



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

FACULTY OF INFORMATION TECHNOLOGY

ÚSTAV POČÍTAČOVÝCH SYSTÉMŮ

DEPARTMENT OF COMPUTER SYSTEMS

**SYSTÉM PRO OTEVÍRÁNÍ OKNA NA ZÁKLADĚ
TEPLoty A KONCENTRACE CO₂ V MÍSTNOSTI**

SYSTEM FOR OPENING A WINDOW BASED ON THE TEMPERATURE AND CO₂
CONCENTRATION IN THE ROOM

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

TADEÁŠ JŮZA

VEDOUcí PRÁCE

SUPERVISOR

Ing. PETER TISOVČÍK

BRNO 2021

Zadání bakalářské práce



Student: **Jůza Tadeáš**
Program: Informační technologie
Název: **Systém pro otevírání okna na základě teploty a koncentrace CO2 v místnosti**
System for Opening a Window Based on the Temperature and CO2 Concentration in the Room

Kategorie: Vestavěné systémy

Zadání:

1. Seznamte se s metodami stanovení kvality ovzduší pomocí měření koncentrace CO2 a teploty.
2. Analyzujte změny kvality ovzduší při různých scénářích pobytu osob v místnosti pomocí soustavy senzorů měřících koncentraci CO2 a teplotu.
3. Navrhněte systém pro otevírání okna podle údajů získaných pomocí senzorů v předchozím bodu.
4. Navržený systém implementujte a ověřte jeho funkci v reálném prostředí.
5. Zhodnoťte dosažené výsledky a diskutujte možnosti dalšího rozšíření.

Literatura:

- Dle pokynů vedoucího.

Pro udělení zápočtu za první semestr je požadováno:

- Splnění bodů 1 až 3 zadání.

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

Vedoucí práce: **Tisovčík Peter, Ing.**

Vedoucí ústavu: Sekanina Lukáš, prof. Ing., Ph.D.

Datum zadání: 1. listopadu 2020

Datum odevzdání: 12. května 2021

Datum schválení: 30. října 2020

Abstrakt

Cílem práce je vytvořit systém pro udržování čerstvého vzduchu v obytné místnosti pomocí automatizovaného větrání, tak aby docházelo k co nejmenším tepelným ztrátám. Byla shromážděována a analyzována data z čidel vnitřní a venkovní teploty vzduchu, CO₂, relativní vlhkosti a stavu otevření okna. Následně byl vybrán vhodný algoritmus pro docílení požadovaných hodnot. Program dále obsahuje algoritmus pro predikci chování systému, tak aby ovládané spotřebiče (okno a topení) vhodně spolupracovaly.

Abstract

The purpose of this work is to enable an automated maintenance of fresh air in a room. Using automated ventilation, so the smallest possible heat losses occur. The data from sensors of indoor and outdoor temperature, CO₂, humidity, and window opening status have been collected and analyzed. Then a suitable algorithm has been selected to accomplish the required values. The program also contains an algorithm for predicting the system's behavior so the controlled appliances (window and heating) work together appropriately.

Klíčová slova

oxid uhličitý, CO₂, řízené větrání, výměna vzduchu, kvalita vzduchu, řízené vytápění, predikce, chytrá domácnost

Keywords

Carbon dioxide, CO₂, controlled ventilation, air exchange, air quality, controlled heating, prediction, smart home

Citace

JŮZA, Tadeáš. *Systém pro otevírání okna na základě teploty a koncentrace CO₂ v místnosti*. Brno, 2021. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Ing. Peter Tisovčík

System pro otevirání okna na základě teploty a koncentrace CO₂ v místnosti

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně pod vedením Ing. Petra Tisovčíka. Uvedl jsem všechny literární prameny, publikace a další zdroje, ze kterých jsem čerpal.

.....

Tadeáš Jůza
11. května 2021

Poděkování

Rád bych poděkoval svému vedoucímu práce Ing. Peterovi Tisovčíkovi za cenné rady při pravidelných konzultacích.

Obsah

1	Úvod	5
2	Měřené veličiny a hardware	6
2.1	Oxid uhličitý	6
2.2	Teplota	8
2.3	Relativní vlhkost	8
2.4	Raspberry Pi	9
2.5	Motor pro otevírání okna	10
2.6	Hlavice na topení	11
3	Strojové učení	12
3.1	Rozhodovací strom	14
3.2	Gradient boosted stromy	15
3.3	Neuronová síť	15
3.4	Logistická regrese	16
3.5	Metoda podpůrných vektorů	17
4	Analýza dat	18
4.1	Místnost	18
4.2	Data	18
4.3	Běžný denní cyklus	20
4.4	Speciální průběhy	21
5	Návrh systému	23
5.1	Uživatelské nastavení	23
5.2	Případy užití	24
5.3	Výběr rozhodovacího algoritmu	25
5.3.1	Tvorba datových sad	25
5.3.2	Výběr sady a algoritmu	26
5.4	Predikce	28
5.4.1	Datová sada pro predikci	28
5.4.2	Výběr sady a algoritmu	30
6	Implementace systému	32
6.1	Webové rozhraní	32
6.2	Komunikace zařízení	34
6.3	Databáze	35
6.4	Model pro otevírání a zavírání okna	36

6.5	Předpovídání otevírání a zavírání okna	36
6.6	Testování	37
6.7	Možná další rozšíření systému	39
7	Závěr	40
	Literatura	41
A	Obsah CD	43
B	Matice korelací	44
C	Predikce	48
C.1	CO ₂	48
C.2	Venkovní teplota	49
C.3	Vnitřní teplota	50
C.4	Relativní vlhkost	51

Seznam obrázků

2.1	Schema senzoru CO ₂ NDIR.	7
2.2	Mikropočítač Raspberry Pi doplnění radiovým přijímačem signálů z bezdrátových senzorů.	9
2.3	Hřebenový otevírač okenní ventilace.	10
3.1	Průběh koncentrace CO ₂ při jednoduché podmínce (horní), a při ideálním průběhu (dolní).	13
3.2	Ukázka množin dat a jejich korelací.	14
3.3	Ukázka rozhodovacího stromu.	15
3.4	Ukázka neuronové sítě.	16
3.5	Ukázka metody podpůrných vektorů.	17
4.1	Diagram základního rozhodovacího algoritmu, který byl v provozu během sběru dat.	19
4.2	Průběh hodnot základních měřených veličin během jednoho dne.	20
4.3	Průběh měřených hodnot během větrání v noci.	21
5.1	Matice korelací základních hodnot.	25
5.2	Matice korelací změny hodnot CO ₂ v pětiminutových intervalech během jedné hodiny.	29
5.3	Predikce koncentrace CO ₂ v místnosti při datové sadě s hodnotami 15 minut zpět.	30
6.1	Diagram případů užití systému.	33
6.2	Schéma průběhů komunikace jednotlivých zařízení.	34
6.3	Úvodní stránka webového rozhraní.	38
B.1	Matice korelací časových rozdílů relevantních měřených veličin.	45
B.2	Matice korelací změny hodnot venkovní teploty v pětiminutových intervalech během jedné hodiny.	46
B.3	Matice korelací změny hodnot teploty v místnosti v pětiminutových intervalech během jedné hodiny.	46
B.4	Matice korelací hodnot relativní vlhkosti v místnosti během jedné hodiny.	47
C.1	Predikce koncentrace CO ₂ v místnosti při datové sadě s hodnotami 10 minut zpět.	48
C.2	Predikce koncentrace CO ₂ v místnosti při datové sadě s hodnotami 20 minut zpět.	49
C.3	Predikce venkovní teploty při datové sadě s hodnotami 20 minut zpět.	49
C.4	Predikce venkovní teploty při datové sadě s hodnotami 40 minut zpět.	50

C.5	Predikce teploty v místnosti při datové sadě s hodnotami 20 minut zpět. . .	50
C.6	Predikce teploty v místnosti při datové sadě s hodnotami 40 minut zpět. . .	51
C.7	Predikce relativní vlhkosti v místnosti při datové sadě s hodnotami 10 minut zpět.	51
C.8	Predikce relativní vlhkosti v místnosti při datové sadě s hodnotami 20 minut zpět.	52
C.9	Predikce relativní vlhkosti v místnosti při datové sadě s hodnotami 30 minut zpět.	52

Kapitola 1

Úvod

Moderní technologie přináší do lidských životů čím dál více usnadnění převážně při opakujících se činnostech. V posledních letech dochází ke snižování finančních nároků a ke zvyšování dostupnosti systémů takzvané chytré domácnosti, které se starají o rutinní činnosti v běžné domácnosti. Jsou to například chytrá světla, která mění intenzitu a barvu světla podle denní doby. Tato práce se zabývá automatizovaným větráním pomocí otevírání okna, a udržením příjemného ovzduší v místnosti.

Cílem práce je vytvořit systém, který bude automaticky udržovat kvalitu vzduchu v místnosti v určitých mezích. Tyto meze si obyvatelé místnosti sami zvolí pomocí uživatelského rozhraní. Systém poté pomocí několika čidel změří hodnoty v místnosti a ve venkovním prostředí. Následně podle vytvořeného modelu rozhodne o nadcházející operaci. Dále systém bude umožňovat i uživatelské ruční ovládání jednotlivých komponent systému. Ovládací rozhraní bude také uživateli prezentovat data a rozhodnutí z minulosti a predikovaná rozhodnutí a hodnoty v budoucnosti. Posledním z hlavních cílů systému je úspora energií potřebných na vytápění místnosti, které systém docílí díky znalostí o stavu otevření okna a ovládání elektronické hlavice na topení.

V kapitole *Měření veličiny a hardware* 2 jsou popsány jednotlivé měřené veličiny, jejich vliv na lidský organismus a metody jejich měření. Také se zde nachází popis dalších hardwarových komponent, které jsou potřeba pro zajištění požadované funkce systému. V následující kapitole *Strojové učení* 3 jsou teoreticky popsány základní typy rozhodovacích algoritmů, z kterých bude následně vybrán nejlepší algoritmus pro jednotlivé problémy. Dále v kapitole *Analýza dat* 4 je popsána místnost, ve které se měření provádí a také je zde seznámení s běžným režimem pobytu lidí v místnosti. Za popisem následuje analýza dlouhodobě sbíraných dat, popis běžného denního cyklu i méně obvyklých situací. Kapitola *Návrh systému* 5 popisuje návrh systému, jaká nastavení bude moci uživatel upravovat. Podrobněji jsou zde také popsány jednotlivé případy užití celkového systému. Dále se zde popisuje tvorba datových sad a výběr z různých algoritmů, jak už pro model rozhodující o otevírání a zavírání okna tak i pro predikční modely. V kapitole *Implementace systému* 6 je popsána implementace jednotlivých částí systému, jaké technologie se využívají a jak se jednotlivé části programu chovají po čas běhu systému. V kapitole jsou také dále popsána další možná rozšíření, která by bylo možné implementovat v budoucnosti. Také je zde popsáno testování cílového systému a jeho chování při nasazení do reálného provozu. V poslední kapitole *Závěr* 7 jsou popsány dosažené cíle a zhodnocena celková funkcionalita systému.

Kapitola 2

Měření veličiny a hardware

V této práci se zabývám řízením kvality vzduchu v běžné obytné místnosti, práce se nezabývá využitím komplexní vzduchotechniky používané pro výměnu vzduchu především v kancelářských prostorách. Pro umožnění výměny vzduchu v místnosti bylo zvoleno motorem otevírané ventilační okno.

Nejjednodušší způsob pravidelného větrání místnosti je řídit otevírání okna podle časového plánu. Tato metoda však nereflktuje venkovní teplotní podmínky. Proto může dojít v chladném období k nežádoucímu poklesu teploty v místnosti a naopak v teplých dnech se zbytečně nevyužívá možnost delšího větrání. Lepších výsledků se dosáhne řízením ventilace podle vnější teploty. I v tomto případě však může docházet ke zbytečnému větrání v chladném období, například když v bytě nikdo není a dochází tím ke zbytečným ztrátám tepla. Pro odstranění těchto nedostatků bylo k měření teploty přidáno zjišťování obsahu CO_2 .

2.1 Oxid uhličitý

Oxid uhličitý je při běžných podmínkách plyn, který se vyskytuje v naší atmosféře. Nemá žádnou barvu ani zápach a je těžší než vzduch. Vzniká při spalování s dostatkem kyslíku. Chemický vzorec je CO_2 , z toho plyne, že molekula je tvořena jedním atomem uhlíku a dvěma atomy kyslíku [16].

Ve venkovním prostoru se koncentrace CO_2 pohybuje mezi hodnotami 0,035 % - 0,045 % (350 ppm - 450 ppm). V nízko položených místech ve městech je koncentrace vyšší, na druhou stranu v přírodě je nižší. V lidmi vydechovaném vzduchu se koncentrace pohybuje okolo 4 % (40 000 ppm) [10]. Při pobytu v prostorách, kde je zvýšená koncentrace CO_2 , dochází ke změně kyselosti krve. Ta se stává kyselější (snižuje se její pH) a klesá její schopnost transportu kyslíku, jelikož hemoglobinu klesá schopnost na sebe vázat kyslík. To způsobuje špatné zásobování všech orgánů kyslíkem.


Vliv koncentrace CO_2 na lidský organismus [10]:

- 350 - 400 ppm – úroveň venkovního prostředí,
- do 1 000 ppm – doporučená úroveň CO_2 ve vnitřních prostorách,
- 1 200 - 1 500 ppm – doporučená maximální úroveň CO_2 ve vnitřních prostorách,
- 1 500 - 2 000 ppm – nastávají příznaky únavy a snižování koncentrace,
- 2 000 - 5 000 ppm – nastávají možné bolesti hlavy,

- 5 000 ppm – maximální bezpečná koncentrace bez zdravotních rizik, způsobuje nevolnost a zvýšený tep,
- 15 000 ppm – dýchací potíže,
- 40 000 ppm – možná ztráta vědomí.

Kvalita vnitřního prostředí je dána hygienickými předpisy. Pro rodinné a bytové domy je závazná především vyhláška č. 268/2009 Sb., o technických požadavcích na stavby. V ní je v § 11 odstavec 5 uvedeno: „Pobytové místnosti musí mít zajištěno dostatečné přirozené nebo nucené větrání a musí být dostatečně vytápěny s možností regulace vnitřní teploty. Pro větrání pobytových místností musí být zajištěno v době pobytu osob minimální množství vyměňovaného venkovního vzduchu $25 \text{ m}^3 \cdot \text{h}^{-1}$ na osobu, nebo minimální intenzita větrání $0,5 \text{ h}^{-1}$. Jako ukazatel kvality vnitřního prostředí slouží oxid uhličitý CO_2 , jehož koncentrace ve vnitřním vzduchu nesmí překročit hodnotu 1 500 ppm.“ [18].

