

Diplomová práce



České
vysoké
učení technické
v Praze

F3

Fakulta elektrotechnická
Katedra řídicí techniky

Modelování závislostí provozních dat pro automatickou kontrolu provozu technického zařízení budov

Bc. Martin Žižka

Vedoucí: Ing. Jiří Dostál
Obor: Kybernetika a robotika
Zaměření: Kybernetika a robotika
Květen 2020

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Žižka** Jméno: **Martin** Osobní číslo: **457214**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávací katedra/ústav: **Katedra řídicí techniky**
Studijní program: **Kybernetika a robotika**
Studijní obor: **Kybernetika a robotika**

II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

Modelování závislostí provozních dat pro automatickou kontrolu provozu technického zařízení budov

Název diplomové práce anglicky:

Modelling of operational data dependencies for automatic inspection in building HVAC systems

Pokyny pro vypracování:

- 1) Seznamte se s problematikou automatické kontroly provozu technického zařízení budov (TZB) a nastudujte metody modelování závislostí a statistické metody detekce poruch.
- 2) Demonstrujte principy modelování na reálných TZB datech a vyberte vhodnou metodu modelování využitelnou pro statistické metody detekce poruch.
- 3) Navržené řešení otestujte na co největší množině reálně měřených dat TZB.
- 4) Zhodnoťte vhodnost použití navržených metod pro různé typy TZB dat.

Seznam doporučené literatury:

- [1] Mathieu, Johanna L., et al., Quantifying changes in building electricity use, with application to demand response, IEEE Transactions on Smart Grid 2.3 (2011): 507-518.
- [2] Široký J., Fabian J., Modelování spotřeb energií budov, Vytápění, větrání, instalace, 4/2015
- [3] Miller C., Nagy Z., Schlueter A., Automated daily pattern filtering of measured building performance data, Automation in Construction, Volume 49, Part A, 2015, Pages 1-17, ISSN 0926-5805

Jméno a pracoviště vedoucí(ho) diplomové práce:

Ing. Jiří Dostál, katedra řídicí techniky FEL

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) diplomové práce:

Datum zadání diplomové práce: **10.02.2020**

Termín odevzdání diplomové práce: **22.05.2020**

Platnost zadání diplomové práce: **30.09.2021**

Ing. Jiří Dostál
podpis vedoucí(ho) práce

prof. Ing. Michael Šebek, DrSc.
podpis vedoucí(ho) ústavu/katedry

prof. Mgr. Petr Páta, Ph.D.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Diplomant bere na vědomí, že je povinen vypracovat diplomovou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v diplomové práci.

Datum převzetí zadání

Podpis studenta

Poděkování

Tímto bych rád poděkoval svému vedoucímu práce Ing. Jiřímu Dostálovi za vedení, rady a podporu při zpracování práce. Dále bych rád poděkoval firmě Energocentrum PLUS, s.r.o., za poskytnutí materiálů pro zhotovení práce, konkrétně Jiřímu Zikmundovi a Ing. Petru Kuderovi za podporu a vstřícnost a v neposlední řadě za konzultace Ing. Janu Širokému, Ph.D.

Prohlášení

Prohlašuji, že jsem předloženou práci vypracoval samostatně a že jsem uvedl veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze dne 22.5.2020

.....

Abstrakt

Tato diplomová práce se zabývá problematikou automatické kontroly provozu technického zařízení budov (TZB). Nejprve jsou představeny možné dopady chyb provozování TZB a následně je nastíněno základní dělení metod modelování. Jsou představeny statistické metody pro detekci poruch. Na základě teoretických znalostí je navržena nová metoda pro automatickou kontrolu provozu TZB, která využívá testování hypotéz pro kontrolu provedení útlumu a detekuje odchýlení od očekávaného chování. Model je navržen tak, aby jej bylo možné použít na budovy, které jsou provozovány i v jiném než klasickém pětidenním provozu. Je tak možné modelovat například nemocnice, či vícesměnný provoz budov. Na závěr je nově navržená metoda validována na více než 300 ročních datových sadách z reálných TZB a je analyzován dopad pandemie COVID-19 na spotřebu elektrické energie kancelářských budov. Pro validaci je využito široké spektrum budov a různé typy TZB dat.

Klíčová slova: TZB, detekce poruch, testování hypotéz, modelování

Vedoucí: Ing. Jiří Dostál

Abstract

This diploma thesis deals with the issue of continuous commissioning in HVAC systems. First, the possible impacts of HVAC operation errors are presented and subsequently the basic division of modelling methods is outlined. Statistical methods for fault detection are presented. Based on theoretical knowledge, a new method for continuous commissioning in HVAC is proposed. The proposed method uses hypothesis testing to control attenuation and detects deviations from expected behavior. The model is designed so that it can be used on buildings operated in other than the classic five-day operation. For this reason, it is possible to model, for example, hospitals or multi-shift operation buildings. Lastly, the newly proposed method is validated on more than 300 annual datasets from real HVAC and impact of COVID-19 pandemic on energy consumption of office buildings is analyzed. A wide range of buildings and various types of HVAC data are used for validation.

Keywords: HVAC, fault detection, hypothesis testing, modeling

Obsah

1 Úvod	1		
1.1 Automatizovaná kontrola provozu TZB	1		
1.2 Chyby při provozování TZB	2		
1.3 Cíle práce	3		
2 Metody modelování systémů TZB	4		
2.1 Metody založené na provozních datech	4		
2.1.1 Denostupňová metoda	7		
2.1.2 Metoda modelování denního profilu spotřeby energie	8		
3 Metody detekce poruch	12		
3.1 Modelový přístup	13		
3.2 Markovovy řetězce	13		
3.3 Statistický přístup	14		
3.3.1 Testování hypotéz	14		
3.3.2 SLR test	14		
3.3.3 CUSUM se SLR	16		
3.4 Automatické filtrování dat pomocí denních profilů	16		
3.5 Shrnutí	17		
4 Návrh metody pro automatickou kontrolu provozu TZB	19		
4.1 Zobecnění využití časových intervalů	20		
4.2 Přizpůsobení režimu obsazenosti a neobsazenosti budovy	20		
4.3 Modifikace algoritmu pro výpočet teplotních komponent	21		
4.4 Využitelnost teplotních intervalů pro neobsazený režim	23		
4.5 Výpočet směrodatných odchylek modelu	23		
5 Implementace modelu	27		
5.1 Prostředí SkySpark	27		
5.2 Trénování modelu	27		
5.3 Výstup metody AKP	28		
5.3.1 Malá administrativní budova využívající převážně topný výkon	29		
5.3.2 Velká administrativní budova využívající převážně chladicí výkon	32		
5.3.3 Monoblok ČVUT Fakulty elektrotechnické a Fakulty strojní	34		
5.3.4 Budova se sedmidenním provozem	36		
5.3.5 Zhodnocení interpretovatelnosti modelu	37		
5.4 Predikce metodou AKP	38		
5.5 Výpočetní náročnost	40		
6 Nasazení metody AKP na měřená data TZB	41		
6.1 Zhodnocení využitelnosti metody pro různé typy TZB dat	41		
6.2 Testování hypotéz	46		
6.2.1 Test změny střední hodnoty	47		
6.2.2 Test neprovedení útlumu	49		
6.2.3 Využití metody AKP pro analýzu dopadu pandemie COVID-19 na spotřebu elektrické energie kancelářských budov	51		
6.3 Diskuze	53		
7 Závěr	55		
Literatura	57		
A Příložené soubory na CD	60		

