jednou za dva týdny, nahřívá vodu v bojleru na maximální hodnotu. Tímto opatřením se eliminuje riziko množení bakterie *Legionella*, čímž je zajištěna zdravotní nezávadnost vody pro uživatele. Pro uživatele disponující domácí foto-

<sup>8</sup><https://github.com/home-assistant/addons-example>

<sup>9</sup><https://pypi.org/project/smartboiler/>

<sup>10</sup>Dockerfile je textový soubor obsahující instrukce pro vytvoření Docker kontejneru.

voltaickou elektrárnou je také připravena funkce, která v případě přebytků vyrobené energie a současně plně nabitě baterie tyto přebytky využije pro ohřátí vody v bojleru. Tato funkce byla testována na zařízení od společnosti Solax, jejichž zařízení disponují API pro získávání informací o jejich stavu. Pro domácnosti, které mají bojler připojený v rámci okruhu nízkého tarifu, jsem implementoval funkci, která na základě historických dat o dostupnosti chytrého relé dokáže rozpoznat časové úseky vysokého tarifu, kdy není možné vodu v bojleru ohřívat. Díky tomu je následně uzpůsobeno plánování ohřevu teplé vody tak, aby se voda v bojleru stihla nahřát před očekávanou spotřebou.

Během testování jsem získal požadavek od uživatelů na implementaci funkce, která zajistí, že po požadované době bude voda v bojleru nahřívána na nastavenou teplotu – odstavení chytrého ohřevu a funkce prostého termostatu bez potřeby zásahu do chodu doplňku. Implementoval jsem proto možnost zadat do Google kalendáře událost s údajem o požadované teplotě. Algoritmus pak zajistí, že po dobu trvání této události bude voda v bojleru nahřívána na tuto nastavenou teplotu.

## Kapitola 6

# Testování implementovaného řešení a vyhodnocení úspor

Začátkem října roku 2023 jsem ve dvou testovacích domácnostech spustil sběr dat o chodu domácnosti včetně údajů o spotřebě teplé vody z bojleru a odebrané elektrické energie bojlerem. Od března roku 2024 pak v těchto domácnostech probíhalo testování a ladění navrženého algoritmu pro závěrečné vyhodnocení jeho úspěšnosti. Pro ověření funkčnosti řešení pro domácnosti s vlastní fotovoltaickou elektrárnou a případné budoucí rozšíření trénovací datové sady jsem využil třetí domácnost. V té došlo k instalaci bojleru s průtokoměrem až v samém závěru mého testování, tudíž jsem zde netestoval chytrý ohřev na základě predikce.

V této kapitole se nejdříve zaměřím na popis testovacích domácností, poté na úspěšnost predikce spotřebovaného tepla z bojleru, dosaženou úsporu chytrým ohřevem, a nakonec rozeberu zpětnou vazbu od uživatelů a představím plán do budoucna.

### 6.1 Testovací domácnosti

Pro ověření funkčnosti mého řešení jsem si vybral tři testovací domácnosti, které k ohřevu teplé vody využívají bojler.

První z nich disponuje 80litrovým elektrickým bojlerem od firmy Dražice s příkonem 2000 W, který byl vyroben v roce 2010. Teplou vodu z tohoto bojleru využívají dvě dospělé osoby s pevnou pracovní dobou pro koupání a běžnou hygienu. Bojler je umístěn ve vytápěné místnosti vedle koupelny. Kuchyně je v tomto případě umístěna v jiném patře rodinného domu a je zásobována teplou vodou z jiného zařízení. Sběr dat v této domácnosti probíhal od začátku října roku 2023 a v půli března roku 2024 bylo zahájeno testování chytrého ohřevu.

Ve druhé testovací domácnosti se nachází rovněž elektrický bojler od společnosti Dražice o objemu 120 litrů, stáří jednoho roku a s příkonem 2000 W je umístěn v nevytápěném sklepě rodinného domu. Teplá voda z tohoto bojleru je využívána k zásobování dvou koupelen. Dodávka teplé vody do kuchyně a umyvadel je v případě této domácnosti řešena průtokovými ohříváči. Tuto domácnost stabilně obývají dvě dospělé osoby se zaměstnáním na směny a jedna nezletilá osoba v posledním ročníku základní školy. Další tři zletilé osoby studují vysokou školu a domů přijíždějí na konci pracovního týdne a v neděli opět odjíždí z domu pryč. Z úvodního sezení s rodinou také vyplynulo, že rodina často hostí početné návštěvy, které u nich využívají teplou vodu z bojleru. Tato domácnost byla osazena chyt-

rými čidly koncem října roku 2023 a testování chytrého ohřevu zde bylo zahájeno v půli března roku 2024.