Detektory oxidu uhličitého použitelné v domácím prostředí jsou dostupné teprve v posledních letech. Dříve vyráběné laboratorní a průmyslové senzory byly pro domácí použití příliš drahé a také složité k ovládání. I dnes patří senzor CO_2 k nejdražším součástem „Chytré domácnosti“. Existují dvě možnosti detekce CO_2 , elektrochemická detekce nebo pomocí NDIR. Čidlo pro elektrochemickou detekci obsahuje speciální topné tělíčko a elektrochemickou cestou analyzuje koncentraci plynů. Senzor proto spotřebovává větší množství elektrické energie s vyšším napětím a bezdrátová čidla s tímto principem detekce CO_2 dosahují krátké výdrže provozu na baterii. Alternativou je systém NDIR senzorů – Nondispersive infrared sensor (Nedisperzivní infračervená čidla). V nich se měří koncentrace CO_2 pomocí útlumu infračerveného záření určité vlnové délky. Senzor ve speciální komoře každých pár sekund rozsvítí IR lampu a detektor na opačné straně komory změří útlum světla, který odpovídá koncentraci CO_2 , viz obrázek 2.1.



Obrázek 2.1: Schema senzoru CO_2 NDIR.

Právě zařízení s tímto NDIR senzorem bylo využito, a to konkrétně CO_2 modul od firmy BigClown¹. Tento senzor disponuje přesností měření $\pm 50 \text{ ppm}$, při vyšších hodnotách maximálně $\pm 3\%$ z měřené hodnoty. Senzor je schopen měřit hodnoty v rozsahu 0 - 10000 ppm. Spotřeba samotného měřicího senzoru je $61 \mu\text{A}$ při měření koncentrace CO_2 jednou za minutu.

¹<https://shop.bigclown.com/co2-module/>

2.2 Teplota

Teplota je další veličina kterou jde regulovat větráním, snižovat klimatizací, případně v zimně zvyšovat vytápěním. Teplota těla zdravého člověka se pohybuje do 37 °C. Teplota ve středu těla je větší než teplota na kůži a to o 4 °C [12].

Ideální teplota vzduchu pro člověka, v klidových podmínkách, který není oblečen je 28 °C. Ideální teplota v obytných místnostech dle norem ČSN je 20 °C [5]. Pocitová ideální teplota během dne kolísá a mění se podle několika faktorů, jako je například činnost prováděná v místnosti. Při spánku je zpravidla příjemnější nižší teplota vzduchu v místnosti. Sama tělesná teplota během dne kolísá o 0,5 - 0,7 °C a právě během noci a spánku se snižuje na své minimum [7].

Pro měření teploty pomocí elektrických zařízení se zpravidla využívá proměnlivého odporu vodiče nebo polovodiče. Protože pro měření CO₂ bylo využito zařízení popsané výše, které má kromě CO₂ čidla i čidlo pro měření teploty, pro měření venkovní teploty byl zvolen senzor od stejné společnosti. Na základní desce měřidla je i možnost umístit přídatné senzory takzvané Tagy. Byl využit Tag² s teplotním senzorem TMP112. Tento senzor disponuje přesností měření v závislosti na teplotě takto:

- ± 0,1 °C při 25 °C
- ± 0,25 °C v rozmezí 0 °C až 65 °C
- ± 0,5 °C v rozmezí -40 °C až 125 °C

Tag také převádí analogovou hodnotu na digitální hodnotu, která je následně přenášena pomocí sběrnice I²C na základní desku zařízení, která rozhodne zda se nově získaná hodnota odešle dále [1].

2.3 Relativní vlhkost

Vlhkost je další veličina, kterou je vhodné měřit v ovzduší v místnosti. Lidské tělo nemá dobrou schopnost vnímat aktuální vlhkost v místnosti, což způsobuje, že nepozná že je v prostoru, kde je hladina nevyhovující [14]. Samozřejmě extrémní hodnoty vlhkosti jde rozeznat, avšak už ne hodnoty které nejsou extrémní, ale již nejsou pro člověka vhodné.

Relativní vlhkost vzduchu se vyjadřuje jako poměr mezi aktuálním množstvím vody ve vzduchu a množstvím vody, které by měl vzduch o stejném tlaku a teplotě při plném nasycení vodou. Množství vody potřebné pro plné nasycení vzduchu je závislé především na teplotě. Chladnému vzduchu stačí pro plné nasycení méně vody než teplému, například vzduch o teplotě 0 °C je schopen pojmout maximálně 4,84 g vody na 1 m³ vzduchu, zatímco při 25 °C to je 23,1 g [8].

Limity relativní vlhkosti v interiéru jsou dány vládním nařízením č. 361/2007 Sb. kde je uvedena dolní hranice 30 %, ale zároveň doporučení udržovat dolní hranici 40 %. Ideální relativní vlhkost vzduchu v obytných místnostech, jako ložnice a obývací pokoj, je podle norem ČSN 60 % [5].

K měření vlhkosti se využívá kapacitní princip měření, kdy se podle vlhkosti měřeného prostředí mění kapacita senzoru, která je následně měřena. Bylo využito možnosti připojit

²<https://shop.bigclown.com/temperature-tag/>


další Tag³ na základní desku CO₂ senzoru, který měří vlhkost okolí právě kapacitním principem. Senzor disponuje přesností $\pm 3\%$ v rozmezí relativní vlhkosti 20 % až 80 %, je však schopen měřit v plném rozsahu, tedy 0 % až 100 %. Mimo rozmezí 20 % až 80 % se však zhoršuje přesnost měření, výrobce ale neuvádí konkrétní chybovost senzoru.

2.4 Raspberry Pi

Existuje několik variant zařízení, která jsou vhodná pro nepřetržitý provoz v běžných domácnostech. Jednou z možností je Raspberry Pi, které vyhovuje jak svým výkonem, tak cenou zařízení i spotřebou elektrické energie při trvalém běhu. Alternativou je například Arduino, které však zpravidla nedisponuje takovým výkonem a softwarovými možnostmi jako Raspberry Pi. Velká výhoda Raspberry Pi je operační systém odvozený z Debianu.

V roce 2020 se na trhu objevila nová verze Raspberry Pi 4, která se prodává v několika variantách výbavy. Nejvyšší verze s 8 GB RAM už se dá použít téměř jako běžný osobní počítač. K účelu této práce je bohatě dostačující starší verze Raspberry Pi 3. Tato verze má nižší veškeré hardwarové parametry, ale také nižší spotřebu a cenu.

Raspberry Pi Model 3 B+ je vybaven čtyřjádrovým 64 bitovým ARM procesorem, 1 GB RAM a napájením prostřednictvím microUSB konektoru. Na desce mikropočítače jsou čtyři USB 2.0 konektory pro připojení periferii, 1Gb ethernet port pro připojení do místní sítě a HDMI port k přímému připojení monitoru. Dále obsahuje možnost bezdrátového připojení prostřednictvím WiFi 802.11ac a Bluetooth 4.2. Pro možnost komunikace s bezdrátovými senzory byl Raspberry Pi doplněn rádiovým modulem pro komunikaci na frekvenci 868/915 MHz, připojeným do USB portu a vybaveným čipem pro šifrovanou komunikaci s až 32 bezdrátově připojenými zařízeními, viz obrázek 2.2.



Obrázek 2.2: Mikropočítač Raspberry Pi doplnění radiovým přijímačem signálů z bezdrátových senzorů.

Jako hlavní úložný prostor na Raspberry Pi je microSD karta. Běžné karty nejsou dimenzovány na časté zápisy dat, například provozování databáze. Proto je nutné použít kartu, která s neustálým zápisem počítá. Tyto karty jsou převážně určeny do bezpečnostních kamer a jsou dražší než běžné karty.


³<https://shop.bigclown.com/humidity-tag/>

2.5 Motor pro otevírání okna

Motory určené na montáž na okno se vyrábí v několika různých provedeních. Většinou jsou však určeny pro veřejné prostory pro řešení požárního odvětrávání nebo pro otevírání špatně dostupných střešních oken ve výrobních halách nebo například ve sklenících. Nabízí se různě řešené pohonné mechanismy, například řetězové, lineární a ramenné otvírače.

Jejich společnou vlastností je poměrně vysoká hlučnost. Pro noční otevírání v ložnici případně v přilehlých místnostech je však nutný tichý provoz. Další možné řešení je použití šroubovicových nebo hřebenových otvíračů. Ty jsou výrazně tišší, a pokud mají regulovatelnou rychlost motoru, jde jejím snížením hlučnost dále omezit.

Většina prodávaných elektrických otvíračů oken pro komerční prostory je určena pro trvalé namontování na rám okna. Pokud potřebujeme okno otevřít ručně, například pokud elektricky otevíráme pouze výklopnou ventilaci a ručně chceme okno plně otevřít, musíme otevírací rameno alespoň částečně demontovat. V internetových nabídkách prodejců se na předních místech vyhledávačů umísťuje česká firma Vektiva se svým elektrickým otvíračem okenní ventilace Smarwi [4]. Jedna z výhod tohoto systému je, že se jedná o kompletní systém, který je schopen komunikovat pomocí vlastního API, případně je možno využívat MQTT příkazy. Veškerá komunikace probíhá přes WiFi. Výrobek je také designově přizpůsoben pro použití v domácnostech.



Obrázek 2.3: Hřebenový otevírač okenní ventilace.

Smarwi je určen k elektronicky řízenému otevírání oken v režimu ventilace. Použit jde na okna s funkcí dovnitř vyklápěné ventilace (Tilt-Turn Windows), která jsou v České republice běžná. Pohyb okenního křídla zajišťuje velmi tichý a spolehlivý krokový motor. Otvírač sestává ze tří částí. Část s motorkem a veškerou elektronikou se připevňuje do prostřed horní části otevíraného (pohyblivého) rámu křídla okna. Touto částí prochází druhá část, jednoduchý hřeben připevněný k pevnému vnějšímu rámu. Poslední část je tlačítko, které se používá k přímému otevření nebo zavření okna místo kliky. Tlačítko je zároveň bezpečnostní prvek, kterým můžeme motor v pohybu okamžitě zastavit. Tlačítko je drátově připojené k motoru a do elektrické zásuvky. Plastový blok s motorkem obsahuje také veškerou elektroniku, viz obrázek 2.3.

2.6 Hlavice na topení

Topení jsou v domácnostech umístěny převážně pod okny. V zimním období, kdy se obytné prostory vytápí, dochází během větrání k velké ztrátě energie, vlivem odvětrání čerstvě ohřátého vzduchu stoupajícího od radiátoru. Pokud má radiátor termostatický ventil dochází k přetápění místnosti, které je způsobeno ochlazením ventilu čerstvým vzduchem proudícím z okna.

Všem těmto ztrátám energie se dá předejít ovládním výkonu topení. Na trhu existuje několik různých hlavice na topení, které umožňují ovládnutí výkonu topení. Často však komunikují pouze se základnou a nelze je propojit s prvky od jiných výrobců. Některé hlavice dokonce vůbec nekomunikují a řídí se pouze senzorem teploty, který mají umístěný ve svém těle. I tak je na trhu zastoupeno několik různých hlavice, které se dají připojit do libovolného systému. Pro připojení jsou využívány různé technologie jako: WiFi, bluetooth, Z-Wave a další.

Jedním z výrobců dálkově řízených termostatických hlavice s inteligentním ovládním je firma NETATMO [3]. Hlavice má dobrý moderní vzhled a její software umožňuje několik zajímavých možností, například ruční upravení intenzity vytápění přímo na hlavici, které se po uplynutí určité doby vrátí do standardního režimu. Nevýhodou této hlavice je, že komunikuje pouze s firemní centrálou. Po nutné registraci na stránkách výrobce se zpřístupní rozsáhlé možnosti ovládnutí hlavice radiátorů přes webové rozhraní. K dispozici je také samostatná aplikace pro mobilní zařízení. Výrobce umožňuje vzdálené ovládnutí ventilů také přes API, což umožňuje využít i vlastní aplikaci.

Kapitola 3

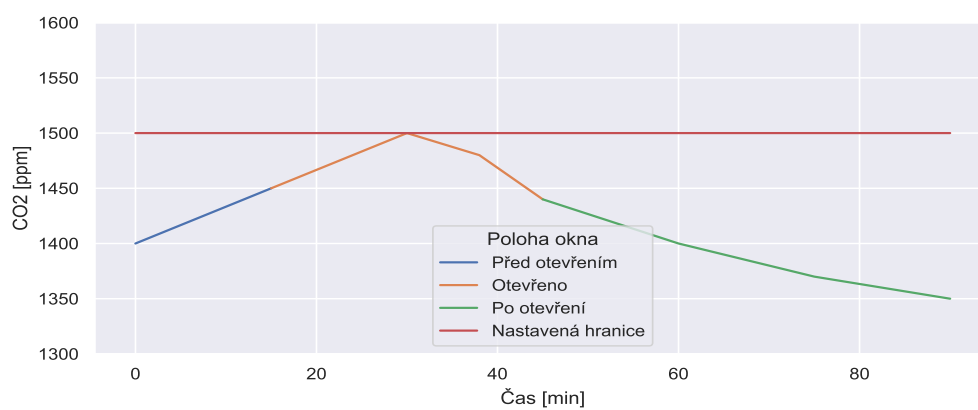
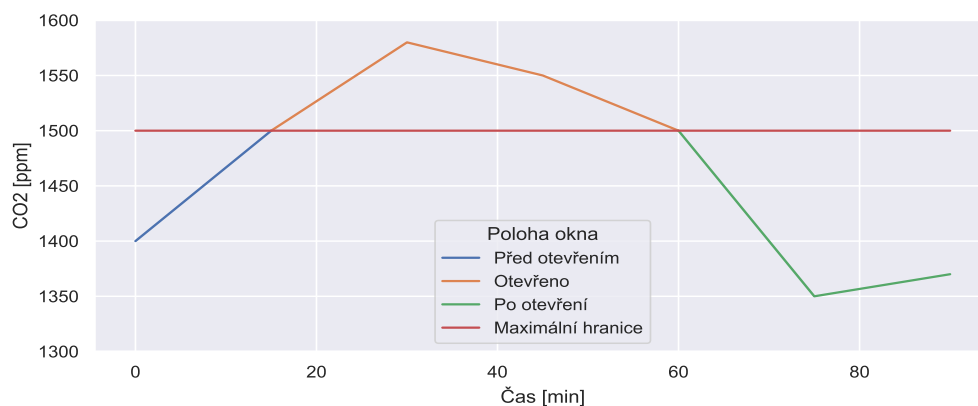
Strojové učení

Strojové učení je oblast, která spadá pod umělou inteligenci. Cílem strojového učení je vytvořit model, který automaticky zlepšuje svoji funkčnost trénováním, případně prací nad daty. Mnoho aplikací je snazší trénovat nad ukázkami vstupních a výstupních dat, než manuálně programovat chování pro všechny možné vstupní varianty [13].

Základní rozdělení možností strojového učení je podle toho, jak se algoritmus učí z dat získat správný výsledek. používá se buďto metoda strojového učení s učitelem nebo strojové učení bez učitele.