Obrázky

2.1 Členění modelů data-driven metod.	6	5.5 Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^u modelu malé administrativní budovy v neobsazeném režimu	31
2.2 Závislost spotřeby elektrické energie na počtu otopných denostupňů.	8	5.6 Graf znázorňující vliv dne v týdnu a času během dne na spotřebu energie s využitím odhadnutých parametrů α_i^o modelu velké administrativní budovy v obsazeném režimu pro pětidenní pracovní týden	32
2.3 Zátěž závislá na venkovní teplotě.	9	5.7 Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^o modelu velké administrativní budovy v obsazeném režimu	33
2.4 Aktuální a predikovaná zátěž závislá na venkovní teplotě	11	5.8 Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^u modelu velké administrativní budovy v neobsazeném režimu	33
3.1 Klasifikace metod detekce poruch dle apriorní informace.	13	5.9 Graf znázorňující vliv dne v týdnu a času během dne na spotřebu energie s využitím odhadnutých parametrů α_i^o modelu monobloku ČVUT Fakulty elektrotechnické a Fakulty strojní v obsazeném režimu pro pětidenní provoz	34
3.2 Trojstavový systém popsaný Markovovými retězci.	14	5.10 Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^o modelu monobloku ČVUT Fakulty elektrotechnické a Fakulty strojní v obsazeném režimu	35
3.3 Spotřeba elektrické energie reprezentovaná denními profily – metoda "DayFilter".	17	5.11 Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^u modelu monobloku ČVUT Fakulty elektrotechnické a Fakulty strojní v neobsazeném režimu	35
4.1 Histogram rozdílů odhadované a měřené spotřeby energie pro 15 minutový interval α_{497}^o	24	5.12 Graf znázorňující vliv dne v týdnu a času během dne na spotřebu energie s využitím odhadnutých parametrů α_i^o modelu budovy se sedmidenním provozem	36
4.2 Histogram rozdílů odhadované a měřené spotřeby energie pro 15 minutový interval α_{417}^o	24		
4.3 Histogram rozdílů odhadované a měřené spotřeby energie pro 15 minutový interval α_{71}^u	25		
5.1 Ukázka vstupní matice pro odhad parametrů modelu metodou AKP v prostředí SkySpark.	28		
5.2 Graf znázorňující vliv dne v týdnu a času během dne na spotřebu energie s využitím odhadnutých parametrů α_i^o modelu malé administrativní budovy v obsazeném režimu pro pětidenní pracovní týden	30		
5.3 Graf znázorňující vliv dne v týdnu a času během dne na spotřebu energie s využitím odhadnutých parametrů α_i^u modelu malé administrativní budovy v neobsazeném režimu	30		
5.4 Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^o modelu malé administrativní budovy v obsazeném režimu	31		

5.13 Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^u modelu budovy se sedmidenním provozem	37	6.14 Detekce neprovedení částečného útlumu o Velikonočních svátcích . .	51
5.14 Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^o modelu velké administrativní budovy v obsazeném režimu s extrapolací dat	40	6.15 Detekce změny střední hodnoty spotřeby elektrické energie vlivem pandemie COVID-19 v prvním čtvrtletí roku 2020	52
6.1 Histogram koeficientu determinace R^2 jednotlivých modelů využívajících měřených dat elektroměrů	42	6.16 Detekce víkendové spotřeby energie ve všední dny způsobené vlivem pandemie COVID-19 v prvním čtvrtletí roku 2020	53
6.2 Ukázka datové sady z elektroměru vhodné pro metodu AKP	42		
6.3 Ukázka datové sady z elektroměru nevhodné pro metodu AKP	43		
6.4 Histogram koeficientu determinace R^2 jednotlivých modelů využívajících měřených dat teploměrů vnitřních teplot	44		
6.5 Ukázka datové sady z teploměru vnitřní teploty vhodné pro metodu AKP	44		
6.6 Ukázka datové sady z teploměru vnitřní teploty nevhodné pro metodu AKP	45		
6.7 Histogram koeficientu determinace R^2 jednotlivých modelů využívajících měřených dat vodoměrů	45		
6.8 Ukázka datové sady z vodoměru nevhodné pro metodu AKP	46		
6.9 Detekce snížení střední hodnoty predikované spotřeby energie o 50 %	47		
6.10 Detekce zvýšení střední hodnoty predikované spotřeby energie o 50 %	48		
6.11 Detekce zvýšení střední hodnoty predikované spotřeby energie o 100 %	49		
6.12 Detekce neprovedení útlumu v neobsazeném režimu	49		
6.13 Detekce neprovedení útlumu o Velikonočních svátcích	50		

Tabulky

4.1 Výsledné teplotní komponenty pro interval venkovních teplot 0 °C – 24 °C.....	21
4.2 Výsledné teplotní komponenty pro interval venkovních teplot 4 °C – 28 °C	21
4.3 Výsledné teplotní komponenty pro interval venkovních teplot 4 °C – 28 °C	22

Kapitola 1

Úvod

Je všeobecně známo, že ve vyspělých zemích tvoří spotřeba energie v budovách přibližně 20 až 40 % z celkové spotřeby energie.[14] Vzhledem k výstavbě nových budov a zvyšujících se nároků na úroveň komfortu lze předpokládat, že spotřeba energie v budovách bude mít nadále roustoucí tendenci. Z tohoto důvodu je v současné době velmi žádaná optimalizace energetické náročnosti budov. Největšího snížení energetické náročnosti budov lze dosáhnout pomocí konstrukčních změn, typicky výměny oken či zateplení budovy. Nezanedbatelný vliv může mít také optimalizace řízení technického zařízení budov (dále TZB). S tím je spojen nastupující trend, kdy jsou aktivněji využívána data ze systému měření a regulace (dále MaR) právě za účelem optimalizace provozu TZB.[14][21]

1.1 Automatizovaná kontrola provozu TZB

V průběhu let přibývá budov se systémy MaR, které umožňují uchovávání provozních dat. Mnoho budov je provozováno neoptimálně. Systémy MaR jsou sice nastaveny tak, aby splnily požadavky na teplotní komfort, ale nejsou přitom energeticky efektivní. Pomocí analýzy provozních dat lze odhalit poruchy systému a neefektivní řízení. Základem zefektivnění provozu budovy je analýza provozních dat a pochopení procesů TZB.

Zde přichází na řadu automatizovaná kontrola TZB. Základním cílem není pořízení nových zařízení, ale optimalizace chodu zařízení stávajících. Automatická analýza dat umožňuje dosáhnout úspory nákladů na energii a provoz prostřednictvím kontrolování chodu stávajících zařízení budov, kontrolou provedení útlumů, či odhalování různých anomálií a poruch systému.

Nezbytnou součástí automatické kontroly TZB jsou periodické kontroly systému vytápění, větrání a klimatizace (*angl. heating, ventilation and air conditioning*). Při údržbě nebo odstraňování poruchy zařízení často dochází k přepnutí do manuálního režimu ovládání zařízení. Vlivem nepozornosti obsluhy často dochází k nepřepnutí zařízení zpět do automatického režimu a proto je vyžadována periodická kontrola, která tuto chybu odhalí.

Nové budovy bývají velmi složité. Často dochází k situacím, kdy budovu není možné provozovat v teoreticky nejlepším stavu. Pokud jsou však získána data vhodně analyzována, lze velké množství provozních chyb odstranit. Pro

kvalitní analýzu provozních dat je nutný krátký časový krok sběru dat, typicky maximálně 15 minut.[7][22]

1.2 Chyby při provozování TZB

S rostoucími požadavky na kvalitu vnitřního prostředí se systémy TZB stávají složitějšími, a tím i jejich řízení. Při provozu nebytových budov připadá na spotřebu energie systémů TZB téměř 50 % z celkové spotřeby energie budov.[14] Odhaduje se, že 5 až 30 % energie je vyplýváno z důvodu chybného řízení systémů TZB.[5]

Studie ukázaly, že lze snížit spotřebu energie budov až o 30 % pomocí opravy stávající struktury budov nebo optimalizací řízení systémů TZB.[4] Podle studie [9] může být uspořeno 20 až 30 % spotřeby energie pomocí opakovaného uvedení do provozu a zaregulování systémů TZB.

K chybám při provozování systémů TZB může docházet z několika důvodů. Jedním z nich může být navržení systémů TZB a způsobu jejich řízení bez znalosti budoucího uplatnění a provozu budovy. Dalším důvodem bývá často chybné zaregulování systémů a s tím spojené uvedení do provozu. Chyby s největším dopadem na zvýšenou spotřebu energie bývají obvykle spojeny s poruchami zařízení a chybným řízením systémů TZB. To může mít několik příčin, od chybně proškolené obsluhy, zapomenutého manuálního režimu chodu až po nepravidelný servis zařízení.[21]

Každé zařízení a systém v budově jsou řízeny na základě měřených hodnot na výstupu senzorů a čidel a jejich porovnání s požadovanými hodnotami. V případě kdy není dosaženo požadovaných hodnot, systém nebo zařízení upravují svoji činnost, aby tohoto stavu bylo dosaženo. V některých situacích může být systém nebo zařízení ovlivněno poruchou, která je velmi často obtížně detekovatelná. Z tohoto důvodu jsou využívány metody detekce a diagnostika chyb (*angl. fault detection and diagnosis*). Metody detekce a diagnostiky chyb umožňují automaticky identifikovat odchylky od očekávaného chování.

Při provozu administrativních budov, škol a podobných zařízení je několik typických využití metod detekce a diagnostiky chyb. Nebytový prostor je provozován v určitém periodickém režimu, kdy se střídá obsazený a neobsazený režim. Typickým příkladem je administrativní budova fungující v klasickém pětidenním provozu. V neobsazeném režimu bývá prováděn útlum budovy. Útlum se obecně zavádí z ekonomických a ekologických důvodů, kdy v režimu neobsazenosti není nutné udržovat teplotní komfort v budově, a dochází tedy k značným úsporám spotřeby energie.[10] Jedním z významných diagnostických testů je kontrola režimu TZB vzhledem k programu budovy (*angl. scheduling*).