Třetí testovací domácnost disponuje rovněž bojlerem od firmy Dražice. Tento bojler je 160litrovou verzí kombinovaného bojleru, kdy k ohřevu vody je využíváno buď elektrické energie nebo plynu. Tato domácnost také disponuje fotovoltaickou elektrárnou s baterií pro ukládání přebytků elektrické energie. Bojler samotný je umístěn v nevytápěném sklepe rodinného domu a teplou vodou zásobuje dvě koupelny i veškerá umyvadla a dřezy. Tuto domácnost obývají po většinu týdne tři dospělí osoby, kdy dvě z nich jezdí přes den do zaměstnání a školy a třetí z nich je žena v domácnosti. Další dvě až tři dospělé osoby dojíždějí do domácnosti na víkendy. Jelikož k instalaci kombinovaného bojleru v této domácnosti došlo až v samém závěru testování mého řešení, rozhodl jsem se této instalace využít pouze pro budoucí rozšíření trénovací sady dat pro základní model predikce a hlavně pro otestování funkce, která v případě plného nabití baterie a přebytků vyrobené elektrické energie, upřednostní uložení těchto přebytků nahřátím vody v bojleru na vyšší než nastavenou.


## 6.2 Dosažená úspora

Cílem chytrého ohřevu bylo díky úspěšné predikci spotřeby nahřívát vodu před očekávanou spotřebou a mimo tyto časy udržovat teplotu vody v bojleru na nižší pohotovostní úrovni. Snížením průměrné teploty vody v bojleru mělo dojít ke snížení tepelných ztrát a s tím spojené úspoře elektrické energie. Testování chytrého ohřevu probíhalo v první domácnosti sedm a ve druhé osm týdnů. V případě první domácnosti klesla průměrná týdenní spotřeba elektrické energie o 26,02 %, což lze vidět na grafu 6.1. U druhé domácnosti, u které byla přesnost predikce spotřeby horší než v případě první domácnosti, lze na grafu 6.2 vidět, že bylo dosaženo snížení průměrné spotřeby elektrické energie pro ohřev vody v bojleru o 22,09 %.


První domácnost, která platí za jednu kWh 5,37 Kč, může díky poklesu průměrné týdenní spotřeby bojleru o 5,94 kWh ušetřit 1660 Kč ročně. Druhá domácnost, která využívá k ohřevu nízký tarif s cenou 4,1 Kč za jednu kWh, může díky poklesu průměrné týdenní spotřeby o 8,95 kWh ušetřit 1908 Kč za rok.

Při srovnání s diplomovou prací [27], kdy autor uvádí dosaženou úsporu v rozmezí 20–25 %, je mé řešení co se týče úspory srovnatelné. Autor v práci však neuvádí informace o zpětné vazbě uživatelů a o diskomfortu během chytrého ohřevu. Nelze tak proto objektivně tato dvě řešení porovnat. V porovnání s mojí bakalářskou prací [17] je maximální dosažená úspora menší zhruba o 4 %, nicméně v obou těchto pracích probíhalo testování po kratší dobu, kdy jako období bez ohřevu na základě predikce spotřeby byl uvažován pouze jeden týden. To mohlo do jisté míry způsobit zkreslení reálné úspory vlivem nárazové změny chování uživatelů.


Jelikož vývoj spotřebované energie může být kromě chytrého ohřevu ovlivněn také jiným faktorem, kterým může být například již zmíněná změna chování uživatelů, rozhodl jsem se porovnat také poměr odebraného a dodaného tepla. Díky tomu lze sledovat trend ve vývoji účinnosti ohřevu teplé vody pomocí bojleru. Z grafů 6.3 a 6.4 je patrné, že díky chytrému ohřevu došlo k nárůstu této účinnosti o 14,54 % v případě první a o 13,28 % u druhé domácnosti.




Obrázek 6.1: Vývoj týdenní spotřeby elektrické energie před a po zahájení chytrého ohřevu vody v bojleru u první domácnosti.