- **Strojové učení s učitelem** - Algoritmy strojového učení s učitelem se používají nejčastěji. U tohoto modelu plní datový expert funkci průvodce, který učí algoritmus, jaké závěry má učinit. Při učení s učitelem je algoritmus trénován datovou sadou, která již má předdefinovaný výstup. Mezi příklady strojového učení s učitelem patří algoritmy, jako je lineární a logistická regrese, klasifikace s více třídami a podpůrné vektory.
- **Strojové učení bez učitele** - Strojové učení bez učitele využívá nezávislejší přístup, ve kterém se počítač učí rozpoznat složité procesy a vzorce bez toho, aby mu člověk poskytoval bližší trvalé vedení. Strojové učení bez učitele je založeno na neoznačených datech bez předem definovaného výstupu. Mezi příklady algoritmů strojového učení bez učitele patří shluková analýza s k-průměry a analýza hlavních a nezávislých komponent.

Řízení otevírání okna by bylo možné provádět pomocí několika jednoduchých podmínek. Takové řízení je reprezentováno na obrázku 3.1 v horním grafu. Jelikož pohyb vzduchu v místnosti je většinou velmi slabý, po otevření relativně malé ventilace dochází k výměně vzduchu pomalu. Díky tomu se často stává, že i nějaký čas po otevření okna dochází k dalšímu stoupání koncentrace CO_2 . Tak může dojít k překročení nastaveného limitu obsahu oxidu uhličitého.



Obrázek 3.1: Průběh koncentrace CO₂ při jednoduché podmínce (horní), a při ideálním průběhu (dolní).

Lepší řešení by bylo, pokud by nastavená hranice byla hranice maximální. Toho je však složité docílit, protože každá místnost i rychlost výměny vzduchu je jiná. Strojové učení nám však může pomoci. Při prvním nasazení bude průběh pravděpodobně podobný hornímu grafu. Zaznamenáváním dat při běhu systému a úpravami rozhodovacího modelu se však časem dostane do ideálního průběhu, reprezentovaném na dolním grafu. Zde se jednak snížila maximální dosažená koncentrace CO₂, ale také se zkrátila doba, po kterou bylo okno otevřeno.


V následujícím textu jsou popsány principy fungování některých požívaných rozhodovacích algoritmů a metod pro analýzu hodnot.

Matice korelací

Matice korelací je matice obsahující hodnoty korelací mezi jednotlivými atributy. Matice je symetrická podle hlavní diagonály a hodnoty na této diagonále označují korelaci atributu se sebou samým. Hodnoty korelací se zpravidla vypočítávají pomocí Pearsonova korelačního koeficientu. Takto vypočtená korelace nabývá hodnoty z intervalu $\langle -1,1 \rangle$.

$$r_{X,Y} = \frac{\sum_{i=1}^n (X_i - \bar{X}) * (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 * \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (3.1)$$

V rovnici 3.1 je $r_{X,Y}$ korelační koeficient v intervalu $\langle -1,1 \rangle$, X a Y jsou množiny hodnot, n udává počet hodnot v množině a \bar{X} / \bar{Y} je aritmetický průměr hodnot z množiny [11].

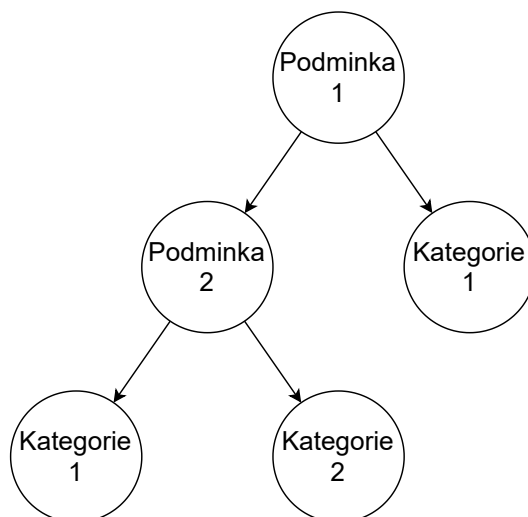


Obrázek 3.2: Ukázka množin dat a jejich korelací.

Na obrázku 3.2 lze vidět tři korelace a jejich grafická reprezentace. Na levé straně lze vidět data která mají korelační koeficient roven 1, mezi takovými daty platí přímá úměra. Na prostředním obrázku můžeme vidět data jejíž korelační koeficient nabývá hodnoty 0, data jsou na sobě tedy nezávislá. Na pravé straně je ukázka záporné korelace -1, kdy mezi daty platí nepřímá úměra.

3.1 Rozhodovací strom

Jedním ze základních rozhodovacích algoritmů, jehož principů se využívá i v pokročilejších metodách, je rozhodovací strom. Rozhodovací strom se skládá z uzlů, každý uzel, kromě počátečního, má nadřazený uzel. A každý uzel, kromě koncových má dva podřízené uzly. Kromě koncových uzlů, které obsahují výsledek v podobě kategorie do které se vyhodnocovaná data přiřazují, obsahuje každý uzel podmínku, podle které se volí na který uzel se má při průchodu pokračovat. Podmínky v jednotlivých uzlech jsou voleny tak, aby co nejvíce rozdělávaly typicky vyhodnocovaná data.



Obrázek 3.3: Ukázka rozhodovacího stromu.

Na obrázku 3.3 lze vidět jednoduchý rozhodovací strom. Jak lze vidět, jedná se o metodu, kterou lze jednoduše a přehledně graficky reprezentovat rozhodovací proces, díky čemuž je velice oblíbená [9].

3.2 Gradient boosted stromy


Gradient boosted metody obecně využívají soubor slabších predikčních metod. Metoda se používá převážně pro řešení regresivních a klasifikačních problémů. V tomto případě metoda využívá několika rozhodovacích stromů. Jednotlivé stromy mají omezenou velikost, počet úrovní uzlů [17]. Každý z těchto rozhodovacích stromů má ohodnocené konečné uzly (listy) určitou hodnotou. Po vyhodnocení všech rozhodovacích stromů jsou hodnoty patřící výsledným koncovým uzlům zpracovány rovnicí:

$$f(x) = z + \sum_{i=0}^n (y_i * r_i) \quad (3.2)$$

Kde z je průměrná hodnota výsledných hodnot, neboli průměrná hodnota výsledných hodnot v trénovací množině dat. Počet rozhodovacích stromů je n , r_i je hodnota výsledného listu stromu pro konkrétní běh vyhodnocování a y_i je váha jednotlivých rozhodovacích stromů.

3.3 Neuronová síť

Jedná se o algoritmus, který má za vzor biologické neuronové sítě. Neuronové sítě se používají v případech, kdy nejsme schopni sestavit matematický model, nebo je sestavený model příliš složitý. Základním prvkem sítě jsou neurony, která se řadí do vrstev.



Obrázek 3.4: Ukázka neuronové sítě.

Neurony mají definovaný nenulový počet vstupů a jeden výstup. Pro každý vstup má neuron specifickou váhu, hodnotu která udává jak je vstup významný pro výstup neuronu. Při vyhodnocování jsou jednotlivé vstupní hodnoty vynásobeny hodnotou váhy daného vstupu, dále jsou tyto hodnoty sečteny a výsledek tohoto součtu je převeden pomocí funkce na výslednou hodnotu, která spadá do oboru hodnot možných výsledků neuronu. Výsledná hodnota bývá zpravidla v rozsahu $\langle 0,1 \rangle$, případně $\langle -1,1 \rangle$. Pro převod se může využívat různých funkcí ať už lineárních či nelineárních [6].

Na obrázku 3.4 lze vidět jednoduchou neuronovou síť. Počet neuronů v jednotlivých vrstvách a počet skrytých vrstev je volitelný a jediný limit je zde kladen hardwarem a časovými nároky na dobu vyhodnocování. Na obrázku je také patrné, že jednotlivé neurony mají základní (nulový) vstup, na obrázku reprezentovaný šipkou shora, který udává základní hodnotu, ze které se vychází při výpočtu výsledné hodnoty neuronu.

3.4 Logistická regrese

Logistická regrese umožňuje analýzu dat a predikci závislé binární hodnoty. Pokud predikovaná hodnota nenabývá binárních hodnot, lze hodnotu zjistit z poměru binárních výsledků po několika měřeních se stejnými vstupními veličinami. Metoda se využívá například pro predikci pravděpodobnosti vzniku chyby zařízení ve výrobní lince.

Tato metoda se používá pro zjištění pravděpodobnosti děje v závislosti na hodnotě spojité proměnné. Pro výpočet pravděpodobnosti se využívá rovnice:

$$\log \frac{\pi(x)}{1 - \pi(x)} = \alpha + \beta x \quad (3.3)$$


Levá strana výrazu 3.3 se nazývá logit. Π představuje binomické rozdělení náhodné proměnné x . Hodnoty α a β jsou regresivní koeficienty, které se odhadují pomocí metody nejmenších čtverců. Vzorec je aplikovatelný pro jednodimenzionální proměnnou x , pro více-dimenzionální $\mathbf{x} = (x_1, \dots, x_m)$ lze aplikovat vzorec:

$$\pi(\mathbf{x}) = \frac{\exp(\alpha + \sum_{i=1}^m \beta_i x_i)}{1 + \exp(\alpha + \sum_{i=1}^m \beta_i x_i)} \quad (3.4)$$

Počet dimenzí v rovnici 3.4 je dán neznámou m . Regresivní koeficient β musí být zjišťován pro každou dimenzi \mathbf{x} , zatímco koeficient α je zjišťován pouze jednou pro všechny dimenze \mathbf{x} [2].

3.5 Metoda podpůrných vektorů

Metoda podpůrných vektorů je metoda, jejíž hlavním cílem je klasifikace dat. Metoda v trénovacích datech vyhledává nadrovinu, která co nejlépe rozděluje prostor podle požadovaných hodnot [15].



Obrázek 3.5: Ukázka metody podpůrných vektorů.

Na obrázku 3.5 lze vidět prostor s dvěma typy bodů. Metoda podpůrných vektorů tento prostor rozděluje nadrovinou a to tak, aby vzdálenost od nejbližších bodů jednotlivých skupin byla stejná a zároveň co největší. Čím větší je mezera mezi skupinami dat, tím menší je chybovost u predikce.

Trénování modelu tedy probíhá s daty ve tvaru $(\vec{x}_1, y_1), (\vec{x}_2, y_2), \dots, (\vec{x}_n, y_n)$, kde \vec{x}_n je vektor se vstupními hodnotami a y_n je výsledná hodnota. Poté je pomocí těchto dat zjištěna optimální poloha nadroviny. Při klasifikaci dochází k vyhodnocování jednotlivých vstupů, kdy podle toho, na jaké straně nadroviny se nachází, získávají výslednou hodnotu [15].

Kapitola 4

Analýza dat

Analýza získaných dat a jejich případná úprava do konzistentního stavu je jednou z nejdůležitějších částí při tvorbě a trénování rozhodovacího systému. Je třeba ověřit vypovídající hodnotu jednotlivých měřených veličin a jak rychle se změny okolí projeví na měření získávaných hodnotách. Také je třeba odhalit a odstranit data, která obsahují chybné údaje.

4.1 Místnost

Zde je popsána analýza dat měřených v obytné místnosti o rozměrech 3,5 x 3,5 m a objemu 32 m³. Místnost je součástí bytu v panelovém domě a je dvěma dveřmi propojena se sousedními místnostmi. Místnost má s venkovním prostředím společnou jen jednu stěnu, směrem na sever, ve které jsou umístěny 3 okna ve starých dřevěných rámech. Okno, které je ovládáno systémem, má velikost 150 x 58 cm a je pomocí motoru otevíráno do pozice ventilace. V této pozici je horní hrana okna odkloněna pomocí motoru od rámu o 11 cm. Senzor pro snímání hodnot CO₂ a teploty je umístěn na druhé straně místnosti vedle dveří do další místnosti, a to tak, že minimální vzdálenost od okna činí 3,3 m. Po několika zkušebních dnech měření bylo zvolené umístění na protější stěně od okna ve výšce 170 cm. Výška nad zemí je důležitá z toho důvodu, že CO₂ je nepatrně těžší než vzduch, proto se v klidovém prostředí (v noci) hromadí u země.

Místnost slouží jako ložnice a obývací pokoj. V noci zde přespávají dva lidé. Během všedního dne obyvatelé spí mezi 23:00 a 6:30, poté odchází mimo byt a vrací se zase domů kolem 15 - 17 hodiny, mezi těmito časy je místnost zpravidla prázdná. Po příchodu se obyvatelé věnují rozdílným činnostem, nejčastěji domácím pracím a práci na počítači. Víkendové využití místnosti může být značně různé, od celodenní nepřítomnosti obyvatel po rodinné sešlosti více lidí.

4.2 Data

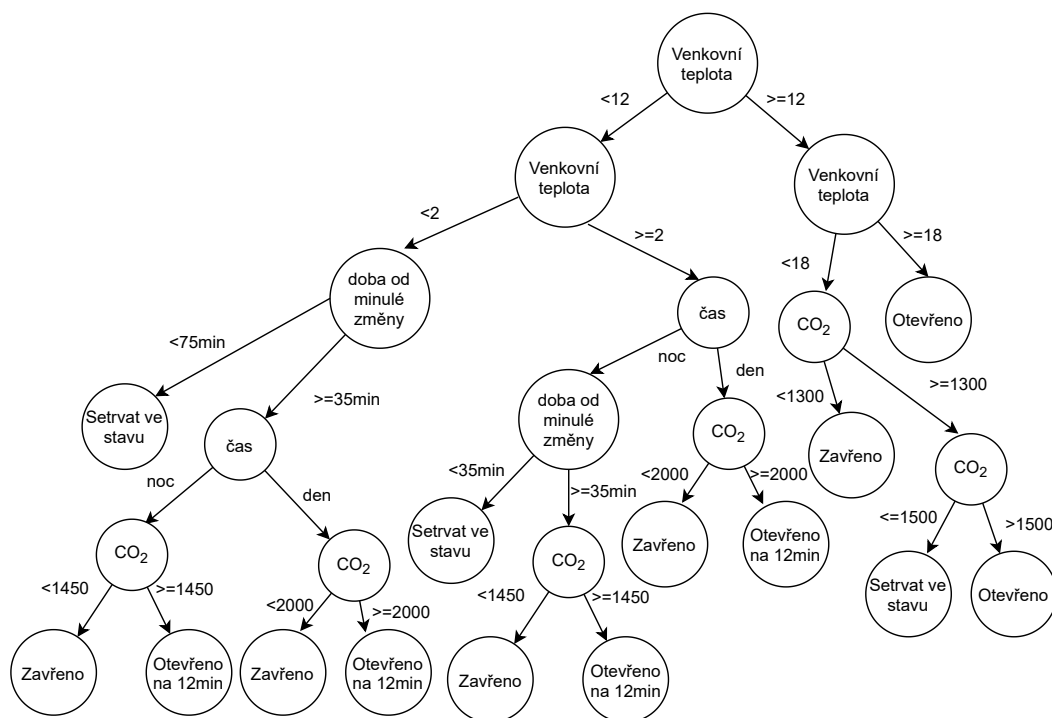
Od 13. října 2020 jsou ukládány informace o změně stavu okna, tedy o tom, zda se zavírá či otevírá. Tyto data jsou ukládána samostatně a za dobu běhu záznamu bylo uloženo více jak 2 200 změn stavu okna. V bezdrátových senzorech popsaných výše se měřená veličina odečítá z detektoru každou minutu. Hodnota se však odesílá pouze pokud dojde k významné změně oproti předchozímu odečtu, nejpozději však po 15 minutách. Protože každý senzor pracuje nezávisle na ostatních, dochází k odesílání jednotlivých údajů v různých časech. Tato data shromážděná v mezipaměti se v pevném časovém intervalu 5 minut ukládají

do tabulky v databázi. Čili databáze obsahuje ke každému časovému intervalu hodnoty změřených teplot uvnitř a venku, koncentrace CO₂, tlak a relativní vlhkost v místnosti. Databáze s těmito daty obsahuje více než 31 000 záznamů každé veličiny. Základní přehled naměřených hodnot lze vidět v tabulce 4.1.