V praxi je možné velkou část těchto chyb detekovat z profilu spotřeby energie budovy, primárně ze spotřeby elektrické energie. Například neprovedení útlumu o víkend, statním svátku nebo jiném nepracovním dnu, které se přímo projeví ve spotřebě elektrické energie. Chyby vyskytující se při provozu TZB nejsou spojené pouze s neprovedením útlumu. Příkladem je porucha klapky rekuperace u vzduchotechnické jednotky (dále VZT), kterou systém MaR dokáže vykompenzovat zvýšením spotřeby energie pro chlazení resp.

vytápění. Tato porucha nemá vliv na teplotní komfort v budově, dochází pouze ke zvýšení spotřeby energie. Chyby TZB se mohou projevit jako anomálie ve spotřebách energie budovy, kde dochází k detekovatelnému odchýlení od očekávaného chování. Značnou výhodou pro detekci těchto chyb jsou relativně nízké nároky na potřebná data ze senzorů a měřidel, kde není nutné mít k dispozici kompletní data systému MaR, ale je postačující pouze měřidlo energie.

■ 1.3 Cíle práce

Cílem této práce je navrhnout vhodnou statistickou metodu pro detekci poruch TZB. Navrženou metodu implementovat a následně validovat s využitím širokého spektra budov a různých typů dat TZB.

Práce je dělená do 7 kapitol. Úvod a cíle práce jsou obsaženy v kapitole 1. V kapitole 2 jsou popsány metody modelování vhodné pro TZB. V kapitole 3 jsou popsány metody pro detekci poruch. Kapitola 4 obsahuje návrh metody pro automatickou kontrolu provozu TZB. V kapitole 5 je popsána implementace navržené metody v prostředí SkySpark. V kapitole 6 je navržená metoda validována na reálných datech TZB včetně zhodnocení její využitelnosti pro různé typy budov a v kapitole 7 jsou shrnuty výsledky práce.

Kapitola 2

Metody modelování systémů TZB

V této kapitole jsou představeny metody modelování využitelné pro TZB. Pro účely efektivního provozu budov je nejčastěji modelovanou veličinou spotřeba energie. Pod spotřebu energie je v této práci zahrnuta spotřeba elektrické energie, tepla, plynu a vody. Využití modelů umožňuje optimalizaci energetické účinnosti systémů TZB, eliminace plýtvání energie (skrze detekci anomálií, změnou provozních řádů atd.) a řízením odběrových maxim.

Modelování systémů TZB umožňuje energeticky efektivnější řízení budovy. Pomocí modelů je možné předpovídat spotřebu energie na základě předpovědi počasí, periodických trendů či jiných událostí jakými jsou například státní svátky. Metody modelování lze rozdělit na metody založené na fyzikálních zákonech, které využívají přesný matematický model, a na metody využívající provozní data systému (data-driven). Kombinací těchto metod jsou metody hybridní, tzv. grey-box, které definují strukturu modelu na základě fyzikálních znalostí, a parametry modelu jsou určeny pomocí měřených dat.

2.1 Metody založené na provozních datech

Tyto metody umožňují modelovat systém s využitím naměřených dat. Velká část budov je dnes napojena na SCADA (dispečerské řízení a sběr dat – *angl. Supervisory control and data acquisition*) systémy, které umožňují sběr a uchovávání provozních dat budovy. Provozní data se dají využít jako trénovací množina pro metody strojového učení. Kvalita modelů je přímo závislá na kvalitě trénovací množiny. TZB systémy jsou velmi často monitorovány po celý čas jejich provozu a data jsou uchovávána pro zpětnou diagnostiku. Pro vytvoření dále použitelného modelu je v trénovací množině nutné zachytit dostatečně excitovaný systém. Pro modelování vlivu ročních období či venkovní teploty je žádoucí, aby v trénovací množině byly zastoupeny záznamy z celého roku.

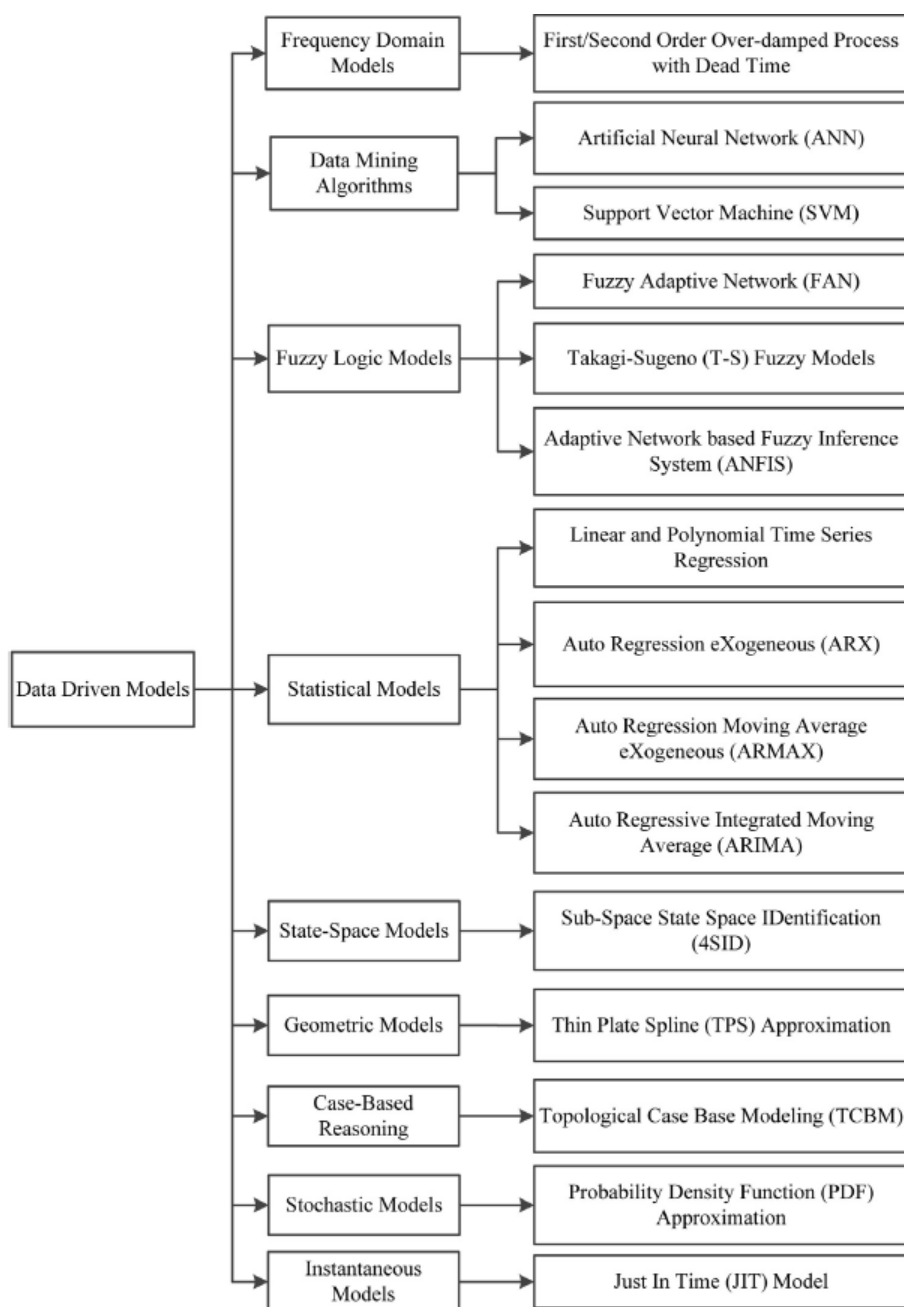
Metody založené na provozních datech umožňují modelovat složité systémy, u kterých klasické fyzikální modely nejsou známé. Tyto metody dělíme na:

■ **Black-box metody**

Tyto metody poskytují model, který popisuje vztah mezi vstupem a výstupem systému, ale není známé, jak přesně model funguje. Black-box metody nevyžadují kromě trénovacích dat žádné dodatečné informace. Mezi nejvyužívanější black-box metody patří mimo jiné neuronové sítě, či metoda podpurných vektorů (*angl. support vector machines*).[16]

■ **Grey-box metody**

Tyto metody využívají kromě dat i dodatečných informací o systému či fyzikálních zákonů. Nejčastějším použitím je hledání parametrů předem daného typu modelu s využitím provozních dat. Grey-box metody vyžadují dodatečné znalosti modelovaného systému, ale jsou interpretovatelné a mohou dosahovat lepších výsledků. Pro efektivní využití grey-box metody stačí zpravidla menší trénovací množina dat. Do této kategorie se řadí statistické a regresní metody.[1]



Obrázek 2.1: Členění modelů data-driven metod.[1]

Cílem této sekce není podat rozsáhlý přehled všech metod modelování dat TZB, ale stručně popsat možné dělení těchto metod. Příklad podrobného rozdělení je uveden na Obrázku 2.1. V další podkapitole jsou popsány vybrané statistické metody používající lineární regresi. Komplexnější přehled lze nalézt v článku [1].