Obrázek 6.2: Vývoj týdenní spotřeby elektrické energie před a po zahájení chytrého ohřevu vody v bojleru u druhé domácnosti.



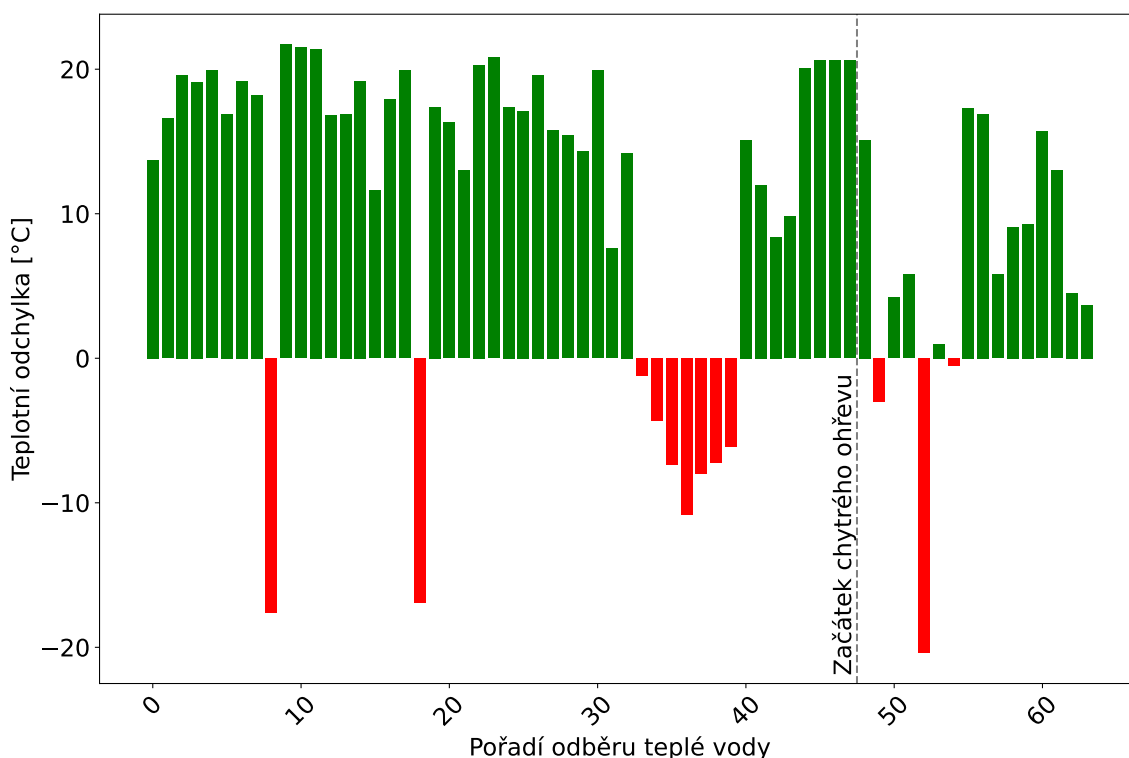
Obrázek 6.3: Vývoj poměru mezi odebraným a dodaným teplem do bojleru v první domácnosti.



Obrázek 6.4: Vývoj poměru mezi odebraným a dodaným teplem do bojleru v druhé domácnosti.

### 6.3 Komfort uživatelů a zpětná vazba

Jako další parametr, který je vhodné vyhodnotit, je komfort uživatelů během provozu chytrého ohřevu. Jako diskomfort lze označit situace, kdy bojler nebyl schopen dodat dostatečné množství teplé vody. Na následujícím grafu 6.5 lze pozorovat teplotu vody na výstupu bojleru během jednotlivých odběrů, kdy červeně jsou zaznačeny odběry, kdy byl rozdíl minimální teploty vody během odběru a minimální komfortní teplotou 40 °C záporný. Zeleně jsou pak označeny odběry, byl tento rozdíl kladný. Z grafu je patrné, že po zahájení chytrého ohřevu nedošlo k výraznému nárůstu odběrů, během kterých měli obyvatelé k dispozici pouze vlažnou vodu.



Obrázek 6.5: Rozdíl minimální teploty vody naměřené během odběru a minimální komfortní teplotou 40 °C před a po začátku chytrého ohřevu.