Veličina	Minimální hodnota	Maximální hodnota	Průměr	Střední hodnota	Směrodatná odchylka
CO ₂ [ppm]	350,0	3 157,0	1 461,8	1353,3	434,3
Teplota v místnosti [°C]	21,1	24,7	23,4	23,2	0,7
Teplota venku [°C]	-2,2	34,1	8,4	7,2	4,9
Tlak [Pa]	95 627,3	100 261,3	98 575,2	98 224,0	957,4
Relativní vlhkost [%]	41,9	71,5	59,5	59,6	4,3

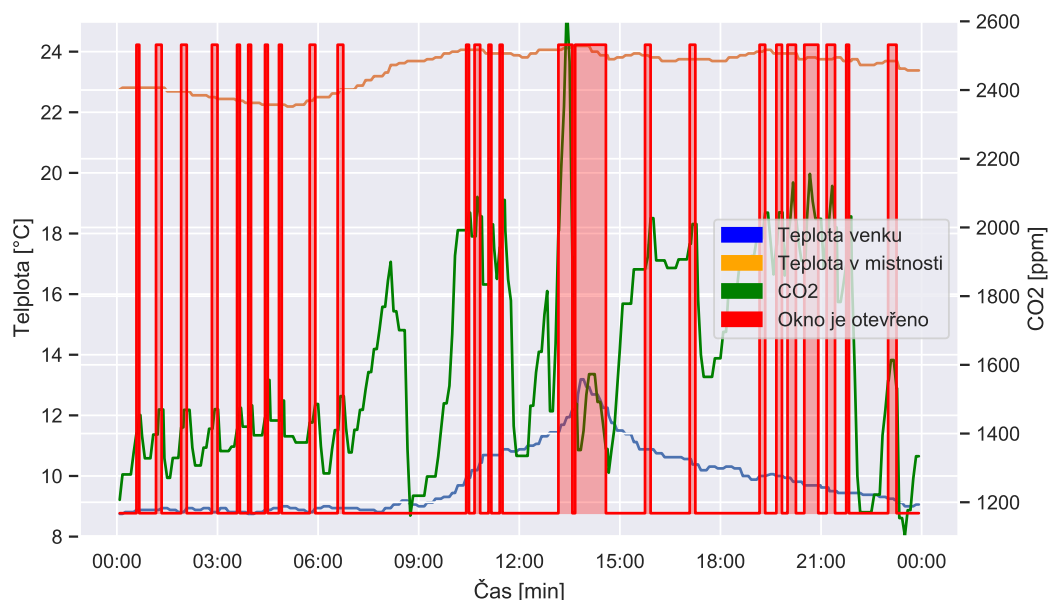
Tabulka 4.1: Základní přehled uložených dat.

Systém od tohoto dne i automaticky otevírá okno. Rozhodování zda se má okno otevřít lze popsat diagramem na obrázku 4.1. Jedná se o jednoduchý systém, vytvořený na základě ideálních hodnot, který byl dále upravován během prvních dnů provozu do stávající podoby. Tato podoba není ideální, nicméně nevznikají přehnaně extrémní situace. Kromě rozhodnutí o změně stavu okna získaných z tohoto stromu jsou ukládány i požadavky uživatelů pro změnu stavu okna. Změnu si uživatel může vyžádat tlačítkem umístěným u okna na kabelu, kterým se napájí motor na okně. Případně přes jednoduchou webovou stránku, která byla vytvořena v rámci zaznamenávajícího systému. Na webové stránce je i možnost zadat časový interval, po který bude okno nastavený stav držet.



Z dat která jsou měřena a ukládána se dají vyloučit data reprezentující tlak v místnosti, tato data nemají vliv na výsledek při rozhodování, zda se má okno otevřít. Další hodnota, která také nepodává relevantní údaje, je vnitřní teplota. Při otevření okna chladný čerstvý vzduch ovlivňuje teplotu senzoru příliš pomalu. Také díky vysoké tepelné setrvačnosti stěn místnosti nepadává senzor dostatečně aktuální stav teploty. Dlouhodobě se vnitřní teplota pohybuje v přijatelných hodnotách bez náhlých výkyvů v rozmezí hodnot 21 až 24 °C, což lze vidět z dat v tabulce 4.1. Tato veličina je z těchto důvodů vyloučena ze systému popsaného diagramem na obrázku 4.1, z komplexnějších rozhodovacích systémů by však už vyloučena být neměla, neboť může upozornit na nestandardní situace. Zbylé měřené veličiny, tedy teplota venku, relativní vlhkost a CO₂, jsou základními veličinami podle kterých je dobré se rozhodovat pro otevření okna.


4.3 Běžný denní cyklus



Obrázek 4.2: Průběh hodnot základních měřených veličin během jednoho dne.

Hodnoty, kterých nabývají veličiny během běžného dne, lze vyčíst z grafu na obrázku 4.2. Z grafu lze vyčíst, že nejlepší stability CO₂ a vnitřní teploty je docíleno v noci, zatímco přes den dochází k velkým výkyvům zvláště u CO₂. To je způsobeno relativně častými změnami počtu lidí v místnosti a prouděním vzduchu mezi sousedními místnostmi dveřmi.

Dále zde lze zjistit, že k poklesu CO₂ může dojít i bez větrání kontrolovaným oknem, a to větráním oknem umístěným ve vedlejší místnosti.



Obrázek 4.3: Průběh měřených hodnot během větrání v noci.

Na obrázku 4.3 lze blíže vidět průběh hodnot během dvou cyklů větrání v noci. Zde je vidět, že senzoru pro měření CO₂ trvá značnou dobu, než zaznamená změnu koncentrace CO₂ ve vzduchu. To je způsobeno několika faktory:

- Senzor je na druhé straně místnosti.
- Vzduch v noci není tolik vířen. (Nejsou otevřeny dveře do dalších místností.)
- Senzor pracuje na baterie, a kvůli šetření energie neměří a hlavně nevysílá data často.

Doba reakce senzoru na otevřené okno se v průměru pohybuje mezi 10 - 15 minutami v noci. Tato časová prodleva je značně dlouhá a proto nelze podle hladiny rozhodovat, zda se má okno zavřít. Je tedy nutné množství CO₂ v ovzduší místnosti předvídat z předem měřených dat.

Přes den, neboli v hodinách kdy se nespí, se doba reakce senzoru mění podle toho, zda jsou otevřeny dveře do sousedních místností a jestli jsou v těchto místnostech otevřeny okna. Případně zda-li vzniká mezi místnostmi průvan, který napomáhá výměně vzduchu.

4.4 Speciální průběhy

Dalším důležitým vlivem na obsah CO₂ přes den je počet lidí a jejich činnost v místnosti. Při počtu lidí v místnosti přesahující 4 lidí větrání pomocí ventilace není dostatečné a i přes maximální otevření okna pomocí motoru, CO₂ koncentrace konzistentně narůstá. V zimním období však dlouhodobým větráním dochází ke snížení pocitové teploty v místnosti, což je nežádoucí efekt především právě při větším počtu lidí v místnosti, rodinné oslavy apod. V takovýchto případech je tedy nutné větrání omezit i přes vyšší hodnoty CO₂ v místnosti

a spoléhat na větrání pomocí oken v jiných místnostech, při kterém nedochází k tak patrnému snížení pocitové teploty v této místnosti. Případně by systém měl umožňovat otevření okna klasickým stylem, který je více efektivní, tedy odpojení od motoru a rychlé intenzivní vyvětrání.

V hodinách kdy se v místnosti nepohybují žádné osoby se hodnoty takřka nemění. Výjimka nastává v případě, kdy se v místnosti suší vyprané prádlo, a proto dochází ke zvýšení relativní vlhkosti vzduchu. V těchto momentech by bylo dobré zajistit snížení vlhkosti pomocí otevření okna.

V případech kdy se v místnosti nikdo nenachází, a proto se hodnota CO_2 delší dobu výrazně nemění, by mělo dojít k vyvětrání, tedy snížení hodnoty CO_2 na minimum. To proto, aby nebylo nutné větrat okamžik poté, co do místnosti dorazí lidé.

Významný vliv na délku a interval větrání má také rychlost a směr větru. V případě že vítr proudí vyšší rychlostí proti oknu, dochází k slabému větrání i při zavřeném okně, protože okno není dostatečně utěsněno. Okno uzavřené ručně pomocí kliky poskytuje větší utěsnění nežli okno uzavřené pouze pomocí motoru. Při extrémních povětrnostních podmínkách může vlivem nárazu větru dojít k násilnému otevření okna, tomuto se dá předejít zajištěním okna pomocí kliky. Při takto zajištěném okně je však důležité motor na okně odpojit aby nedocházelo ke snaze okno otevřít, což snižuje trvanlivost motoru. Je tedy dobré měřit, případně získávat z nějakých volně dostupných předpovědí, informace o aktuálních povětrnostních podmínkách, případně na ně upozorňovat uživatele a například ho vyzvat k ručnímu uzavření okna a následně neposílat motoru příkazy pro otevření.

Kapitola 5

Návrh systému

Hlavní funkcí systémů je udržovat hladinu CO₂, teploty a relativní vlhkosti v ideálních intervalech. Vedlejšími cíli je predikovat vývoj hodnot a nadcházející operace motoru. V zimním období také spravovat intenzitu vytápění ústředního topení v místnosti a tím zajistit energetickou úsporu.

5.1 Uživatelské nastavení

Pod ideálními hodnotami teploty a CO₂ si každý člověk může představovat rozdílné rozmezí hodnot. Ideální hodnota je také ovlivněna činností, kterou osoby v místnosti právě provádí. Proto by systém měl umožňovat přívětivou cestou tato nastavení:

- **CO₂** - Nastavení maximální koncentrace CO₂. Minimální koncentraci není třeba nastavovat, za minimální koncentraci se bude považovat venkovní hodnota, tedy hodnota v rozmezí 350 - 400 ppm.
- **Teplota** - Nastavení horní a dolní hranice rozmezí, ve kterém se bude udržovat teplota.
- **Relativní vlhkost** - Nastavení horní a dolní hranice rozmezí ve kterém se bude systém snažit hodnotu udržet.
- **Noční režim** - Nastavit časové rozmezí ve kterém se systém přepne do nočního režimu. V tomto režimu bude dále možné nastavovat specifické hodnoty výše uvedených veličin.

Protože tato nastavení budou mít vliv na nutnost vytvářet nové modely, respektive na úpravu aktuální trénovací datové sady a následnou nutnost přetrénovat rozhodovací modely, je žádoucí, aby toto nastavení nebylo přístupné běžným uživatelům. Uživatel by tedy měl mít určité oprávnění, aby mohl toto nastavení měnit.

Uživatel může také požadovat provést některou konkrétní akci:

- **Otevření / Zavření okna** - Osoby v místnosti by měly mít možnost vynutit otevření okna kvůli případům, které systém nemůže detekovat, případně predikovat. Další možný požadavek je zavřít okno a zablokovat možnost jeho opětovného otevření po určitou dobu.

- **Odpojení okna od motoru** - Pro případy, kdy je nutno otevřít okno standardním způsobem, je třeba odpojit okno od motoru. Pro tuto funkci by uživatel měl mít možnost zadat systému příkaz pro odjištění spojení mezi motorem a oknem a také následné zajištění.

Tato nastavení již nebudou mít takový vliv na systém a proto by k nim měl mít přístup i běžný uživatel, stále však ne kdokoli.

Pro veškerá tato uživatelská nastavení bude systém disponovat webovým rozhraním. Na něm bude možnost disponovat uživatelským účtem s různým druhem oprávnění k nastavování. Vytvoření uživatelského účtu, případně jeho smazání, by měla být jedna z dalších operací, pro kterou uživatel musí disponovat určitým oprávněním. Web by měl dále přihlášeným uživatelům umožňovat stručný přehled aktuálních měřených veličin a jejich průběhu v minulosti ve vybraném období, například pomocí grafu.

Dále by měl mít uživatel možnost na webovém rozhraní získat informace o systému. Tedy například získat informace o stavu baterií, kterými jsou napájeny jednotlivé senzory.

5.2 Případy užití

Systém by měl automaticky bez zásahu uživatele plnit tyto hlavní případy užití:

- Hlavním cílem je, aby systém byl schopen rozhodnout, zda se za aktuálních podmínek má otevřít, respektive zavřít okno. Toto rozhodnutí bude učiněno na základě aktuálního stavu otevření okna, teploty uvnitř místnosti a venku, koncentrace CO₂ v místnosti, relativní vlhkosti v místnosti a intervalů hodnot zadaných uživatelem. Rozhodování bude probíhat pomocí rozhodovacího modelu, který bude optimalizován pomocí nasbíraných dat. Jaký algoritmus bude konkrétně použit rozhodne jejich přesnost nad nasbíranými daty.
- Dalším cílem je predikovat vývoj hodnot v místnosti na základě předchozích průběhů a aktuálního uživatelského nastavení. Výstupem této části systému budou informace za jak dlouho dojde k jaké změně stavu okna. Tento výstup bude jednak zobrazován uživateli, aby mohl získat přehled o plánovaném chování systému. Zobrazeny budou na webové stránce. Dále tyto hodnoty budou sloužit pro případ užití popsany v dalším odstavci. Algoritmus, který bude využíván pro predikci hodnot, bude vybrán podle úspěšnosti nad trénovací množinou dat z několika implementovaných alternativ.
- Posledním z cílů je energetická úspora v zimní období. Úspory se docílí ovládním hlavice na topení. Systém podle predikce rozpozná že dojde k otevření okna a vypne topení v místnosti před samotným otevřením. Tímto se zabrání čerstvě ohřátému vzduchu aby vycházel následně otevřeným oknem nad topení. Topení bude setrávat ve vypnutém stavu po celou dobu otevřeného okna a následně i určitou dobu po jeho uzavření. Cílem zpoždění zapnutí topení po uzavření okna je docílit ohřevu vzduchu o předměty v místnosti. Tímto se docílí nižší potřeby dovytápět místnost pomocí topení. Toto řešení je umožněno také díky tepelnému čidlu, které je vzdáleno od topení a tudíž má více vypovídající data o skutečném stavu v místnosti, než čidla která jsou například vložena do chytrých hlavice na topení.

5.3 Výběr rozhodovacího algoritmu

Pro rozhodnutí, který rozhodovací algoritmus je nejvhodnější pro rozhodování zda se má okno otevřít či zavřít, je dobré vytvořit několik datových sad. Následně nad nimi vytrénovat několik modelů za použití různých rozhodovacích algoritmů. Poté tyto modely otestovat nad daty, nad kterými nebyly trénovány a porovnat jejich úspěšnost.