Statistické metody využívají lineární regresi jedné, či více proměnných.[1] Mezi statistické modely se řadí například autoregresní modely ARX nebo

ARMAX.[3] Tyto modely jsou schopné popisovat komplexní systémy, které mají deterministickou i náhodnou složku.

Dynamika diskrétního systému je zachycena pomocí zpožděných hodnot vstupu a výstupu. S rostoucí dimenzí modelu rostou výpočetní i paměťové nároky. Volba vhodné struktury modelu je otázkou zkušenosti a vzhledu do dané problematiky. V případě neznámého systému je možné vyzkoušet modely s různým počtem dimenzí a následně zvolit vhodnou strukturu. Po dosažení minimální dimenze potřebné pro popsání systému by se přesnost modelu neměla s přibývajícimi dimenzemi modelu dále zlepšovat. Metody pro odhadování modelu jsou popsány v [6].

2.1.1 Denostupňová metoda

Denostupňová metoda je statistická metoda, která je využívána pro modelování závislosti spotřeby energie budov na venkovní a požadované vnitřní teplotě. Prestože tato metoda byla převážně využívána v minulém století, díky své jednoduchosti je v praxi stále běžná. K provedení lineární regrese je zapotřebí korelovat spotřebu energie s denostupni. Pro získání denostupňů je využito průběhu meteorologických dat venkovní teploty. Výpočet se provádí nad množinou denních průměrných teplot venkovního vzduchu. Denostupně mohou být použity v jakémkoliv časovém intervalu, typicky bývá použit jeden týden nebo měsíc.

Výpočet

Existují dva hlavní typy denostupňů. Otopné denostupně a chladicí denostupně. Základní výpočetní formule pro denostupně je dána následující rovnicí

$$D^{\circ}(t_{int}) = d \cdot (t_{int} - t_{ext}).[17] \quad (2.1)$$


Z rovnice (2.1) vyplývá, že počet denostupňů určený vnitřní teplotou odpovídá součinu počtu otopných nebo chladicích dnů d a rozdílu vnitřní teploty t_{int} a průměrné venkovní teploty t_{ext} . Výpočet je proveden pro jednotlivé dny z daného období zvlášť.

Jedním z hlavních problémů je stanovení počtu otopných nebo chladicích dnů d . Tyto dny se určují dle vyhlášky Ministerstva průmyslu a obchodu č.194/2007Sb.[17]

Vyhodnocení

Vyhodnocení denostupňové metody lze provést v libovolném tabulkovém nástroji pomocí grafu a dostupných funkcí viz Obrázek 2.2, kde na osu y je vynesena spotřeba elektrické energie a na osu x jsou vyneseny denostupně. Při vyhodnocení byla použita lineární regrese pro proložení bodů přímkou. Bod, kde příмка protíná osu y , vyjadřuje základní spotřebu elektrické energie. Pomocí rovnice přímkou lze odhadovat spotřebu elektrické energie v závislosti na denostupních.

K charakteristice kvality regresního modelu slouží koeficient determinace R^2 . Parametr $R^2 \in <0, 1>$, maximální hodnota 1 odpovídá dokonalé predikci hodnot závislé proměnné.[15]



Obrázek 2.2: Závislost spotřeby elektrické energie na počtu otopných denostupňů.[15]

■ Výhody a nevýhody

Výhodou denostupňové metody je historické využití, relativně jednoduchý výpočet a snadná interpretace dat v jakémkoliv tabulkovém emulátoru. Nevýhodou denostupňové metody je neuvážení denního profilu spotřeby energie. Tato metoda využívá průměrné denní teploty, čímž v době kdy je teplota běžně měřena s periodou 5 minut dochází k nevyužití měřených dat.

■ 2.1.2 Metoda modelování denního profilu spotřeby energie


V této sekci bude představena metoda pro analýzu spotřeby energie budovy v 15 minutových intervalech z publikace LBNL-4944E [12] nebo-li Lawrence Berkley National Laboratory číslo 4944E (dále bude tento model nazýván LBNL-4944E). Tato statistická metoda je založená na regresním modelu spotřeby energie využívající identifikátor doby v týdnu, závislosti dat na venkovní teplotě a parametrech charakterizující spotřebu energie budovy.[12]

Výstupem tohoto modelu je predikce spotřeby energie na základě venkovní teploty. Tato predikce slouží nejčastěji k porovnání s aktuálním stavem. Predikce je použita k analýze změn spotřeby energie v periodických intervalech. Dále je využita ke kvantifikování účinností optimalizačních kroků, a také k detekci anomálií.

V zemích, kde je využívána technologie odezvy na spotřebu (*angl. Demand Response*) lze touto metodou odhadovat také efektivnost odezvy na spotřebu.

■ Časové intervaly a teplotní závislost

Metoda využívá rozdělení dat pracovních dnů do 15 minutových intervalů (první interval pondělí 0:00 – 0:15 atd.). Toto intervalové rozdělení umožňuje přidělení různé predikované zátěže jednotlivým časovým úsekům v týdnu. Dále metoda očekává zátěž závislou na teplotě, kdy se zvyšující se teplotou se zvyšuje chladicí zátěž a se snižující se teplotou se zvyšuje topná zátěž. Pro určité rozmezí teplot může být zátěž nezávislá na teplotě, jelikož není vyžadováno vytápění ani chlazení (tzv. mrtvé pásmo). Při vysokých teplotách, může naopak dojít k situaci, kdy chladicí kapacita zařízení není dostatečná ke splnění požadavku na regulaci vnitřní teploty a dochází k saturaci chladicího výkonu a s ním spojené spotřeby energie. Tento nelineární efekt může být modelován po částech lineárním a spojitým modelem viz Obrázek 2.3.



Obrázek 2.3: Zátěž závislá na venkovní teplotě.[12]

■ Teplotní intervaly

Pro modelování po částech lineárního a spojitého modelu je venkovní teplota rozdělena do 6 ekvidistantních teplotních intervalů. Teplotní parametr β_j je přiřazen ke každému teplotnímu intervalu, kde $j = 1, \dots, 6$. Pro dosažení linearity a spojitosti je venkovní teplota $T(t_i)$ v daném čase t a daném intervalu i (15 minutový interval) rozdělena do šesti teplotních komponent $T_{c,j}(t_i)$, následně přenásobena teplotním parametrem β_j a sečtena pro určení zatížení závislé na teplotě. Pro výpočet teplotní komponent je využit algoritmus 1, kde T_c je teplotní komponenta, t_i konkrétní 15 minutový interval, $T(t_i)$ teplota v konkrétním časovém intervalu, B_n společná okrajová hodnota dvou teplotních intervalů ($n = 1, \dots, 5$) a m počet teplotních komponent ($m = 1, \dots, 6$). Intervaly teplotních komponent jsou vypočteny z rozdílu maximální a minimální venkovní teploty, kde pro venkovní teploty v intervalu (0 – 24 °C) dostáváme teplotní intervaly (0 – 4 °C), (4 – 8 °C), ..., (20 – 24 °C), kde B_1 odpovídá hodnotě 4 °C.

Při rozboru algoritmu 1 bylo zjištěno, že pro interval teplot nezačínající od 0 °C dochází k nechtěnému zvýšení hodnot při výpočtu první teplotní

Algorithm 1: Algoritmus pro výpočet teplotních komponent pro teplotu $T(t_i)$.

Result: Teplotní komponenty $T_{c,m}(t_i), m = 1, \dots, 6$

```

if  $T(t_i) > B_1$  then
  |  $T_{c,1}(t_i) = B_1$ 
else
  |  $T_{c,1}(t_i) = T(t_i)$  a pro  $m = 2, \dots, 6$  platí  $T_{c,m}(t_i) = 0$ 
  | end
if  $T(t_i) > B_n$  pro  $n = 2, \dots, 4$  then
  |  $T_{c,n}(t_i) = B_n - B_{n-1}$ 
else
  |  $T_{c,n}(t_i) = T(t_i) - B_{n-1}$  a pro  $m = (n + 1), \dots, 6$  platí  $T_{c,m}(t_i) = 0$ 
  | end
if  $T(t_i) > B_5$  then
  |  $T_{c,5}(t_i) = B_5 - B_4$  a  $T_{c,6}(t_i) = T(t_i) - B_5$ 
end

```

komponenty, pokud platí $T(t_i) \geq B_1$. Tato problematika včetně návrhu řešení bude dále rozebrána při návrhu metody pro automatickou kontrolu provozu TZB v sekci 4.3.