V rámci mé práce jsem také získával od uživatelů testovacích domácností zpětnou vazbu formou rozhovoru, kdy jsem se jednotlivých členů domácností dotazoval na jejich zkušenost s úsporným chytrým ohřevem.

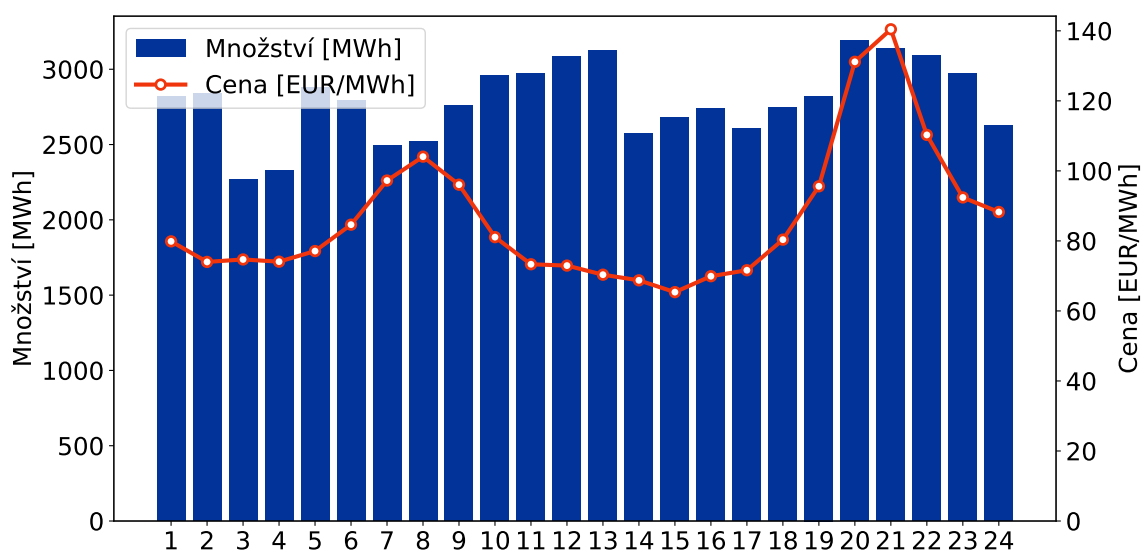
Respondenti z první testovací domácnosti uváděli, že na rozdíl od chytrého ohřevu, který si měli možnost zkusit během testování mé bakalářské práce, nepocítili během testování chytrého ohřevu s využitím strojového učení výrazné snížení komfortu. Díky zpětné vazbě od této domácnosti byla implementována funkce prostého termostatu, kdy je voda v bojleru nahřívána na nastavenou teplotu po dobu trvání události v Google kalendáři, v jejímž názvu je uvedena cílová teplota. Uživatelé si také pochvalovali systém chytré domácnosti Home Assistant, díky kterému měli možnost odkudkoliv sledovat stav jejich chytré domácnosti včetně statistik ohřevu teplé vody. Po předvedení dosažené úspory se obyvatelé

této domácnosti rozhodli ponechat v jejich domácnosti čidla a zařízení pro chod chytrého ohřevu teplé vody.

Obyvatelé druhé domácnosti, ve které byl instalován systém chytrého ohřevu, se za celou dobu chodu chytrého ohřevu nesetkali s tím, že by měli v době odběru k dispozici pouze vlažnou či studenou vodu. Co však pocítili, byla má častá přítomnost u nich v domácnosti, jelikož s chodem systému Home Assistant bylo čerstvě po nasazení mnoho problémů. To v nich z počátku vytvořilo lehkou skepsi co se týče stability tohoto řešení. Postupem času, kdy se veškeré neduhy systému podařilo vyřešit, však jejich nedůvěra opadla a se zájmem se mnou konzultovali možné rozšíření jejich chytré domácnosti do dalších let. I druhá domácnost se proto rozhodla pokračovat v chytrém ohřevu teplé vody i po skončení testování v rámci mé diplomové práce.