5.3.1 Tvorba datových sad

Ze zaznamenaných dat je potřeba vytvořit vhodné sady dat pro trénování modelů. Model pro první případ užití má rozhodovat o tom, zda se má okno otevřít či zavřít. Proto z naměřených dat vybereme pouze ty záznamy, kdy dochází k otevření okna a následně k nim přidáme stejný počet záznamů kdy je okno zavřeno. Tím docílíme vyváženosti datové sady co se týče počtu zastoupení cílového stavu. V případě že bychom vzali veškerá data kdy je okno zavřeno, byly by výsledné hodnoty ve značném nepoměru. V případě že bychom brali pouze hodnoty kdy dochází k zavření okna, tak by v datové sadě chyběly některé běžné hodnoty atributů. Toto je způsobeno setrvačností některých změřených hodnot v místnosti.

Dále je potřeba zajistit, aby každá hodnota přinášela nějakou informaci pro model a aby nedocházelo ke zbytečné duplicitě informací přenášených hodnotami. Ke zjištění, jak na sobě hodnoty jednotlivých atributů závisí, pomáhá matice korelací.

Datové sady

Na obrázku 5.1 jde vidět matice korelací relevantních měřených hodnot (bez jakýchkoliv úprav), časového údaje (který udává čas od minulého otevření / zavření okna) a dále hodnoty, která udává zda je noc či den. Lze vyčíst, že měřené veličiny spolu převážně nekorelují a nejvyšší korelace je mezi relativní vlhkostí a CO₂ v místnosti. Proto budou veškeré tyto hodnoty zahrnuty do trénovacích sad. Dále je však třeba předat modelu informaci o tom, jak se hodnoty mění v čase, zda klesají či stoupají a jakou rychlostí se tato změna odehrává. To lze docílit rozdílem hodnoty v aktuálním měření a hodnoty některého z minulých měření.



Obrázek 5.1: Matice korelací základních hodnot.

V matici korelací, která je vložena v příloze B, lze vidět korelace naměřených aktuálních hodnot a rozdílů hodnot po 5/10/15 minutách. Lze vidět, že nejvíce s aktuálními hodnotami korelují hodnoty informující o koncentraci CO₂ a s větším časovým rozdílem velikost korelace klesá.

Z matice lze také vyčíst, že jednotlivé hodnoty rozdílů spolu korelují, z čehož vyplývá, že není vhodné využívat více rozdílů jedné veličiny v jedné sadě. Protože není zcela jednoznačné, který časový rozestup je nejvíce informačně přínosný, vytvoříme 3 datové sady. Každá z nich bude obsahovat dobu od poslední změny stavu okna, aktuální hodnotu veličin a rozdíl měřených hodnot o 5/10/15 minut.

5.3.2 Výběr sady a algoritmu

Nad vytvořenými sadami natrénujeme modely za použití různých rozhodovacích algoritmů. K tomuto nám dobře poslouží program **RapidMiner**, který dokáže nad námi poskytnutými daty natrénovat sadu modelů za použití rozhodovacích algoritmů, které se pro tento úkol nejvíce hodí.

	Chybovost [%]		
	15 minut	10 minut	5 minut
Naive bayes	16,5	20,9	18,0
Zobecněný lineární model	17,2	13,1	13,2
Logistická regrese	17,5	12,5	13,6
Fast large margin	18,0	19,9	15,6
Hluboké učení	10,6	11,0	8,9
Rozhodovací strom	19,6	8,9	7,4
Náhodný les	9,8	7,7	7,0
Gradient boosted stromy	5,0	8,2	6,9
Metoda podpůrných vektorů	26,6	21,2	20,2

Tabulka 5.1: Úspěšnost modelů s různými algoritmy nad různými datovými sadami.

V tabulce 5.1 je vypsána chybovost jednotlivých natrénovaných modelů určitých rozhodovacích algoritmů nad vytvořenými sadami. Lze vidět, že nejmenší chybovost má rozhodovací sada obsahující rozdíl hodnot o 15 minut, v kombinaci s rozhodovacím algoritmem Gradient boosted stromy. Proto se zaměříme na tuto sadu a na tento rozhodovací algoritmus.

Gradient boosted stromy

Rozhodovací algoritmus gradient boosted stromy vyšel z testů jako nejlepší, a proto se na něj zaměříme více. U tohoto algoritmu lze nastavovat několik vlastností. Program **RapidMiner** sám zkouší vytvořit několik modelů s různými hodnotami parametrů.

Počet stromů	Maximální Hloubka	Learning Rate	Chybovost [%]
30	2	0,001	13,33
90	2	0,001	13,33
150	2	0,001	13,33
30	4	0,001	5,48
90	4	0,001	5,48
150	4	0,001	5,48
30	7	0,001	5,89
90	7	0,001	5,89
150	7	0,001	5,64
30	2	0,010	13,33
90	2	0,010	12,52
150	2	0,010	7,44
30	4	0,010	5,48
90	4	0,010	5,23
150	4	0,010	5,31
30	7	0,010	5,64
90	7	0,010	5,31
150	7	0,010	5,40
30	2	0,100	5,64
90	2	0,100	5,56
150	2	0,100	5,97
30	4	0,100	4,99
90	4	0,100	5,31
150	4	0,100	5,97
30	7	0,100	5,48
90	7	0,100	5,81
150	7	0,100	6,13

Tabulka 5.2: Úspěšnost modelů Gradient boosted stromy s různými nastavení parametrů.

V tabulce 5.2 lze vidět chybovost. Nejmenší chybovosti se dosáhlo při rozsahu 30 stromů o maximální hloubce 4 a learning rate 0,1. V tabulce lze také vidět, že jednotlivé parametry značně ovlivňují výslednou přesnost modelu.

Neuronová síť

Při bližším prozkoumání jednotlivých modelů v programu **RapidMiner** lze zjistit, že neuronová síť obsahuje pouze dvě skryté vrstvy a každá z těchto vrstev obsahuje padesát perceptronů. Tedy **RapidMiner** netestuje změnu těchto parametrů obdobným způsobem jako testoval změnu některých parametrů u algoritmu gradient boosted stromy.

Toto může mít za následek nižší přesnost modelu, tedy přesnost modelu by se dala zvětšit přidáním dalších skrytých vrstev neuronové sítě, případně změnou počtu neuronů v jednotlivých vrstvách. Proto je dobré otestovat jakých úspěšností lze docílit při změně těchto parametrů.

Skryté vrstvy	Počet neuronů v vrstvě									
	10	20	30	40	50	60	70	80	90	100
0	88,47	89,39	88,90	88,28	88,53	89,51	89,57	89,75	90,37	89,26
1	88,47	91,17	90,98	92,94	93,13	94,05	92,33	94,60	93,50	93,93
2	89,88	91,60	93,19	92,15	93,01	91,78	92,52	93,44	92,27	92,52
3	90,61	92,70	93,50	92,21	94,66	94,23	93,37	93,25	94,79	94,66
4	91,90	93,62	93,25	94,79	95,95	95,89	94,60	94,97	95,03	95,09
5	91,41	92,82	93,19	94,85	96,81	94,97	95,34	96,07	95,15	96,01
6	90,00	93,37	94,11	92,82	94,60	97,24	96,13	96,99	97,24	96,20
7	92,02	95,46	94,60	97,91	97,18	96,38	95,89	95,40	96,75	96,69
8	93,74	95,64	96,63	96,20	97,55	97,36	95,52	97,55	98,47	96,01
9	92,33	94,48	94,72	96,75	97,42	97,79	96,81	97,36	96,56	96,56
10	92,52	95,71	96,69	96,50	96,38	97,12	96,63	96,99	95,09	95,77

Tabulka 5.3: Úspěšnost shody modelů s naměřenými daty při různých velikostech neuronové sítě s vyznačenými hodnotami nejvyšší úspěšnosti.

V tabulce 5.3 lze vidět, že největší úspěšnosti, tedy 98.47%, bylo docíleno, když měla neuronová síť 8 skrytých vrstev a každá vrstva obsahovala 90 neuronů. Podařilo se tedy docílit větší přesnosti, než která se získala pomocí RapidMineru, který dosahoval přesnosti necelých 90%.

Pro získání těchto informací byl implementován krátký skript v jazyce Python, pro tvorbu neuronové sítě byl využit modul `keras.models`. Můžeme tedy porovnat přesnost při stejném množství skrytých vrstev a stejném počtu neuronů jako v programu RapidMiner uvedenou v tabulce 5.1. Můžeme vidět, že přesnost je vyšší, a to o 3,73%.

5.4 Predikce

Jedním z účelů predikce je zjistit, že dojde k otevření či zavření okna a za jak dlouho k této změně stavu dojde. Následně informaci o dalším čase otevření okna prezentovat uživateli na webovém rozhraní. Hlavním cílem predikce je včasné rozpoznání blížícího se času otevření okna v zimním období. Předem může dojít ke ztlumení topení a tím snížení tepelných ztrát při následném otevření okna.


Predikce otevření či zavření okna by měla využívat stejný model jako rozhodnutí, zda se má okno aktuálně otevřít či zavřít. S tím rozdílem, že data hodnot, která model využije pro rozhodnutí o změně stavu okna, budou predikována jinými modely. Pro predikci spojitých veličin lze využít opět několik druhů algoritmů. Protože predikované hodnoty budou využívány v modelu popsaném výše, je nutné predikovat veškeré veličiny využívané tímto modelem.

5.4.1 Datová sada pro predikci

Datová sada sloužící pro trénování modelů predikujících vývoj jednotlivých veličin, by měla obsahovat aktuální hodnotu a hodnoty z minulosti. Výslednou hodnotou pak budou hodnoty, kterých veličina nabývá v budoucnosti. Čím více hodnot do minulosti, tím více model odhalí aktuální průběh. Bohužel aktuální průběh veličin se může rychle měnit podle stavu dveří do okolních místností a podle aktuálního počtu lidí v místnosti. Pokud by tedy sada

obsahovala hodnoty, které veličina nabývala ve vzdálenější době, zvyšovala by se nepřesnost předpovědi hodnoty. Je tedy nutné zjistit ideální počet hodnot z minulosti, neboli z jak velké minulosti data získávat.

Dále je nutné stanovit kolik času do budoucnosti mají být veličiny predikovány. Opět je nutné brát v potaz, že predikce na delší časový úsek není vhodné provádět kvůli měnícímu se počtu lidí a stavu dveří do sousedních místností, a stavu otevření oken v těchto místnostech. Samozřejmě tyto hodnoty se nemění v období kdy uživatel spí. Avšak v tomto období uživatele predikované hodnoty nezajímají, protože spí, a predikce potřebná pro rozhodnutí o ztlumení topení je pouze pro blízkou budoucnost.



Obrázek 5.2: Matice korelací změny hodnot CO_2 v pětiminutových intervalech během jedné hodiny.

Jak lze vidět na obrázku 5.2, matici korelací hodnot, kterých nabývá CO_2 během jedné hodiny, nejvíce korelují hodnoty s malým časovým rozdílem. Tím, jak časový rozdíl mezi hodnotami roste, korelace klesá. Pro predikční modely hledáme mezi jednotlivými atributy modelu vysokou korelaci. Vytvoříme proto prozatím opět vícero datových sad a podle přesnosti vytrénovaných modelů určíme, která sada je nejvhodnější. Toto je nutné provádět pro každou veličinu zvlášť. Pro CO_2 , které je uvedeno v této matici korelací, zvolíme sady s daty, které sahají do minulosti 10, 15 a 20 minut. Pro další veličiny, jejichž matice korelací jsou příloze B, zvolíme následující datové sady:

- pro teplotu venku 40 a 20 minut do minulosti,
- pro teplotu uvnitř 40 a 20 minut do minulosti,
- pro relativní vlhkost 30, 20 a 10 minut do minulosti.

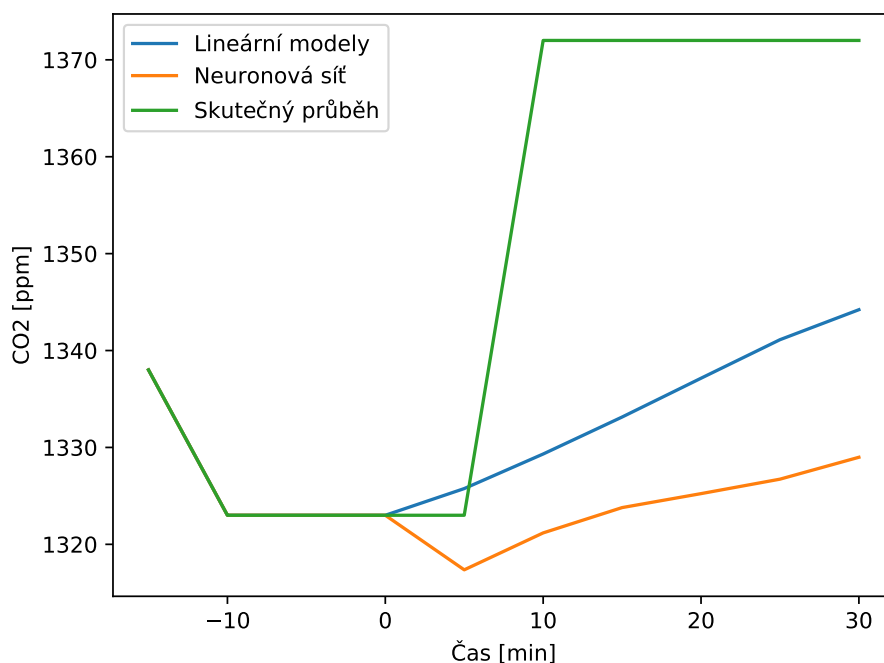
Doba, na kterou se data predikují, je zvolena na 30 minut. Tato hodnota je zvolena kvůli CO₂, jehož hodnota se mění výrazně nepředvídatelně, protože velmi závisí na počtu lidí v místnosti a proudění vzduch mezi místnostmi. Ostatní veličiny mají vyšší setrvačnost a bylo by tedy možné je predikovat na delší dobu dopředu. Model pro vyhodnocení však potřebuje znát všechny veličiny, proto je zbytečné predikovat některé veličiny na delší dobu než jiné.

5.4.2 Výběr sady a algoritmu

Pro predikci hodnot lze využít několika možných algoritmů, pro testování byly zvoleny tyto algoritmy:

- lineární regrese,
- Lasso,
- Ringe,
- neuronová síť s MLP regresorem.

Kromě neuronové sítě se jedná o lineární modely.



Obrázek 5.3: Predikce koncentrace CO₂ v místnosti při datové sadě s hodnotami 15 minut zpět.

Z grafu na obrázku 5.3 lze dobře rozeznat skutečný průběh koncentrace CO₂ a předpovězené koncentrace pomocí neuronové sítě a ostatních metod. Rozdíly mezi jednotlivými lineárními metodami jsou tak malé, že je lepší je prezentovat v tabulce.