■ Výpočet celkové zátěže

Výpočet celkové zátěže se liší podle obsazenosti budovy. Parametr β_j je použit jen v případě, kdy je budova v obsazeném režimu. Celková zátěž v obsazeném režimu je určena následující rovnicí


$$\hat{L}_o(t_i, T(t_i)) = \alpha_i + \sum_{j=1}^6 \beta_j T_{c,j}(t_i). \quad (2.2)$$

Pro odhadování zátěže v neobsazeném režimu je použit jednotný parametr β_u , z důvodu očekávaného výskytu zátěže v mrtvém pásmu dle rovnice

$$\hat{L}_u(t_i, T(t_i)) = \alpha_i + \beta_u T(t_i). \quad (2.3)$$

Parametry α_i kde $i = 1, \dots, 480$, β_j kde $j = 1, \dots, 6$ a β_u jsou odhadovány metodou nejmenších čtverců s využitím teplotních dat. Každý z těchto parametrů vyjadřuje část spotřeby energie, kde parametry α udávají základní spotřebu energie budovy v 15 minutových intervalech a parametry β spotřebu energie závislou na změně venkovní teploty.

Na Obrázku 2.4 lze pozorovat aktuální a predikovanou zátěž závislou na teplotě v obsazeném a neobsazeném stavu budovy, kde šedá křivka odpovídá po částech lineární a spojité funkci teploty.



Obrázek 2.4: Aktuální a predikovaná zátěž závislá na venkovní teplotě, kde osa x interpretuje venkovní teplotu a osa y interpretuje spotřebu energie. Horní dva grafy odpovídají režimu obsazenosti a spodní dva grafy režimu neobsazenosti, pravé a levé grafy interpretují zátěž pro různé budovy.[12]

■ Výhody a nevýhody

Většina využívaných metod modeluje spotřebu energie zvláště pro různé časové intervaly.[12] Spotřeba energie v pracovní den a o víkendu stejně jako v obsazeném a neobsazeném režimu se zpravidla liší. Přidáním identifikátoru pracovního dne lze zlepšit přesnost modelu. V případě modelování budovy, která má rozdílnou pracovní dobu pro různé dny v týdnu, nebo některé dny mají trvale vyšší spotřebu energie je nutné zohlednit konkrétní dobu v týdnu. Modelování každého dne zvláště má za důsledek zpřesnění modelu.

Výhodou této metody je zachycení nelineárního vztahu mezi venkovní teplotou a spotřebou energie rozdělením venkovních teplot do několika intervalů a následného vytvoření po částech lineární a spojitě teplotní závislosti. Nevýhodou této metody je potřebné množství dat. Při použití dat z jednotek měsíců nebo kratšího intervalu může nastat přeoptymalizace hodnot parametrů (over-fitting), které budou nadměrně ovlivněny stochastickou variabilitou dat.[12]

Principy využívané metodou LBNL-4944E byly převzaty pro návrh nové metody automatické kontroly provozu TZB v této práci.

Kapitola 3

Metody detekce poruch

V této kapitole je stručně popsáno možné členění metod pro detekci poruch a následně je vybrána vhodná skupina metod pro využití na TZB. Z vybrané skupiny metod jsou diskutovány Markovovy řetězce a metody založené na statistickém a modelovém přístupu. Cílem této kapitoly je vybrat vhodnou metodu detekce poruch, která bude následně využita při návrhu metody automatické kontroly provozu TZB.

Metody detekce poruch mohou být členěny do několika kategorií. V této práci je uvažováno dělení dle charakteru apriorní informace viz Obrázek 3.1. Pro dělení dle charakteru apriorní informace dostáváme následující tři kategorie.[20][18][19]

- **Metody založené na kvalitativním popisu**

Metody v této skupině jsou založené na expertních znalostech daných technologií. S použitím těchto znalostí mohou být vytvořeny diagnostická pravidla popisující fungování dané technologie, která slouží pro odhalení poruch.

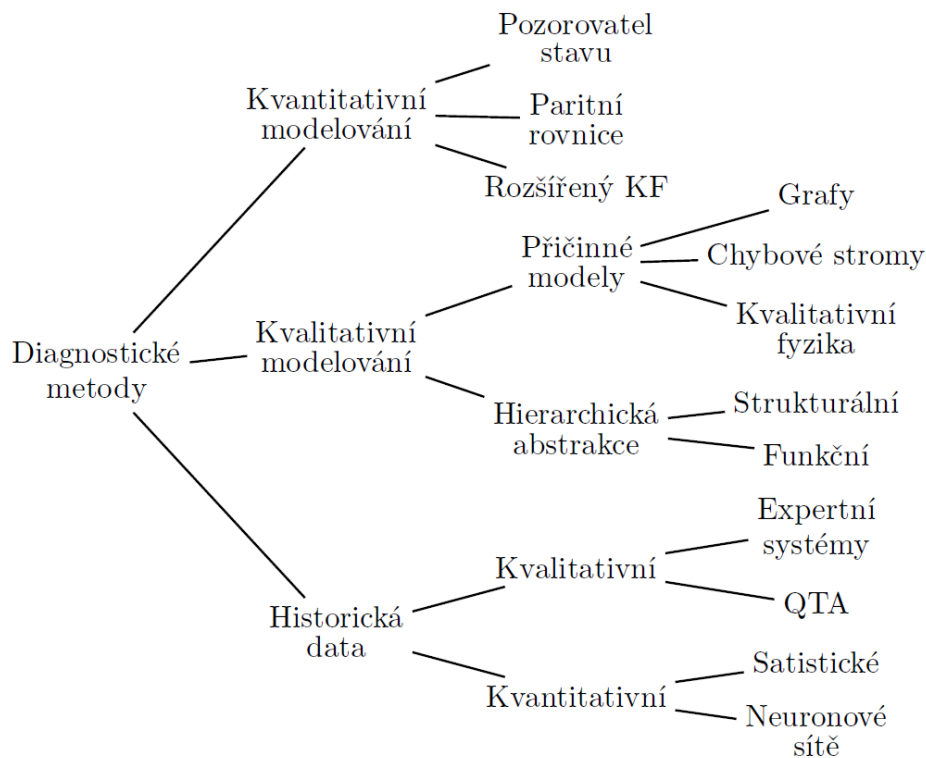
- **Metody založené na kvantitativním popisu**

Tyto metody umožňují výpočty teoretických hodnot jednotlivých veličin a následně modelování poruchových stavů.

- **Metody založené na znalosti historických dat**

V současné době, kdy je nespočet budov a technologií zautomatizováno, je k dispozici velké množství měřených dat. Je proto možné využít metody založené na zpracování provozních dat, kde není zapotřebí expertní znalost konkrétní technologie.

Tato práce je zaměřena na využití statistických metod detekce poruch TZB, které patří do skupiny metod založených na znalosti historických dat.



Obrázek 3.1: Klasifikace metod detekce poruch dle apriorní informace.[20]


3.1 Modelový přístup

Metody založené na modelovém přístupu vychází z podrobné znalosti systému, který je popsán matematickým modelem. Na základě vlastností modelu jsou dále vyhodnocována měřená data a dochází k případné detekci změny chování dané technologie. Změnou lze uvažovat například změnu parametrů modelu nebo také změnu celého modelu. Modelový přístup je vhodné použít zejména pro dynamické systémy.[23]

3.2 Markovovy řetězce

Chování systému lze modelovat pomocí Markovových řetězců. Markovovy řetězce využívají stochastický stavový model, kdy je přechod mezi jednotlivými stavy popsán pomocí pravděpodobnosti. Tento přístup je vhodný i pro modelování náhodných procesů. Na Obrázku 3.2 lze vidět příklad trojstavového systému popsaného pomocí Markovových řetězců.

Modifikované Markovovy řetězce lze využít v kombinaci s metodami Monte Carlo. V literatuře lze najít příklady, kdy Markovovy řetězce dosahují lepších výsledků pro modelování systémů TZB než klasické deterministické metody.[11]



Obrázek 3.2: Trojstavový systém popsany Markovovými retězci.

3.3 Statistický přístup

Metody založené na statistickém přístupu generují rozhodnutí na základě vyhodnocování statistických vlastností reziduálního signálu (tzn. porovnání měřených a předpokládaných hodnot). V této práci jsou statistické vlastnosti reziduálního signálu odhadovány z měřených dat. Mezi způsoby vyhodnocování reziduálního signálu například patří testování hypotéz.