## 6.4 Plán do budoucna

V rámci budoucí práce se plánují zaměřit na implementaci webového rozhraní, které bude dostupné přímo z uživatelského rozhraní pro Home Assistant, díky kterému bude uživatel moci upravovat parametry jeho domácnosti a sledovat stav samotného doplňku. Jako další užitečná funkce se jeví vytvoření modelu pro odhad odebraného tepla pouze z informací o teplotách naměřených v okolí bojleru jako jsou teploty na vstupních a výstupních trubkách a v plášti bojleru. Díky tomu by bylo možné použít mé řešení i v domácnostech, kde není možnost instalace průtokoměru do výstupní trubky bojleru. Pro domácnosti s FVE se také nabízí funkce, která bude řídit ohřev s přihlédnutím na aktuální spotovou cenu elektřiny na trhu. Pokud by daná domácnost měla tarif, kdy se cena za kilowatthodinu odvíjí od aktuální ceny na trhu, dalo by se využít predikce spotřeby k ohřívání vody během nízkých spotových cen. V principu by ohřev fungoval tak, že v případě, kdy by ohřev vody v bojleru před předpokládaným odběrem byl na základě spotové ceny v daný okamžik dražší než ohřev dříve za nižší spotovou cenu i přes započítání tepelných ztrát do doby odběru, voda v bojleru by byla nahřívána dříve. Vývoj spotových cen během 26. 4. 2024 lze vidět na grafu 6.6.



Obrázek 6.6: Vývoj spotových cen elektřiny během 26. dubna 2024. Data převzata z [48].

# Kapitola 7

## Závěr

Tato diplomová práce se zabývala využitím strojového učení v rámci chytrých domácností s důrazem na optimalizaci spotřeby energie. V teoretické části byla provedena rešerše modelů pro predikci a jejich následného využití s cílem úspory energie v domácnostech. Praktická část se zabývala návrhem a implementací inteligentního řízení ohřevu teplé vody pomocí bojleru v domácnosti s využitím strojového učení pro predikci. V rámci výsledného řešení byla na dvou testovacích instalacích sbírána data o chodu domácnosti včetně spotřeby teplé vody v bojleru a ukládána do databáze InfluxDB. Tato data byla následně zpracována a využita pro natrénování Long Short-Term Memory (LSTM) neuronové sítě pro predikci množství odebraného tepla v podobě teplé vody z bojleru. Na základě predikce odebraného tepla byl v jazyce Python vytvořen řídicí algoritmus pro ohřev vody v bojleru tak, aby byla voda ohřívána na vyšší než pohotovostní teplotu až těsně před očekávaným odběrem, po kterém se teplota vody opět ustálila na pohotovostní teplotě. Toto řešení kromě ohřevu na základě predikce obsahuje funkce jako Antilegionella, ochrana proti zamrznutí, odstavení ohřevu během dovolené, nebo funkci pro využití přebytků energie z domácí fotovoltaické elektrárny. Řešení bylo nasazeno ve dvou testovacích domácnostech jako doplněk systému chytré domácnosti Home Assistant. Během měření bylo v případě první domácnosti dosaženo 26,08 % úspory elektrické energie na ohřev vody v bojleru. V případě druhé domácnosti, u které byla předpověď méně úspěšná, činila úspora 22,09 %. Dalším sledovaným údajem byl poměr mezi odebraným a dodaným teplem, který u obou domácností vzrostl o zhruba 14 %. První domácnost, která platí 5,37 Kč za kWh může díky poklesu průměrné týdenní spotřeby bojleru o 5,94 kWh ušetřit 1660 Kč za rok. Druhá domácnost může díky poklesu průměrné týdenní spotřeby o 8,95 kWh a ceně 4,1 Kč za kWh v nízkém tarifu ušetřit ročně 1908 Kč. Ze zpětné vazby od uživatelů vyplynulo, že během chytrého ohřevu pocítili diskomfort v podobě studené vody pouze ve výjimečných situacích, které byly způsobeny neobvykle velkým odběrem teplé vody během jednorázových akcí. Hlavním přínosem této práce je vytvoření řešení, které s využitím strojového učení při ohřevu vody v domácnosti dokáže snížit výdaje za energie při zachování komfortu uživatelů. Jako další rozšíření se nabízí implementace uživatelského rozhraní pro získání základních statistik, nebo algoritmus pracující se spotovou cenou elektřiny pro optimalizaci časů ohřevu. Do budoucna bych se také rád zaměřil na odhad odebraného tepla z bojleru bez nutnosti instalace průtokoměru.