Metoda	Předpověď koncentrace CO ₂ [ppm] na čas za					
	5 minut	10 minut	15 minut	20 minut	25 minut	30 minut
Lineární regrese	1325,753	1329,322	1333,138	1333,142	1341,117	1344,213
Lasso	1325,755	1329,223	1333,139	1337,143	1341,118	1344,209
Ridge	1325,753	1329,322	1333,138	1337,142	1341,117	1344,213

Tabulka 5.4: Predikované hodnoty jednotlivých lineárních metod.

V tabulce 5.4 lze vidět rozdíly mezi předpovězenými koncentracemi pomocí lineárních metod. V tabulce sou vyneseny stejné hodnoty jako na v grafu na obrázku 5.3. Je patrné, že rozdíl mezi jednotlivými metodami je tak malý, že je z pohledu koncentrace CO₂ zcela zanedbatelný.

V příloze C jsou grafy pro další navržené datové sady a také pro datové sady dalších predikovaných veličin. Při pohledu na grafy s predikcí CO₂ je možné usoudit, že nejlepší datová sada je s rozdílem 15 minut, tedy ta na obrázku 5.3. U predikování zbylých veličin, tedy vnitřní a vnější teploty a relativní vlhkosti lze vidět, že lineární metody Lineární regrese a Ridge dávají pořád hodnoty se zanedbatelnými rozdíly okolo jednoho procenta. Metoda Lasso však již poskytuje hodnoty jiné a při predikci vnitřní teploty jsou predikované teploty nižší přibližně o 5 %.

Co se týče rozdílů lineárních metod a neuronové sítě, tak kromě patrného rozdílu predikovaných hodnot je výrazný rozdíl v časové náročnosti. Protože systém má běžet na Raspberry Pi, je nutné brát v potaz určité omezení v podobě hardwaru a časové náročnosti, hlavně co se týče trénování modelů. Trénování neuronové sítě je přibližně stokrát časově náročnější, nežli trénování lineárních metod. Konkrétní doba pak samozřejmě závisí na dostupných hardwarových prostředcích a velikosti dat. U neuronové sítě pak dále záleží na její velikosti, tedy kolik má skrytých vrstev a kolik neuronů je v těchto vrstvách obsaženo. Neuronová síť, se kterou se pracovalo při predikci, měla 7 vrstev neuronů a 20 neuronů v každé vrstvě.

Pro implementaci je tedy nejvhodnější zvolit Lineární regresi nebo Ridge. Metoda Lasso dává u CO₂ stejné a u zbylých veličin méně přesné hodnoty. Neuronová síť dává oscilující hodnoty, což by způsobovalo předčasnější, respektive opožděnější, predikci otevření nebo zavření okna. Dalším důvodem, proč neuronová síť není vhodná, je to, že je náročnější na trénování.

Co se týče výběru z vytvořených datových sad, tedy z jak velké minulosti se mají brát data pro jednotlivé predikce, tak pro CO₂ je nejvhodnější 15 minut, jak je již popsáno výše a pro zbylé hodnoty je nejvhodnější 20 minut. Nižší počet hodnot zpravidla neposkytne modelu dostatečnou představu o aktuální průběhu. Naopak vyšší počet hodnot zavádí do modelu data s průběhem, který již není aktuální. Obě tyto možnosti tedy způsobují nižší přesnost predikovaných hodnot.

Kapitola 6

Implementace systému

Pro celkovou implementaci cílového systému byl zvolen programovací jazyk `Python`, protože umožňuje rychlé a přehledné psaní zdrojových kódů. Také má velkou vývojářskou základnu, která poskytuje velké množství různých modulů pro všestranné využití.

Cílový systém se dá rozdělit na několik hlavních částí: databáze, webové rozhraní, komunikace s jednotlivými zařízeními a modely umělé inteligence.

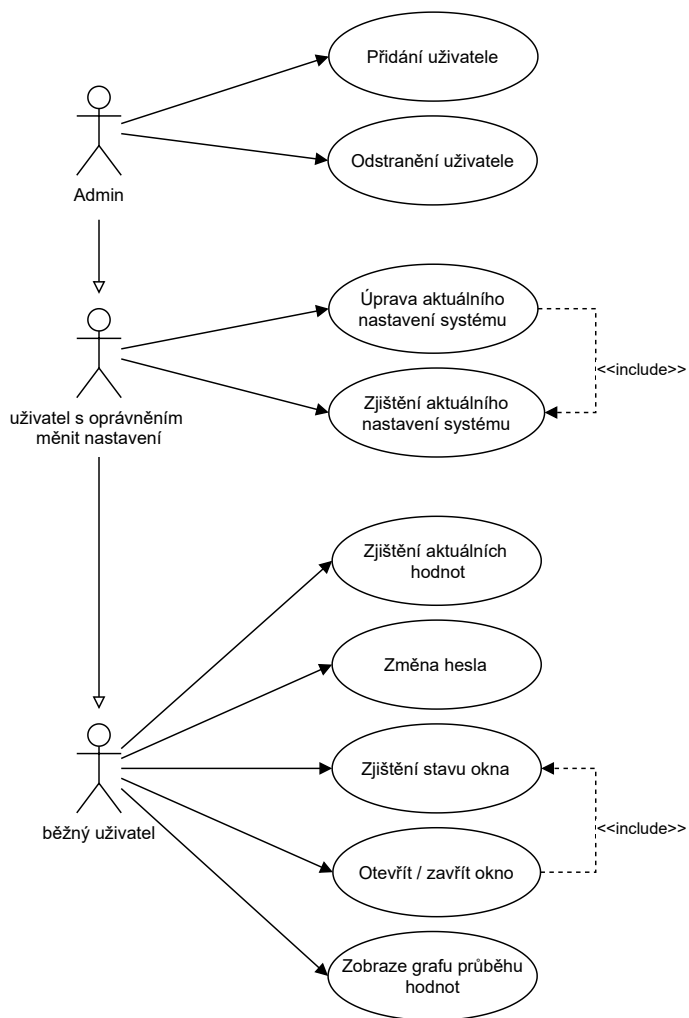
6.1 Webové rozhraní

Webové rozhraní je implementováno pomocí mikro webového frameworku `Flask` v `Pythonu`. Dále je v `html` předlohách využit šablonovací systém `Jinja`. Ten umožňuje přehlednější a snadněji rozšiřitelný `HTML` kód.

Na obrázku 6.1 můžeme vidět případy užití webového rozhraní. Webové rozhraní umožňuje v první řadě přihlášení. Po přihlášení se uživatelé dělí do tří kategorií, podle toho jaká práva mají v aplikaci a tedy jaké změny mohou v systému provádět.

- **běžný uživatel** - může v systému sledovat aktuální měřené hodnoty a jejich průběh během dne v grafu. Může také získat přehled o aktuálním stavu baterií v jednotlivých senzorech. Také může vynutit otevření okna na dobu v intervalu od 5 do 90 minut. Na dobu ve stejném intervalu může také zavřít okno. Pokud se již okno v požadované poloze nachází systém zabrání její změně. Uživatel si také může změnit heslo ke svému účtu.
- **uživatel s oprávněním měnit nastavení** - tento uživatel má veškerá práva běžného uživatele rozšířená o možnost nastavovat dobu, po kterou je systém v nočním režimu. Dále může vybrat který model se bude starat o vyhodnocení hodnot. Také může nastavovat rozsahy hodnot měřených veličin, které se systém snaží udržet v místnosti, tedy relativní vlhkost, teplota a koncentrace CO_2 .
- **admin** - má práva uživatele s oprávněním měnit nastavení a tedy i běžného uživatele. Dále má přístup k seznamu uživatelů v systému. Může ze systému smazat libovolného uživatele, kromě sebe. Tímto je zajištěno, aby v systému byl vždy alespoň jeden admin, a systém se tedy nemůže dostat do stavu, že nikdo nemá administrátorská práva. Také jako jediný může zakládat nové uživatelské účty s libovolnými oprávněními.

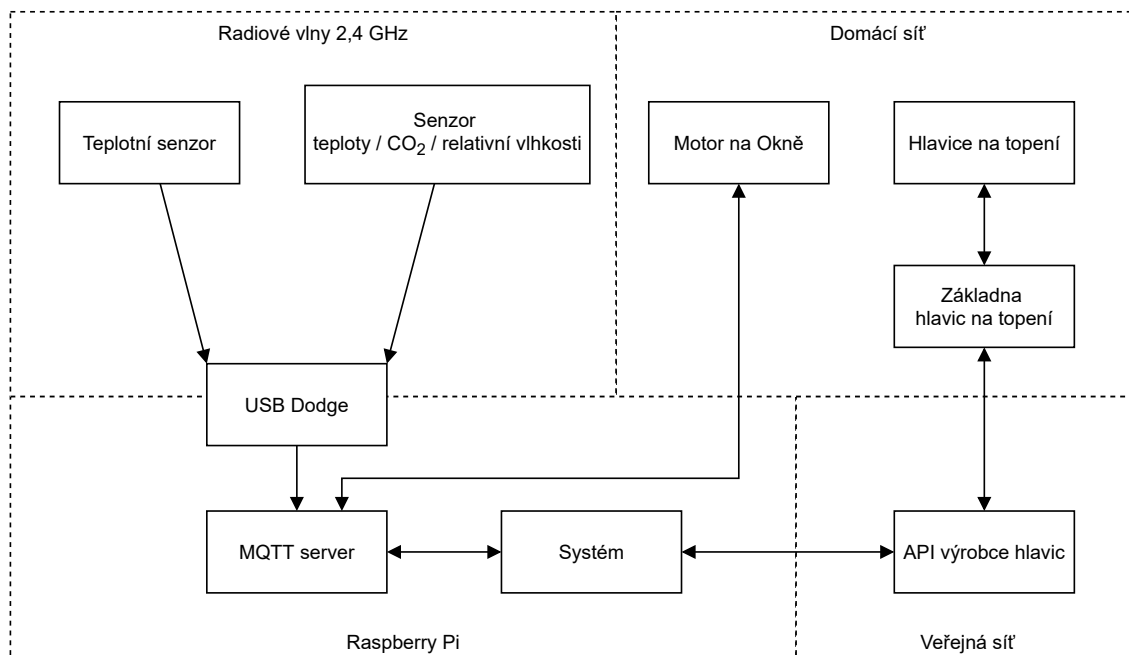
Přihlašovací údaje jednotlivých uživatelů jsou ukládány do databáze. Pro ukládání hesla je využita hashovací funkce z modulu `flask_bcrypt`.



Obrázek 6.1: Diagram případů užití systému.

6.2 Komunikace zařízení

Komunikace jednotlivých zařízení probíhá převážně přes MQTT server, s výjimkou komunikace s hlavicemi na topení. Komunikace s hlavicemi musí probíhat přes API rozhraní serveru výrobce hlavic, který hlavice následně přes centrálu ovládá. MQTT server, skrze který probíhá zbytek komunikace, může běžet kdekoliv, pokud se k němu budou moci připojit veškerá zařízení, respektive programy, které zprostředkovávají zprávy z jednotlivých zařízení.



Obrázek 6.2: Schéma průběhu komunikace jednotlivých zařízení.

Na obrázku 6.2 je zobrazen možný způsob komunikace, kdy je MQTT server (například Mosquitto Broker) spuštěn na Raspberry Pi, na kterém běží celý systém.

Interval odesílání naměřených hodnot senzory, je možné měnit. Díky tomu, že výrobce senzorů poskytuje zdrojové kódy v jazyce C programů běžících na senzorech, je možné upravený kód nahrát na senzor. Základní nastavení dodávané výrobcem poskytuje dobrý kompromis mezi informovaností ostatních zařízení a časovou výdrží na baterie zařízení. Základní nastavení, které lze vyčíst ze zdrojových kódů je pro:

- **vnitřní senzor** - Zdrojový kód senzoru je dostupný na GitHubu výrobce¹. Odeslání naměřených hodnot probíhá alespoň každých 15 minut, nebo pokud se hodnota od předchozí odeslané změnila o určitou hodnotu. Hodnoty jsou nastavené pro jednotlivé veličiny takto:
 - CO₂ o 50 ppm a více
 - teplota o 0,2 °C a více
 - relativní vlhkost o 5 % a více

¹<https://github.com/hardwario/twr-radio-push-button>

- **venkovní senzor** - Měří pouze teplotu. Zdrojový kód senzoru je volně dostupný na GitHubu výrobce². Má nastavené hodnoty odesílání obdobně, tedy alespoň každých 15 minut nebo při pohybu teploty o 0,2 °C a více.

Informace o stavu motoru na okně lze získat vícero způsoby. V případě, že informace nemáme, lze se na ně pomocí speciálního příkazu přes MQTT dotázat, případně lze informace zjistit obdobným příkazem na API, které motor na okně poskytuje. Pokud je motor připojen k MQTT serveru, tak na tento server odesílá informaci při každé změně stavu. Změnou stavu, která vyvolá odeslání zprávy, je například otevírání, zavírání, zablokování, odblokování, atd. Proto se systém na aktuální stav a polohu motoru dotazuje jen při svém spuštění dále spoléhá na to že motor bude dále o změnách sám informovat.

Pro odesílání pokynů motoru na okně je opět využíván MQTT server. Systém po vyhodnocení požadované polohy okna zkontroluje zda se okno již v této poloze nenachází a v případě že ne a zároveň je motor a okno zajištěno vyšle příkaz. Pokud by se systém nacházel ve stavu že nemá aktuální informace o poloze okna a odeslal by například příkaz k otevření přičemž by okno již otevřeno bylo. Dojde k zavření okna a opětovnému otevření, při této operaci okno odesílá zprávy o změnách stavů a systém tedy získá a uloží správný aktuální stav.

6.3 Databáze

Databáze pro systém je implementována pomocí SQLite ve speciálním modulu `database.py`. Jedná se o relační databázový systém. Implementovaná databáze systému obsahuje několik tabulek:

- **uživatel** - tabulka která obsahuje základní informace o uživateli, tedy:
 - ID
 - Jméno
 - Hash hesla
 - Role

Role, které může uživatel mít, jsou popsány v sekci webové rozhraní 6.1. Při prvním spuštění systému, kdy se databáze vytváří, je vytvořen jeden uživatel s nejvyšší úrovní role. Jeho jméno i heslo je „admin“.

- **nastavení** - tabulka obsahující rozsahy veličin, ve kterých se systém snaží udržet aktuální hodnoty. Rozsahy jsou uloženy jak pro denní tak pro noční režim. Dále je v tabulce uložen časový rozsah, ve kterém je aktivní noční režim.

Při vytváření databáze je do tabulky vloženo základní nastavení, které má uživatel možnost měnit přes webové rozhraní.

- **základní trénovací datové sady** - tabulky obsahující základní datové sady. Tato data slouží pro vytvoření trénovacích sad. Při vytváření databáze jsou načtena ze souboru `default_data_*.csv`. Každému modelu, který je třeba trénovat, odpovídá jedna tabulka s daty a každá tabulka získává data z jiného souboru.