3.3.1 Testování hypotéz

Testování hypotéz je statistická metoda vyjadřující s jakou pravděpodobností odpovídají měřená data testované hypotéze, jestliže je platná. Při testování statistických hypotéz se typicky porovnávají dvě hypotézy. Testování hypotéz se uplatňuje ve vědeckém výzkumu nebo průmyslu obzvláště v oblastech, kde mohou nastat navzájem se vylučující jevy. V této práci je například uvažována otázka – *Odpovídá spotřeba energie budovy pracovnímu dni nebo naopak nepracovnímu?* Stěžejní částí této metody je formulace hypotéz, které bývají označeny jako nulová hypotéza H_0 , jež je testována, a alternativní hypotéza H_1 . Rozhodování mezi hypotézami je založeno na vhodném statistickém modelu pozorované proměnné. Pro vyhodnocení lze využít sekvenční testy, které s každým novým měřením vyhodnocují statistiku definovanou logaritmem poměru věrohodností.[2]

3.3.2 SLR test

SLR (Sequential Likelihood Ratio) nebo-li sekvenční test poměru věrohodností rozhoduje, které pravděpodobností rozdělení odpovídá datové sadě.

Pro aktualizaci statistiky platí následující vztah

$$S_k = S_{k-1} + \ln \frac{p_1(y(k))}{p_0(y(k))}, \quad (3.1)$$

s počáteční podmínkou $S_{-1} = 0$, kde S_k je výsledná statistika, S_{k-1} je statistika v předchozím měření a $\ln \frac{p_1(y(k))}{p_0(y(k))}$ je logaritmus poměru věrohodností. S každým novým měřením je vyhodnocen poměr věrohodnostních funkcí a aktualizovaná statistika je porovnána s parametry α a β následovně:

- Jestliže $S_k \geq \alpha$, tak přijímáme hypotézu H_1 .
- Jestliže $S_k \leq \beta$, tak přijímáme hypotézu H_0 .
- Jestliže $\alpha < S_k < \beta$, tak nepřijímáme žádnou hypotézu a měření pokračuje.

Jedním z využití SLR testu je testování změny střední hodnoty normálního rozdělení na základě logaritmu poměru věrohodností, kde normální rozdělení je popsáno Gaussovou funkcí ve tvaru

$$f_{N(\mu, \sigma^2)}(t) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(t-\mu)^2}{2\sigma^2}}, \quad (3.2)$$

kde μ je střední hodnota a σ^2 je rozptyl.

Pro podmíněnou hustotu pravděpodobnosti se známým rozptylem σ^2 a změnou střední hodnoty μ platí následující

$$p(y|\mu_0) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(y-\mu_0)^2}{2\sigma^2}}, \quad p(y|\mu_1) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(y-\mu_1)^2}{2\sigma^2}}, \quad (3.3)$$

kde μ_0 je původní střední hodnota a μ_1 je střední hodnota po změně.

Pro statistiku $s(y)$ dále platí rovnice (3.4) a (3.5)

$$\ln l(\mu|y) = -\ln \sigma - \frac{1}{2} \ln 2\pi - \frac{(y-\mu)^2}{2\sigma^2}, \quad (3.4)$$

$$s(y) = \ln \frac{l(\mu_1|y)}{l(\mu_0|y)} = -\frac{(y-\mu_1)^2}{2\sigma^2} + \frac{(y-\mu_0)^2}{2\sigma^2} = \frac{\mu_1 - \mu_0}{\sigma^2} \left(y - \frac{\mu_0 + \mu_1}{2} \right). \quad (3.5)$$

Test změny střední hodnoty podmíněné pravděpodobnosti bude dále využíván pro detekci chyb v sekci 6.2.1.[6]

Pro podmíněné hustoty pravděpodobnosti s různým rozptylem σ^2 a různou střední hodnotou μ platí následující

$$p(y|\mu_0, \sigma_0) = \frac{1}{\sigma_0\sqrt{2\pi}} e^{-\frac{(y-\mu_0)^2}{2\sigma_0^2}}, \quad p(y|\mu_1, \sigma_1) = \frac{1}{\sigma_1\sqrt{2\pi}} e^{-\frac{(y-\mu_1)^2}{2\sigma_1^2}}, \quad (3.6)$$

kde μ_0 je střední hodnota a σ_0^2 je rozptyl první hustoty pravděpodobnosti a μ_1 je střední hodnota a σ_1^2 je rozptyl druhé hustoty pravděpodobnosti.

Pro statistiku $s(y)$ dále platí:

$$\ln l(\mu_0, \sigma_0|y) = -\ln \sigma_0 - \frac{1}{2} \ln 2\pi - \frac{(y-\mu_0)^2}{2\sigma_0^2}, \quad (3.7)$$

$$\ln l(\mu_1, \sigma_1|y) = -\ln \sigma_1 - \frac{1}{2} \ln 2\pi - \frac{(y-\mu_1)^2}{2\sigma_1^2}, \quad (3.8)$$

$$s(y) = \ln \frac{l(\mu_1, \sigma_1|y)}{l(\mu_0, \sigma_0|y)} = -\ln \sigma_1 + \ln \sigma_0 - \frac{(y - \mu_1)^2}{2\sigma_1^2} + \frac{(y - \mu_0)^2}{2\sigma_0^2}. \quad (3.9)$$

Tato statistika bude dále použita s využitím metody CUSUM se SLR pro detekování neprovedení útlumu v sekci 6.2.2.[6][23]

3.3.3 CUSUM se SLR

CUSUM (cumulative sum nebo-li kumulované součty) s využitím SLR je metoda využívaná pro detekci změn chování systému. Typickým využitím této metody je online detekce poruchy. Pro názornou ukázkou uvažujme poruchu těsnění rekuperace VZT, při které dojde ke skokovému poklesu efektivity přenosu tepla. Při detekci této poruchy pomocí metody SLR, hodnota S_k klesá až do času poruchy, kdy začne být alternativní hypotéza H_1 (těsnění je rozbité) pravděpodobnější než testovaná hypotéza H_0 . V případě dlouhého časového intervalu, na kterém je detekce prováděna, může hodnota S_k před poruchou dosáhnout vysokých záporných hodnot, které je třeba postupně odintegrovat v čase, kdy je těsnění rozbité. Toto chování vede ke zpoždění detekce. Z tohoto důvodu se zavádí modifikace, kde je hodnota S_k zdola omezena 0 a platí následující rovnice

$$S_k = S_{k-1} + s_k \text{ pro } S_{k-1} + s_k > 0, \quad (3.10)$$

$$S_k = 0 \text{ pro } S_{k-1} + s_k \leq 0. \quad (3.11)$$

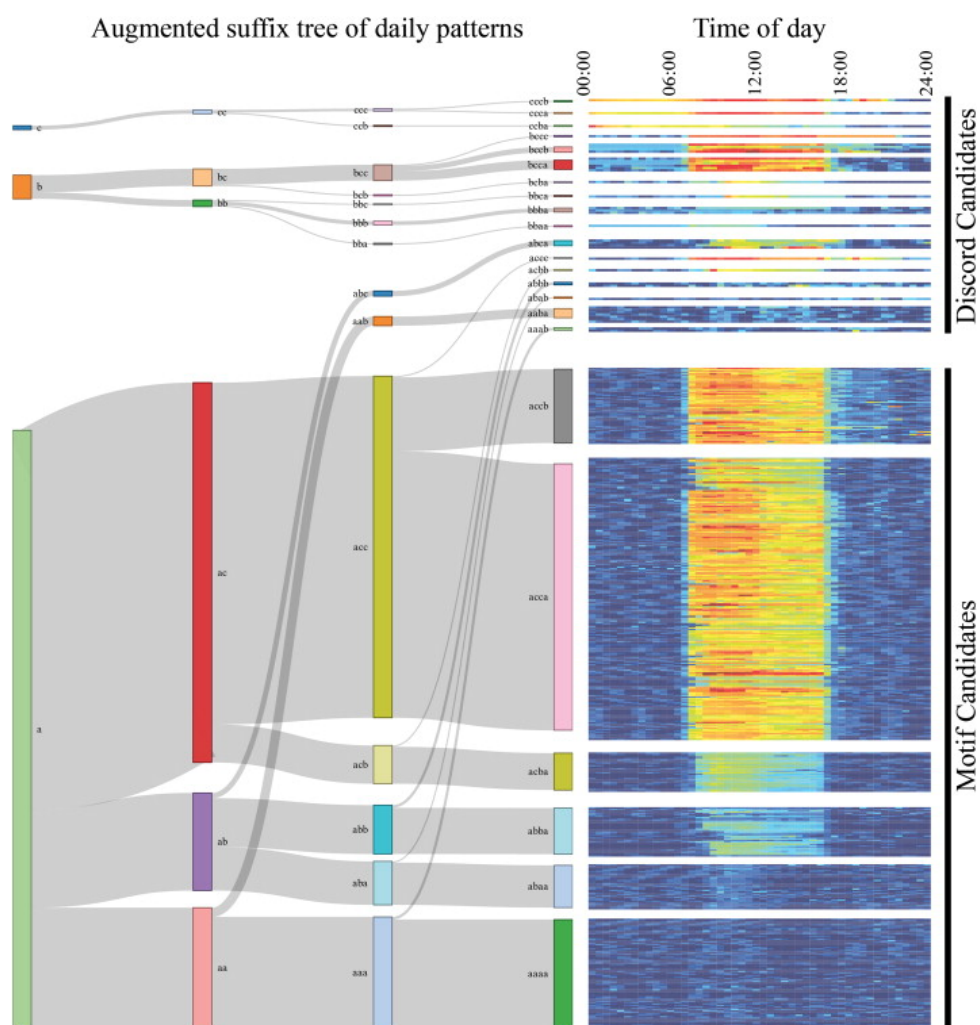
Pro detekci poruchy je třeba vhodně zvolit rozhodovací úroveň. Příliš nízká hodnota úrovně způsobuje falešnou detekci a příliš vysoká zase velké zpoždění detekce. V případě, že je trvání poruchy časově omezené může nevhodně zvolená rozhodovací úroveň způsobit absenci detekce.[6]