# Literatura

- [1] ABB. *ABB Free@Home*. Online. 2020. Dostupné z: <https://new.abb.com/low-voltage/cs/nizke-napeti/produkty/automatizace-bytu-a-budov/produktove-rady/abb-free@home>. [cit. 2023-12-27].
- [2] ALIZADEH, E. *NeuralProphet: A Time Series Modeling Library Based on Neural Networks*. Online. 2020. Dostupné z: <https://towardsdatascience.com/neural-prophet-a-time-series-modeling-library-based-on-neural-networks-dd02dc8d868d>. [cit. 2023-12-03].
- [3] AMAZON.COM, I. *Amazon Smart Thermostat*. Online. 2024. Dostupné z: <https://www.amazon.com/Amazon-Smart-Thermostat/dp/B08J4C8871>. [cit. 2024-01-20].
- [4] AQUANTA, I. *Aquanta*. Online. 2023. Dostupné z: <https://aquanta.io/>. [cit. 2023-12-20].
- [5] BARBIERI, M. *Understanding the Seasonal Order of the SARIMA Model*. Online. 2019. Dostupné z: <https://towardsdatascience.com/understanding-the-seasonal-order-of-the-sarima-model-ebef613e40fa>. [cit. 2023-11-05].
- [6] BARNES, B. a FULFORD, G. *Mathematical Modelling with Case Studies: A Differential Equations Approach using Maple and MATLAB, Second Edition*. 1. vyd. Taylor & Francis, 2002. Differential Equation Approach Using Maple. ISBN 9780415298049.
- [7] BHOJ, N. a SINGH BHADORIA, R. Time-series based prediction for energy consumption of smart home data using hybrid convolution-recurrent neural network. *Telematics and Informatics*. 1. vyd., 2022, sv. 75, č. 1, s. 101907. ISSN 0736-5853.
- [8] CATHERINE, V. *In-Depth Understanding of NeuralProphet through a Complete Example*. Online. 2021. Dostupné z: <https://towardsdatascience.com/in-depth-understanding-of-neuralprophet-through-a-complete-example-2474f675bc96>. [cit. 2023-11-19].
- [9] CONTROLS, J. *GLAS Smart Thermostat Product Bulletin*. Online. 2024. Dostupné z: <https://docs.johnsoncontrols.com/bas/r/Johnson-Controls/en-US/GLAS-Smart-Thermostat-Product-Bulletin/GLAS-Smart-Thermostat>. [cit. 2024-01-20].
- [10] DIX, P. *Why Time Series Matters for Metrics, Real-Time Analytics and Sensor Data*. Online. 2021. Dostupné z: <https://get.influxdata.com/rs/972-GDU-533/images/why%20time%20series.pdf>. [cit. 2023-10-20].