²<https://github.com/hardwario/bcf-radio-lcd-co2-voc-lp>

- **aktuální trénovací sady** - jedná se o tabulky obsahující trénovací sady pro modely rozhodující o stavu okna a pro modely predikující vývoj hodnot. Tyto datové sady jsou ze začátku vytvořeny ze základních trénovacích datových sad a dále jsou rozšiřovány o další záznamy při běhu systému. Protože data v tabulkách závisí na konkrétním uživatelském nastavení, tak vždy při změně tohoto nastavení jsou tabulky vymazány a následně znovu vytvořeny. Při novém vytvoření jsou opět naplněny základními daty, upravených podle aktuálního uživatelského nastavení.
- **data** - tabulka, do které se pravidelně ukládají aktuální hodnoty měřených veličin, a zda je okno otevřeno či zavřeno. Do tabulky jsou v nastavitelném pravidelném intervalu ukládány data, data jsou také ukládány při otevírání nebo zavírání okna. Z tabulky jsou také v pravidelných intervalech získávány data do trénovací sady za poslední časové období.

6.4 Model pro otevírání a zavírání okna

Jak je popsáno výše, pro implementaci rozhodovacího modelu je vhodné zvolit gradient boosted stromy nebo neuronovou síť. V systému byly implementované obě varianty a uživatel má možnost si mezi těmito variantami vybrat.

Oba modely se trénují na stejných datových sadách a jsou vždy v pravidelném intervalu přetrénovány na aktuálnější data. Uživatel tedy pouze volí který model zasílá příkazy motoru na okně.

Pro model gradient boosted stromy je využit modul `sklearn.ensemble` a pro neuronovou síť je využit modul `keras.models`. Implementace tvorby trénování a rozhodování se nachází v modulu `Decide.py`. Příprava dat pro rozhodování, tedy informace o aktuálních velikostech měřených veličin a výpočet zbylých hodnot nutných pro rozhodnutí, se provádí ve speciálním modulu `Data.py`.

Při spuštění aplikace systém hledá, zda existují soubory, ve kterých by byly uloženy modely. Jestliže takové soubory neexistují, systém modely vytvoří, vytrénuje a uloží do souborů. Během tohoto tréningu systém není schopen rozhodovat o vhodném chování motoru, protože nemá k dispozici žádný model.

Modely jsou dále v určitých intervalech tvořeny a trénovány vždy nad aktuálnější datovou sadou. K tomuto trénování také dochází při uživatelské změně intervalů veličin, ve kterých se mají hodnoty pohybovat. V obou těchto případech, pokud dojde k požadavku o rozhodnutí jak se má motor zachovat, využijí se modely, které byly vytrénovány, případně načteny, ze souboru v minulosti.

6.5 Předpovídání otevírání a zavírání okna

Jak je již popsáno výše, pro predikci jak a kdy se má okno zachovat se využívá stejný model jako pro rozhodování, zda se má aktuálně okno otevřít či zavřít. Pouze se tomuto modelu předkládají predikované hodnoty jednotlivých veličin. Modelů pro predikování je tedy několik, pro každou veličinu jeden.

Jak je již popsáno v sekci *Výběr sady a algoritmu*, pro každou veličinu je implementován lineární model. Pro implementaci modelů je využit modul `sklearn.linear_model`. Implementace jednotlivých modelů je v modulu `Prediction.py` a příprava dat se provádí v souboru `Data.py`.

Chování modelů při spuštění a běhu aplikace je takřka identické jako chování modelu pro otevírání a zavírání okna. Tedy při spuštění se modely načítají ze souborů, případně jsou trénovány a dále jsou v pravidelných intervalech přetrénovány na aktuální data.

6.6 Testování

Testování správné funkčnosti systému probíhalo ve stejné místnosti jako počáteční získávání dat. Systém byl do provozu nasazen od prvního dubna. Co se týče venkovních podmínek, tak se za toto období vystřídaly jak teplá období, tak i velice chladné. To umožnilo otestovat systém za různých situacích.

Jako srovnávací data byly vybrány hodnoty získané ze senzorů v průběhu října a listopadu 2020. V této době se okno otevíralo podle schématu uvedeného v kapitole *Analýza dat 4* na obrázku 4.1. To znamená, že podle změřené venkovní teploty se větralo k dosažení různé maximální koncentrace CO₂. Při vyšších venkovních teplotách větrání udržovalo nižší hodnoty CO₂, v chladnějších dnech mohla být koncentrace CO₂ v místnosti vyšší, aby se zamezilo ztrátám tepla častým větráním. V průběhu tohoto testovacího provozu bylo zaznamenáno přibližně 18 000 datových položek z každého měřicího senzoru. Během tohoto období došlo přibližně k pěti stům otevření okna. Souhrn dat z tohoto období je uveden v tabulce 6.1.

Veličina	Minimální hodnota	Maximální hodnota	Průměr	Střední hodnota	Směrodatná odchylka
CO ₂ [ppm]	352,2	3 013,0	1 458,3	1 276,7	403,3
Teplota v místnosti [°C]	21,1	24,7	23,4	23,2	0,7
Teplota venku [°C]	3,2	34,1	8,7	7,4	4,7
Relativní vlhkost [%]	41,9	70,8	59,5	59,4	4,3

Tabulka 6.1: Data zaznamenaná za říjen a listopad 2020. Větrání podle pevně daných rozhodovacích kritérií.

Po implementaci vytvořeného systému bylo zahájeno testování ve stejné místnosti během dubna 2021. Kvůli zkrácení intervalu sběru dat na jednu minutu bylo uloženo přes 43 000 záznamů u každé veličiny. Ve sledovaném období došlo k 220 otevření okna. Souhrny dat zobrazuje tabulka 6.2.

Veličina	Minimální hodnota	Maximální hodnota	Průměr	Střední hodnota	Směrodatná odchylka
CO ₂ [ppm]	361,0	2 431,8	1 238,7	1 031,3	391,1
Teplota v místnosti [°C]	21,2	25,1	23,5	23,5	0,7
Teplota venku [°C]	-7,8	21,4	3,9	3,1	5,1
Relativní vlhkost [%]	39,7	75,3	62,5	62,2	7,1

Tabulka 6.2: Data zaznamenaná za duben 2021. Větrání řízené optimalizovaným modelem.

Model rozhodující o otevření, respektive zavření okna ze začátku nedokázal udržet hodnoty CO₂ v intervalech daných uživatelem. Nicméně nedocházelo k tak vysokému překročení těchto hodnot, jako v případě původního systému s pevně danými hranicemi hodnot. I když je model přetrénován v pravidelných intervalech s aktuálními daty pro danou místnost, stále dochází k překročení stanovených hodnot, i když již ne k tak výrazným. K výraznému

překročení hodnot stále může dojít, a to obzvláště při rychlé změně situace například při náhlém vstupu několika lidí do místnosti.

Pokud byla požadovaná koncentrace CO₂ omezena na maximum 2 000 ppm, docházelo v původním systému s pevnými hraničními hodnotami k překročení mezní hodnoty až o 50 % a nejvyšší koncentrace byla změřena 3 013 ppm, viz tabulka 6.1. Po implementaci systému došlo ke snížení překročení nastaveného limitu. Nejvyšší hodnota byla naměřena 2 431 ppm, viz tabulka 6.2.

Predikce hodnot je nejlépe funkční pro interval do patnácti minut, je to tedy postačující pro rozhodování o ztlumení topení. Predikce na delší doby již nejsou tolik přesné a často obsahují chyby. Tyto chyby jsou částečně způsobeny vlivy, které systém není schopen detekovat, jako počet lidí v místnosti a proudění vzduchu mezi místnostmi.

Zatím co původní termostatické ventily na topení se při snižování teploty vzduchu v místnosti postupně otevíraly a plynule pouštěly horkou vodu do systému, nový algoritmem řízený ventil pracuje pouze se stavy otevřeno na 100 % nebo zavřeno. Díky tomu byla ve sledovaném období zaznamenána zvýšená teplota v místnosti. Spolu s kontrolovaným spouštěním topení pouze v případech, kdy je okno zavřeno, tak došlo v některých případech k zbytečně vysokému ohřátí vzduchu až na více než 25 °C.

Optimalizovaný čas větrání také zapříčinil zvýšenou relativní vlhkost vzduchu v místnosti. I když došlo ke snížení hodnoty CO₂ zároveň se zkrácením času větrání a tím i ke snížení tepelných ztrát, zvýšená vlhkost je nežádoucí.

I když webové rozhraní umožňuje změnit maximální požadovanou hranici CO₂, po dobu testování nebyly hodnoty měněny. Byly tedy nastaveny na výchozí hodnoty systému, které jsou podobné jako hodnoty v dříve používaném srovnávacím systému.

Základní informace zobrazuje systém na webové stránce. Po přihlášení se zobrazí nejdůležitější údaje, čili aktuální koncentrace CO₂ a teploty venku a doma. Nad těmito informacemi jsou umístěna nejčastěji používaná tlačítka pro vynucení otevření nebo zavření okna, spolu s nastavením po jakou dobu má tento příkaz platit, viz 6.3.

The screenshot shows the 'Okno' web interface. At the top, there is a navigation bar with 'Ovládání', 'Nastavení', and 'Odhlásit' links, and a 'Přihlášen jako admin' status indicator. A 'ZAVŘENO' button is visible in the top left. The main heading is 'Ovládání', with a sub-message 'Okno se otevře za více jak 30 min'. Below this is a slider control for window opening. Two buttons, 'Otevřít na 15min.' and 'Zavřít na 15min.', are positioned below the slider. At the bottom, three data cards display: 'Teplota venku 22.56', 'Teplota doma 24.75', and 'CO2 536.0'.

Obrázek 6.3: Úvodní stránka webového rozhraní.

6.7 Možná další rozšíření systému

Tato práce se převážně zabývá výběrem vhodných rozhodovacích algoritmů a systémem trénování modelů, které tyto algoritmy využívají.

System by šel dále rozšiřovat hlavně po stránce uživatelského rozhraní, kde by mohla přibýt možnost přidávání dalších místností, které by společně mohly sdílet jednotlivé senzory. Tedy kompletně systém rozšířit o správu jednotlivých čidel, případně místností. V takovém případě se však můžou zvýšit minimální požadavky na hardware zařízení, na kterém systém běží, protože bude nutné rozhodovací modely duplikovat a trénovat pro každou místnost samostatně.

Kapitola 7

Závěr

Cílem práce bylo nastudovat problematiku měření kvality ovzduší v místnosti. Jako indikátor zhoršené kvality vzduchu bylo vybráno měření a vyhodnocování úrovně CO_2 . Dalšími studovanými veličinami byla teplota a relativní vlhkost vzduchu. Pro udržení vysoké kvality ovzduší v obytné místnosti je v našich zeměpisných podmínkách nutné najít vhodný kompromis mezi intenzitou větrání a zabráněním ztrátám tepla.

Pro tuto práci byla zaznamenávána koncentrace CO_2 a další data od října 2020. Výhoda měření CO_2 je také v rychlosti detekce změn. Při výměně vzduchu v místnosti zaregistruje změnu dříve senzor CO_2 , než senzor teploty.

Dále se práce zabývá jednotlivými rozhodovacími případně predikčními algoritmy a jejich principy fungování. Z těchto algoritmů byly následně vybrány ty nejvhodnější, tedy konkrétně Neuronová síť s úspěšností 98 % a Gradient boosted stromy s úspěšností 95 % shody predikce otevření či zavření okna s optimálním průběhem. Při použití těchto algoritmů došlo při reálném testování ke snížení průměrné koncentrace CO_2 z 1458 ppm na 1238 ppm. Docházelo také k menšímu překročení maximálních požadovaných hodnot a nejvyšší naměřená hodnota klesla z původních 3013 ppm na 2431 ppm. Toto je významný pokles, který může být vnímán i zlepšením kvality pobytu v místnosti. Aby nedocházelo k situaci, kdy se větrá a topí zároveň, byly použity algoritmy pro predikci měřených veličin s následnou predikcí potřeby větrání. Jako nejvhodnější byla vybrána metoda Lineární regrese případně Ridge. Díky tomu je možné včas ztlumit topení před otevřením ventilace a zabránit tak ztrátám tepla. Došlo ke zlepšení kvality vzduchu při kratší době otevření okna a zároveň ke snížení potřeby vytápění.

Typický průběh práce systému vypadá takto. Během pracovní doby je místnost prázdná a hodnota CO_2 se tedy postupně ustálí na velikosti jen málo převyšující venkovní hodnotu. K automatizovanému větrání tedy nedochází a teplota místnosti po ranním vytopení pomalu klesá. Po příchodu obyvatel domů začne stoupat množství CO_2 ve vzduchu. Po každé aktualizaci důležitých měřených veličin dochází k vyhodnocení, zda se má okno otevřít či zavřít. Pokud systém vyhodnotí, že v blízké době dojde k překročení koncentrace CO_2 , pošle příkaz ke snížení požadované teploty ovladači topení a po určité době otevře okno. Při dostatečné výměně vzduchu systém rozhodne o uzavření okna a následně k navrácení původní teploty termostatu radiátoru.

Podařilo se implementovat systém, který se snaží udržovat v místnosti čerstvý vzduch podle uživatelem zadaných rozsahů jednotlivých veličin. V případě, že se systému nepodaří udržet hodnoty v přednastavených intervalech, snaží se o návrat hodnoty do intervalu.

Literatura

- [1] *About Temperature Tag* [online]. [cit. 2020-12-20]. Dostupné z: <https://tower.hardwario.com/en/latest/hardware/about-temperature-tag/>.
- [2] *Logistická regrese* [online]. [cit. 2021-01-24]. Dostupné z: <https://www.trilobyte.cz/downloadfree/qcemanual/logreg.pdf>.
- [3] *Netatmo - Přídavná Inteligentní Termostatická Hlavice* [online]. [cit. 2020-12-23]. Dostupné z: <https://www.netatmo.com/cs-cz/energy/additional-valve>.
- [4] *Smarwi - chytré otevírání oken* [online]. [cit. 2020-12-21]. Dostupné z: <https://vektiva.com/shop/smarwi>.
- [5] *Vnitřní výpočtové teploty dle ČSN EN 12831 a doporučené relativní vlhkosti vzduchu dle ČSN 06 0210* [online]. [cit. 2020-12-30]. Dostupné z: <https://vetrani.tzb-info.cz/tabulky-a-vypocty/28-vnitрни-vypoctove-teploty-dle-csn-en-12831-a-doporucene-relativni-vlhkosti-vzduchu-dle-csn-06-0210>.
- [6] ALEŠ, M. *Umělá neuronová síť RCE* [online]. 2013 [cit. 2021-01-22]. Dostupné z: <http://hdl.handle.net/11012/26049>.
- [7] BERNACIKOVÁ, M. *Fyziologie a patofyziologie člověka v extrémních podmínkách* [online]. 2013 [cit. 2020-12-28]. Dostupné z: <https://www.fsps.muni.cz/inovace-SEBS-ASEBS/elearning/fyziologie/fyziologie-a-patofyziologie>.
- [8] CHARVÁT, Z. *Větrání – nezbytnost nebo zbytečnost?* [online]. 2017 [cit. 2021-01-20]. Dostupné z: <https://www.zcharvat.cz/aktuality-vetrani-nezbytnost-nebo-zbytecnost-detail-30>.
- [9] DAN LESSNER, M. P. T. a. J. H. *Rozhodovací stromy a chytré otázky* [online]. 2020 [cit. 2021-1-25]. Dostupné z: https://popelka.ms.mff.cuni.cz/~lessner/mw/index.php/U%C4%8Debnice/Informace/Rozhodovac%C3%AD_stromy_a_chytr%C3%A9_ot%C3%A1zky.
- [10] ENECTIVA, T. *Vliv koncentrace CO₂ na zdraví člověka* [online]. 2017 [cit. 2021-01-20]. Dostupné z: <https://www.enectiva.cz/cs/blog/2017/04/co2-vnitрни-prostory/>.
- [11] ING. MICHAL DORDA, P. doc. *Část IV. – Regresní a korelační analýza* [online]. [cit. 2021-04-05]. Dostupné z: <http://homel.vsb.cz/~dor028/Regrese.pdf>.
- [12] JANDOVÁ, D. *Balneologie*. Grada Publishing, a.s., 2009. ISBN 978-80-247-2820-9.
- [13] M. I. JORDAN, T. M. M. *Machine learning: Trends, perspectives, and prospects*. Science. 2015.