3.4 Automatické filtrování dat pomocí denních profilů

Automatické filtrování dat pomocí denních profilů [13] je zde popsáno z důvodu vhodné ukázkou spojení metody modelování závislostí s metodou detekce poruchy s využitím znalosti historických dat, i když se nejedná o statistickou metodu detekce poruchy.

Automatické identifikování denních profilů v měřených datech umožňuje kontrolu provozu budovy a detekce chyb. Tato metoda je založená na metodě "DayFilter", která slouží k typování dnů symbolickým vyjádřením s jehož pomocí jsou hledány periodické denní profily které slouží k reprezentaci základní spotřeby energie budov a nepravidelné denní profily. Nepravidelné denní profily jsou následně filtrovány a označeny pro další analýzu, jež slouží k odhalení poruch. Následně jsou denní profily podle podobnosti vizualizovány. Vzorový příklad je na Obrázku 3.3, kde "Motif Candidates" jsou opakované denní profily a "Discord Candidates" jsou nepravidelné denní profily. Část "Augmented suffix tree of daily patterns" vyjadřuje rozšířené symbolické

označení pro jednotlivé denní profily a "Time of day" vyjadřuje čas v rámci dne.[13] Při použití této metody je limitující dělení na časová pásma.



Obrázek 3.3: Spotřeba elektrické energie reprezentovaná denními profily – metoda "DayFilter".[13]

3.5 Shrnutí

V této kapitole bylo představeno možné členění metod detekce poruch, z kterých byly dále vybrány metody založené na znalosti historických dat. Z těchto metod byly blíže popsány statistické metody, modelový přístup a Markovovy řetězce. Pro další části práce byly vybrány statistické metody, které nemají velké nároky na detailní popis modelu. S využitím statistických metod bude dále pomocí testování hypotéz a metody CUSUM se SLR testováno neprovedení útlumu a odchýlení měřené spotřeby energie od spotřeby energie predikované. V závěru této kapitoly byl stručně popsán princip metody využívající symbolické vyjádření k modelování opakujících se denních profilů,

kde jsou dále detekovány poruchy analýzou nepravidelných denních profilů. Tato metoda je využívána v oblasti TZB a je jednou z mála využívající modelování závislostí k následné detekci. Obdobný způsob kombinace metody modelování závislostí a metody statistických detekcí poruch bude použit při návrhu metody pro automatickou kontrolu provozu TZB v další kapitole.

Kapitola 4

Návrh metody pro automatickou kontrolu provozu TZB

V této kapitole je popsán návrh metody pro automatickou kontrolu provozu TZB (dále metoda AKP). Při návrhu této metody byl kladen důraz na co největší využitelnost. Jinými slovy, aby bylo možné modelovat spotřebu energie pro co nejvíce různých typů budov, nejen pro kancelářské budovy a budovy, které jsou obsazeny pouze v klasickém pracovním týdnu, ale také pro budovy a zařízení, která bývají v provozu i o víkendech (např. nemocnice, obchodní centra, průmyslové budovy). Dalším cílem bylo vytvořit metodu, kde bude vhodným použitím statistických metod pro detekci poruch kontrolováno provedení resp. neprovedení útlumu spotřeby energie či odchýlení měřené spotřeby energie od predikované hodnoty.

Tato kapitola je rozdělena na dvě části, v první části kapitoly bude modifikován a upraven model LBNL-4944E a v druhé části kapitoly bude model rozšířen tak, aby mohl být využit pro statistické testování hypotéz.

Základem pro návrh metody AKP byl model LBNL-4944E. Pro tento model jsou parametry, používané pro predikci spotřeby energie, odhadovány metodou nejmenších čtverců, viz sekce 2.1.2. Při návrhu metody AKP na základě modelu LBNL-4944E bylo zapotřebí navrhnout, modifikovat nebo vyřešit tyto úlohy:

- **Zobecnění využití časových intervalů.**
- **Přizpůsobení režimu obsazenosti a neobsazenosti budov.**
- **Modifikace algoritmu pro výpočet teplotních komponent.**
- **Využitelnost teplotních intervalů pro neobsazený režim.**

Aby bylo možné použít metodu AKP k statistické detekci poruch, je zapotřebí k deterministickému modelu přidat stochastickou část. Pro tuto metodu bylo na základě kapitoly 3 vybráno testování hypotéz a metoda CUSUM se SLR. Přidáním stochastické části do metody je možné postihnout rozdílné odchylky v různých časových intervalech a v rozdílných částech týdne. Příkladem může být rozdílná váha odchylky zátěže budovy ve dne a v noci, kdy při stejné odchylce může ve dne docházet k zanedbatelným výkyvům spotřeby energie, ale naopak v noci bude odchylka tvořit významnou část zátěže budovy.

4.1 Zobecnění využití časových intervalů

Jelikož model LBNL-4944E zohledňuje pouze zátěž pro typický pětidenní pracovní týden, bylo nutné provést zobecnění využití časových intervalů. Z tohoto důvodu byla metoda AKP navržena tak, aby bylo možné modelovat celotýdenní spotřebu energie budov. Metoda AKP uvažuje klasický sedmidenní týden. Pro víceúčelové využití metody AKP (tzn. využití pro více druhů různých budov) musí být metoda doplněna o další den, sloužící k modelování zátěže budovy v neobsazeném režimu. Při navrhování metody AKP bylo uvažováno, že v neobsazeném režimu by měla být v jednotlivé časové úseky část spotřeby energie budovy neměnná. V případě budovy fungující v klasickém pětidenním provozu bude spotřeba energie v sobotu a neděli modelována v neobsazeném režimu. Uvažujeme tedy, že část spotřeby energie budovy v časovém intervalu (0:00 – 0:15) v sobotu bude stejná jako v neděli ve stejný časový interval.

V neobsazeném režimu by se měla v jednotlivé časové intervaly měnit pouze část spotřeby energie závislá na změně venkovní teploty.

Obdobně jako u modelu LBNL-4944E, bylo při návrhu metody AKP uvažováno rozdělení měřených dat do 15 minutových intervalů, kde parametry α_i^o pro $i = 1, \dots, 672$ náleží jednotlivým 15 minutovým intervalům v týdnu za podmínky obsazeného režimu a parametry α_i^u pro $i = 1, \dots, 96$ náleží jednotlivým 15 minutovým intervalům ve dni za podmínky neobsazeného režimu (parametr α_1^u odpovídá časovému úseku 0:00 – 0:15).

4.2 Přizpůsobení režimu obsazenosti a neobsazenosti budovy

Jedním z uplatnění metody AKP má být vhodná použitelnost pro testování hypotéz, konkrétně testování provedení útlumu a odchýlení měřené spotřeby energie od predikované hodnoty. Jelikož naprostá většina budov funguje s jistým zpožděním od akčního zásahu, počátek zvyšování spotřeby energie za cílem dosažení požadované teploty, dochází v budovách často k nemalým spotřebám energie i v režimu neobsazenosti.