- [11] DZD. *OHŘÍVAČ VODY OKCE*. Online. 2023. Dostupné z: <https://www.dzd.cz/ohrivace-a-zasobniky-teple-vody/elektricke/zavesne/okce>. [cit. 2024-01-03].
- [12] ECOBEE. *Ecobee Smart Thermostat*. Online. 2024. Dostupné z: <https://www.ecobee.com/en-ca/smart-thermostats/smart-thermostat-premium/>. [cit. 2024-01-20].
- [13] EON. *Jak fungují úsporné žárovky*. Online. 2023. Dostupné z: <https://www.eon.cz/radce/chytra-domacnost/led-osvetleni/jak-funguji-usporne-zarovky/>. [cit. 2023-12-31].
- [14] FACEBOOK. *Prophet Documentation*. Online. 2021. Dostupné z: [https://facebook.github.io/prophet/docs/quick\\_start.html](https://facebook.github.io/prophet/docs/quick_start.html). [cit. 2023-10-09].
- [15] GAHIRWAL, M. a VIJAYALAKSHMI, M. Inter Time Series Sales Forecasting. *International Journal of Advanced Studies in Computers, Science and Engineering*. 1. vyd., 2013, sv. 2, č. 1, s. 55–66. Dostupné z: <https://www.proquest.com/scholarly-journals/inter-time-series-sales-forecasting/docview/1372488956/se-2>.
- [16] GOOGLE. *Nest Thermostat Savings*. Online. 2024. Dostupné z: <https://store.google.com/intl/en/ideas/articles/nest-thermostat-savings/>. [cit. 2024-01-20].
- [17] GRÜNWARD, A. *Z hloupého bojleru chytrý pomocí chytré zásuvky*. Brno, 2021. Bakalářská práce. Vysoké učení technické v Brně. Vedoucí práce MATERNA, Z.
- [18] HOME ASSISTANT. *Home Assistant*. Online. 2023. Dostupné z: <https://www.home-assistant.io>. [cit. 2023-12-30].
- [19] HOMEY. *Homey*. Online. 2023. Dostupné z: <https://homey.app>. [cit. 2023-12-30].
- [20] HONEYWELL. *T10 Pro Smart Thermostat with RedLINK Room Sensor*. Online. 2024. Dostupné z: <https://www.honeywellhome.com/us/en/products/air/thermostats/wifi-thermostats/t10-pro-smart-thermostat-with-redlinkr-room-sensor-thx321wfs2001w-u/>. [cit. 2024-01-20].
- [21] HYNDMAN, R. J. a ATHANASOPOULOS, G. *Forecasting: principles and practice*. Online. OTexts, 2018. Dostupné z: <https://otexts.com/fpp2/>. [cit. 2024-02-19].
- [22] JANIO MARTINEZ BACHMANN. *What is the difference between a probability and a likelihood?* Online. 2019. Dostupné z: <https://www.kaggle.com/questions-and-answers/198544>. [cit. 2023-12-30].
- [23] KIM, O. *Predicting Future by LSTM, Prophet, Neural Prophet*. Online. 2021. Dostupné z: <https://www.kaggle.com/code/ohseokkim/predicting-future-by-lstm-prophet-neural-prophet>. [cit. 2023-11-09].
- [24] LEARY, S. P. *Time Series H2O AutoML Example*. Online. 2019. Dostupné z: <https://github.com/SeanPLeary/time-series-h2o-automl-example>. [cit. 2023-11-11].

- [25] LIPTON, Z. A Critical Review of Recurrent Neural Networks for Sequence Learning. *ArXiv*. 1. vyd., Květen 2015, abs/1506.00019, č. 1, s. 24–26.
- [26] NAM, T. *Time Series Data Characteristics*. Online. 2020. Dostupné z: <https://medium.com/@namnguyenthe/time-series-data-characteristics-994e43c470c6>. [cit. 2023-10-10].
- [27] NECPÁL, D. *Prediktivní řízení ohřevu TUV a vytápění pomocí metod strojového učení*. Brno, 2023. Diplomová práce. Vysoké učení technické v Brně. Vedoucí práce ING. ZDENĚK MATERNA, P.
- [28] ORGANIZATION, W. H. *Legionella and the Prevention of Legionellosis*. 1. vyd. World Health Organization (WHO), 2007. ISBN 9241562978. Library Cataloguing-in-Publication Data.
- [29] PENNSYLVANIA STATE UNIVERSITY. *2.1 - Introduction to Probability Distributions*. Online. 2023. Dostupné z: <https://online.stat.psu.edu/stat510/lesson/2/2.1>. [cit. 2024-01-01].
- [30] RASPBERRY PI FOUNDATION. *Raspberry Pi 4 Model B*. Online. 2023. Dostupné z: <https://www.raspberrypi.com/products/raspberry-pi-4-model-b/>. [cit. 2023-10-10].
- [31] ROBERT H. SHUMWAY, D. S. S. *Time Series Analysis and Its Applications*. 4. vyd. Springer Cham, 2017. 2197-4136. ISBN 978-3-319-52452-8.
- [32] SAK, H.; SENIOR, A. a BEAUFAYS, F. Long short-term memory recurrent neural network architectures for large scale acoustic modeling. *Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH*. 1. vyd., Leden 2014, č. 1, s. 338–342.
- [33] SANTOS, R. *Best ESP8266 Wi-Fi Development Board – Buying Guide 2021*. Online. 2023. Dostupné z: <https://makeradvisor.com/best-esp8266-wi-fi-development-board/>. [cit. 2023-12-22].
- [34] SHOHAN, M. J. A.; FARUQUE, M. O. a FOO, S. Y. Forecasting of Electric Load Using a Hybrid LSTM-Neural Prophet Model. *Energies*. 1. vyd., 2022, sv. 15, č. 6. ISSN 1996-1073.
- [35] SIEMENS. *Siemens HVAC Connected Home*. Online. 2023. Dostupné z: <https://www.siemens.com/cz/cs/products/technologie-budov/hvac/connected-home.html>. [cit. 2023-12-31].
- [36] SYSTEMS, E. *Espressif Systems Documentation*. Online. 2023. Dostupné z: <https://www.espressif.com>. [cit. 2023-12-20].
- [37] TADO. *Tado Wired Smart Thermostat Starter Kit V3*. Online. 2024. Dostupné z: <https://shop.tado.com/en-row/products/tado-wired-smart-thermostat-starter-kit-v3-intelligent-heating-control>. [cit. 2024-01-20].
- [38] TAYLOR, S. J. a LETHAM, B. Forecasting at scale. *The American Statistician*. 1. vyd. Taylor & Francis, 2018, sv. 72, č. 1, s. 37–45.