- [14] MILOSLAV V. JOKL, S. M. *Relativní vlhkost a člověk - nové přípustné limity* [online]. 2009 [cit. 2020-12-29]. Dostupné z: <https://www.bozpinfo.cz/josra/relativni-vlhkost-clovek-nove-pripustne-limity>.
- [15] MUNI. *Support vector machines (SVM)* [online]. 2005 [cit. 2021-04-30]. Dostupné z: https://is.muni.cz/el/fi/podzim2006/PA034/09_SVM.pdf.
- [16] R.O., S. C. spol. s. *BEZPEČNOSTNÍ LIST - Oxid uhličitý* [online]. 2015 [cit. 2021-01-29]. Dostupné z: <https://www.siad.cz/documents/261220/0/oxid+uhlicity.pdf/d106249c-eebb-c45b-bf6f-01961455391c>.
- [17] STEFANOS FAFALIOS, I. T. *Gradient Boosting Trees* [online]. 2020 [cit. 2021-1-25]. Dostupné z: https://www.gnosisda.gr/wp-content/uploads/2020/07/Gradient_Boosting_Implementation.pdf.
- [18] ČESKO. *§ 11 odst. 5 vyhlášky č. 268/2009 Sb., o technických požadavcích na stavby*. [online]. Zákony pro lidi.cz © AION CS 2010-2021, 2009 [cit. 2021-01-29]. Dostupné z: <https://www.zakonyprolidi.cz/cs/2009-268#p11-5>.

Příloha A

Obsah CD

Příložené CD obsahuje:


- `documentation` - složka obsahující zdrojové kódy textu bakalářské práce,
- `xjuzat00.pdf` - text bakalářské práce,
- `src` - zdrojové kódy pro úpravu dat, které nejsou součástí hlavního systému,
- `src_system` - zdrojové kódy hlavního výsledného systému,
- `README.md` - instrukce pro spuštění systému.

Příloha B


Matice korelací



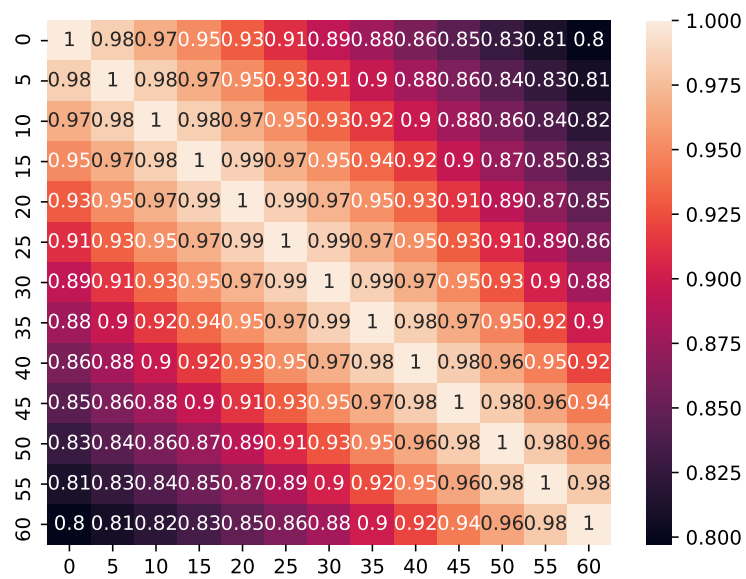
Obrázek B.1: Matice korelací časových rozdílů relevantních měřených veličin.



Obrázek B.2: Matice korelací změny hodnot venkovní teploty v pětiminutových intervalech během jedné hodiny.



Obrázek B.3: Matice korelací změny hodnot teploty v místnosti v pětiminutových intervalech během jedné hodiny.




Obrázek B.4: Matice korelací hodnot relativní vlhkosti v místnosti během jedné hodiny.

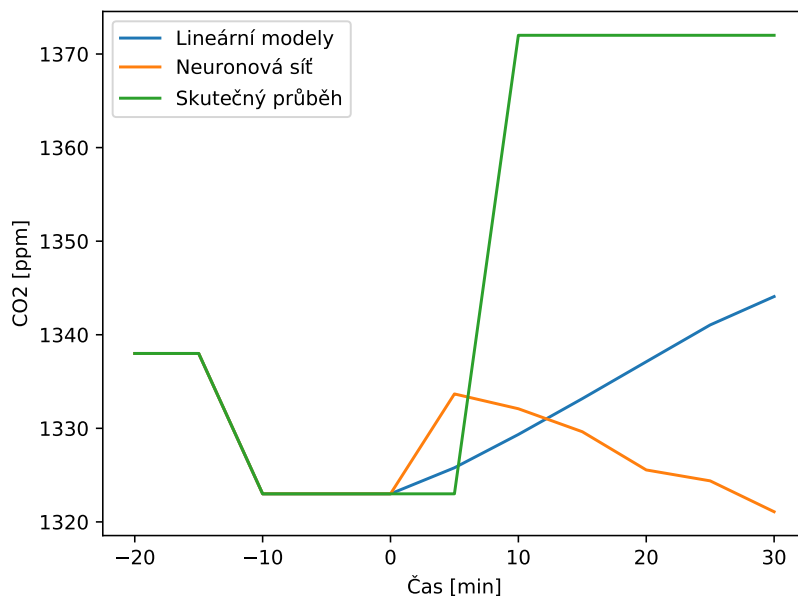
Příloha C

Predikce

C.1 CO₂




Obrázek C.1: Predikce koncentrace CO₂ v místnosti při datové sadě s hodnotami 10 minut zpět.

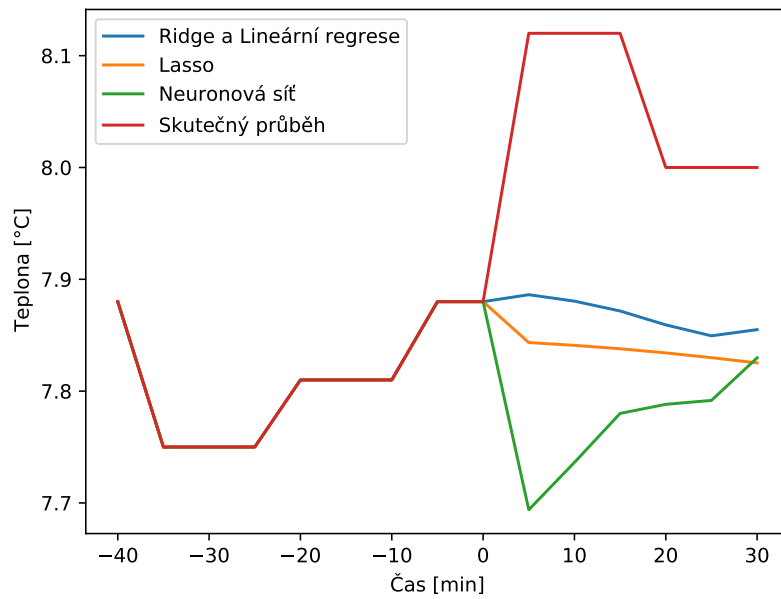


Obrázek C.2: Predikce koncentrace CO₂ v místnosti při datové sadě s hodnotami 20 minut zpět.

C.2 Venkovní teplota

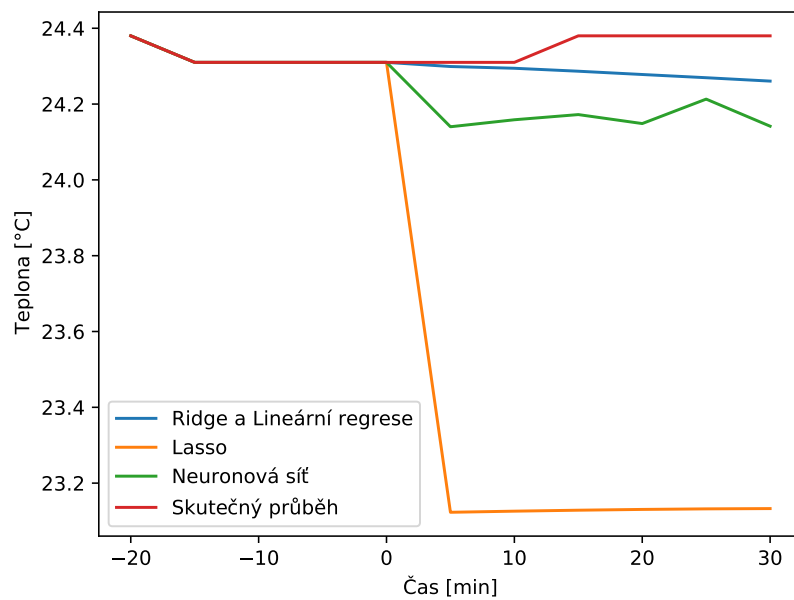


Obrázek C.3: Predikce venkovní teploty při datové sadě s hodnotami 20 minut zpět.

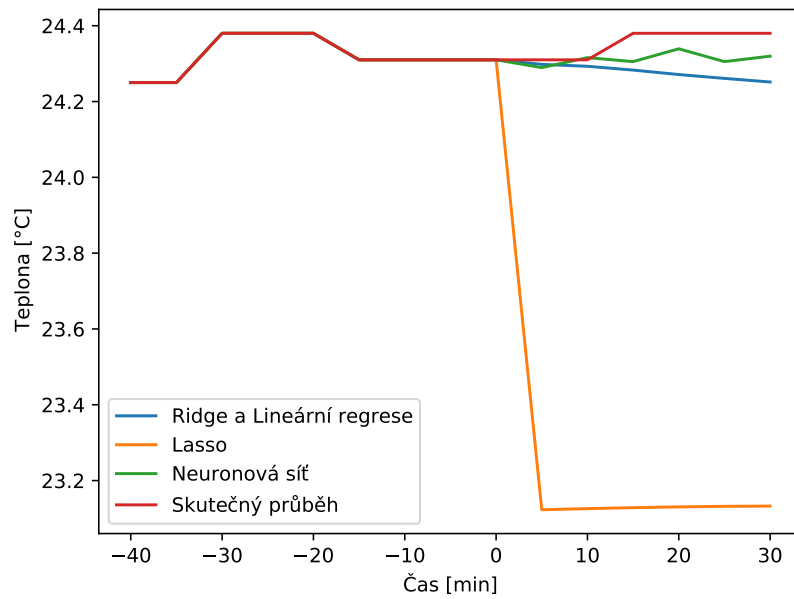


Obrázek C.4: Predikce venkovní teploty při datové sadě s hodnotami 40 minut zpět.

C.3 Vnitřní teplota

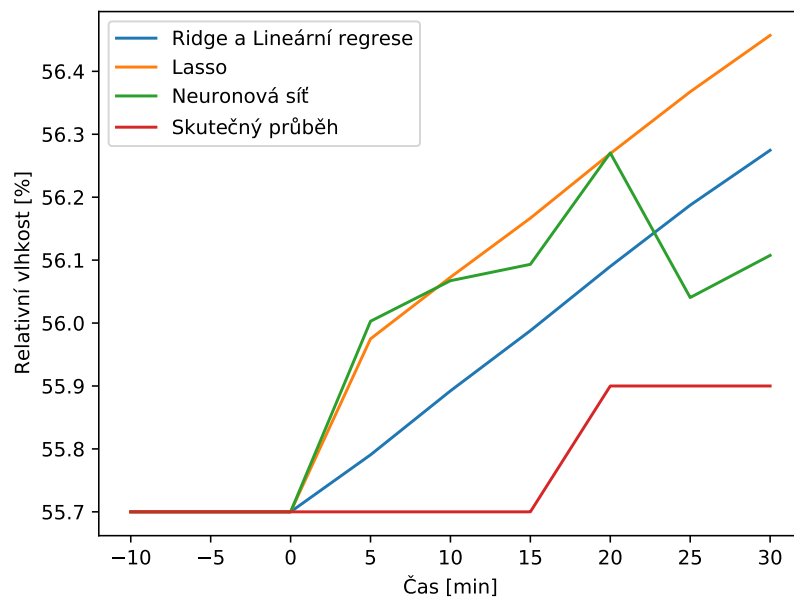


Obrázek C.5: Predikce teploty v místnosti při datové sadě s hodnotami 20 minut zpět.

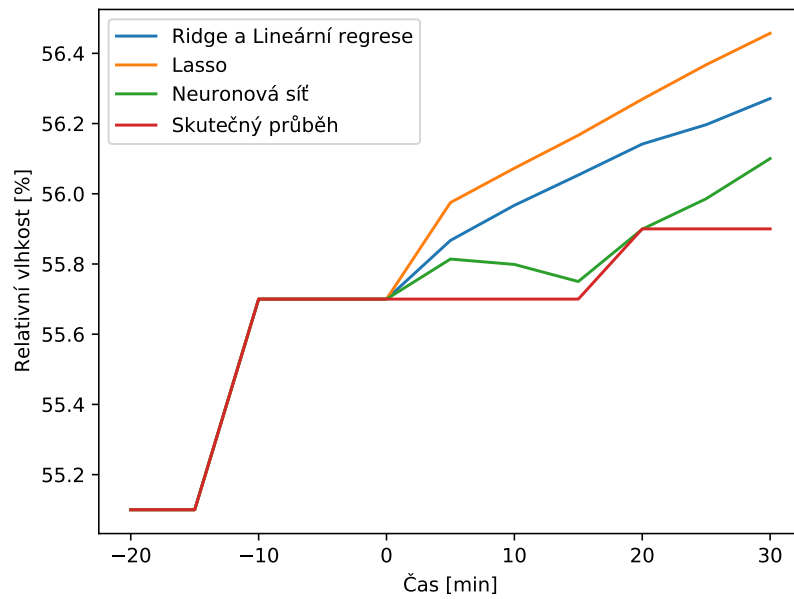


Obrázek C.6: Predikce teploty v místnosti při datové sadě s hodnotami 40 minut zpět.


C.4 Relativní vlhkost



Obrázek C.7: Predikce relativní vlhkosti v místnosti při datové sadě s hodnotami 10 minut zpět.



Obrázek C.8: Predikce relativní vlhkosti v místnosti při datové sadě s hodnotami 20 minut zpět.



Obrázek C.9: Predikce relativní vlhkosti v místnosti při datové sadě s hodnotami 30 minut zpět.