- [39] TOPINFO, s. *Ceny elektřiny v roce 2024*. Online. 2024. Dostupné z: <https://www.tzb-info.cz/ceny-paliv-a-energie/14-ceny-elektriny>. [cit. 2024-04-08].
- [40] TRIEBE, O.; HEWAMALAGE, H.; PILYUGINA, P.; LAPTEV, N. P.; BERGMEIR, C. et al. NeuralProphet: Explainable Forecasting at Scale. *ArXiv*. 1. vyd., 2021, abs/2111.15397, č. 1. Dostupné z: <https://api.semanticscholar.org/CorpusID:244729652>.
- [41] VASICA, R. *Inteligentní řízení akumulčního ohřevu teplé vody*. Brno, 2014. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií.
- [42] WEMOS. *Wemos D1 Mini*. Online. 2023. Dostupné z: [https://www.wemos.cc/en/latest/d1/d1\\_mini.html](https://www.wemos.cc/en/latest/d1/d1_mini.html). [cit. 2023-12-23].
- [43] WOOD, S. N. *Generalized Additive Models: An Introduction with R, Second Edition*. 2nd ed. Boca Raton, FL: Chapman and Hall/CRC, 2017. ISBN 9781315370279.
- [44] YU, L.; XIE, W.; XIE, D.; ZOU, Y.; ZHANG, D. et al. Deep Reinforcement Learning for Smart Home Energy Management. *IEEE Internet of Things Journal*. 1. vyd., 2020, sv. 7, č. 4, s. 2751–2762.
- [45] ZHANG, Z. a LAM, K. P. Practical Implementation and Evaluation of Deep Reinforcement Learning Control for a Radiant Heating System. In: GOWRI SANKAR RAMACHANDRAN, G. N., ed. *Proceedings of the 5th Conference on Systems for Built Environments*. New York, NY, USA: Association for Computing Machinery, 2018, s. 148–157. BuildSys '18. ISBN 9781450359511.
- [46] ZHAO, C.; HU, P.; LIU, X.; LAN, X. a ZHANG, H. Stock Market Analysis Using Time Series Relational Models for Stock Price Prediction. *Mathematics*. 1. vyd., 2023, sv. 11, č. 5. ISSN 2227-7390.
- [47] ZHENG, S. *Time Series Analysis: Chapter 6*. Online. 2023. Dostupné z: <http://people.missouristate.edu/songfengzheng/Teaching/MTH548/Time%20Series-ch06.pdf>. [cit. 2023-11-22].
- [48] ČEPS, A.S.. *Denní trh*. Online. 2024. Dostupné z: <https://www.ote-cr.cz/cs/kratkodobe-trhy/elektrina/denni-trh?date=2024-04-26>. [cit. 2024-04-25].
- [49] ČSÚ. *Dvě třetiny spotřeby energie domácností padnou na vytápění*. Online. 2021. Dostupné z: <https://www.czso.cz/csu/czso/dve-tretiny-spotreby-energie-domacnosti-padnou-na-vytapeni>. [cit. 2023-12-20].
- [50] ČSÚ. *Dvě třetiny spotřeby energie domácností padnou na vytápění*. Online. 2022. Dostupné z: <https://www.czso.cz/csu/czso/dve-tretiny-spotreby-energie-domacnosti-padnou-na-vytapeni>. [cit. 2023-12-25].