V praxi bývá běžně spuštěno chlazení v budově několik hodin před začátkem pracovní doby, aby byl dosažen teplotní komfort už se začátkem provozu v budově. Z tohoto důvodu byla metoda AKP navržena, oproti modelu LBNL-4944E, který uvažuje v daný den v jednotlivé časové intervaly různé režimy obsazenosti, následovně: Jestliže byla budova v konkrétním dnu alespoň v jednom časovém intervalu obsazena, byl tento den brán jako obsazený, v opačném případě byla budova v neobsazeném režimu.

Model LBNL-4994E byl navržen pro technologii odezvy na spotřebu (*angl. Demand Response*), která je v USA velmi rozšířená. Tato technologie je založená na aktivní možnosti ovlivňovat zatížení v síti, kde je zákazník za změnu spotřeby odměňován a tato možnost změny náleží ve většině případů přímo zákazníkovi. V České republice je tato technologie ve fázi

testování. Podle evropské asociace lze tuto technologii v Evropě v ostrém provozu očekávat nejdříve v roce 2030.[8] Z tohoto důvodu bylo pojetí obsazeného a neobsazeného režimu přizpůsobeno k využití pro testování hypotéz a následné detekci neprovedení útlumu a odchylky měřené spotřeby energie od predikované hodnoty.

4.3 Modifikace algoritmu pro výpočet teplotních komponent

Při implementaci tohoto algoritmu bylo vycházeno z modelu LBNL-4944E. V rozboru algoritmu pro výpočet teplotních komponent viz algoritmus 1 bylo odhaleno, že při intervalu teplot nezačínající od teploty 0 °C dochází k chybnému zvýšení hodnoty v první teplotní komponentě. Například, pokud nejnižší vyskytnutá venkovní teplota byla 0 °C a nejvyšší 24 °C jsou výsledné teplotní komponenty pro konkrétní teploty uvedeny v Tabulce 4.1:

T	$T_{c,1}$	$T_{c,2}$	$T_{c,3}$	$T_{c,4}$	$T_{c,5}$	$T_{c,6}$
0	0	0	0	0	0	0
4	4	0	0	0	0	0
9	4	4	1	0	0	0
13	4	4	4	1	0	0
17	4	4	4	4	1	0
24	4	4	4	4	4	4

Tabulka 4.1: Výsledné teplotní komponenty pro interval venkovních teplot 0 °C – 24 °C, kde T vyjadřuje konkrétní teplotu a $T_{c,j}$ odpovídá jednotlivým teplotním komponentám pro danou teplotu.

Naopak pokud nejnižší vyskytnutá venkovní teplota nebyla 0 °C, například bude nejnižší venkovní teplota 4 °C a nejvyšší 28 °C, dostáváme interval první komponenty (4 – 8 °C) a hodnotu $B_1 = 8$ °C, kde v první teplotní komponentě $T_{c,1}$ dochází k navýšení hodnot viz Tabulka 4.2. Je zřejmé, že nedostáváme stejný přírůstek v každé teplotní komponentě a první komponenta bude mít větší váhu.

T	$T_{c,1}$	$T_{c,2}$	$T_{c,3}$	$T_{c,4}$	$T_{c,5}$	$T_{c,6}$
4	4	0	0	0	0	0
9	8	1	0	0	0	0
13	8	4	1	0	0	0
17	8	4	4	1	0	0
21	8	4	4	4	1	0
28	8	4	4	4	4	4

Tabulka 4.2: Výsledné teplotní komponenty pro interval venkovních teplot 4 °C – 28 °C, kde T vyjadřuje konkrétní teplotu a $T_{c,j}$ odpovídá jednotlivým teplotním komponentám pro danou teplotu.

Pro vyřešení tohoto problému byl algoritmus modifikován tak, že je odečítána nejnižší vyskytnutá teplota od teploty v první teplotní komponentě. Algoritmus 2 je modifikovaný algoritmus 1, kde nově přidaná proměnná T_{min} reprezentuje nejnižší vyskytnutou teplotu.

Algorithm 2: Modifikovaný algoritmus pro výpočet teplotních komponent pro teplotu $T(t_i)$, kde je od první teplotní komponenty odečítána nejnižší teplota T_{min} .

Result: Teplotní komponenty $T_{c,m}(t_i), m = 1, \dots, 6$

```

if  $T(t_i) > B_1$  then
  |  $T_{c,1}(t_i) = B_1 - T_{min}$ 
else
  |  $T_{c,1}(t_i) = T(t_i) - T_{min}$  a pro  $m = 2, \dots, 6$  platí  $T_{c,m}(t_i) = 0$ 
  end
if  $T(t_i) > B_n$  pro  $n = 2, \dots, 4$  then
  |  $T_{c,n}(t_i) = B_n - B_{n-1}$ 
else
  |  $T_{c,n}(t_i) = T(t_i) - B_{n-1}$  a pro  $m = (n + 1), \dots, 6$  platí  $T_{c,m}(t_i) = 0$ 
  end
if  $T(t_i) > B_5$  then
  |  $T_{c,5}(t_i) = B_5 - B_4$  a  $T_{c,6}(t_i) = T(t_i) - B_5$ 
end

```

V Tabulce 4.3 je ukázka vypočtených teplotních komponent s využitím modifikovaného algoritmu 2, kde nejnižší teplota byla $4\text{ }^\circ\text{C}$ a nejvyšší teplota byla $28\text{ }^\circ\text{C}$.

T	$T_{c,1}$	$T_{c,2}$	$T_{c,3}$	$T_{c,4}$	$T_{c,5}$	$T_{c,6}$
4	0	0	0	0	0	0
9	4	1	0	0	0	0
13	4	4	1	0	0	0
17	4	4	4	1	0	0
21	4	4	4	4	1	0
28	4	4	4	4	4	4

Tabulka 4.3: Výsledné teplotní komponenty pro interval venkovních teplot $4\text{ }^\circ\text{C} - 28\text{ }^\circ\text{C}$, kde T vyjadřuje konkrétní teplotu a $T_{c,j}$ odpovídá jednotlivým teplotním komponentám pro danou teplotu.

Z Tabulky 4.3 je zřejmé, že přírůstek v každé teplotní komponentě může dosahovat stejných hodnot. Algoritmus z Obrázku 2 je použit při trénování modelu metodou AKP. Pro predikci s využitím metody AKP je zapotřebí další modifikace. Důvody pro další modifikaci a její řešení je popsáno v sekci 5.4.

4.4 Využitelnost teplotních intervalů pro neobsazený režim

Teplotní intervaly byly využity z důvodu zachování po částech lineárního a spojitého modelu viz sekce 2.1.2. Model LBNL-4944E uvažuje v nepracovní dny zátěž budovy v mrtvém pásmu viz Obrázek 2.3, teplotní komponenty jsou tedy vypočítávány pouze pro pracovní dny.

Při návrhu nového modelu byla brána v potaz i skutečnost, že v nepracovní dny nemusí být zátěž v mrtvém pásmu (tzn. spotřeba energie budovy se nemění). Model byl navržen takovým způsobem, aby postihl po částech lineární a spojitou závislost na teplotě i v nepracovní dny. Pro modelování po částech lineárního a spojitého modelu je teplota, obdobně jako u modelu LBNL-4944E, rozdělena do 6 ekvidistantních teplotních intervalů. Hlavním rozdílem od modelu LBNL-4944E je výpočet teplotních intervalů jak pro obsazený režim, tak i neobsazený režim. Dostáváme tedy teplotní parametr β_j^o přiřazený ke každému teplotnímu intervalu pro obsazený režim, kde $j = 1, \dots, 6$. Pro neobsazený režim je ke každému teplotnímu intervalu přiřazen teplotní parametr β_j^u , kde $j = 1, \dots, 6$.

Pro odhadování zátěže v obsazeném režimu je použita stejná rovnice (viz rovnice (2.2)) jako pro model LBNL-4944E s parametry ze sekcí 4.1 a 4.4 ve tvaru

$$\hat{L}_o(t_i, T(t_i)) = \alpha_i^o + \sum_{j=1}^6 \beta_j^o T_{c,j}(t_i), \quad (4.1)$$

kde parametr α_i^o vyjadřuje část zátěže nezávislou na teplotě v konkrétní časový interval v týdnu a $\sum_{j=1}^6 \beta_j^o T_{c,j}(t_i)$ vyjadřuje část zátěže, která je závislá na teplotě v konkrétní časový interval v týdnu.

Pro odhadování zátěže v neobsazeném režimu je rovnice modelu LBNL-4944 (viz rovnice (2.3)) nahrazena následující rovnicí

$$\hat{L}_u(t_i, T(t_i)) = \alpha_i^u + \sum_{j=1}^6 \beta_j^u T_{c,j}(t_i), \quad (4.2)$$

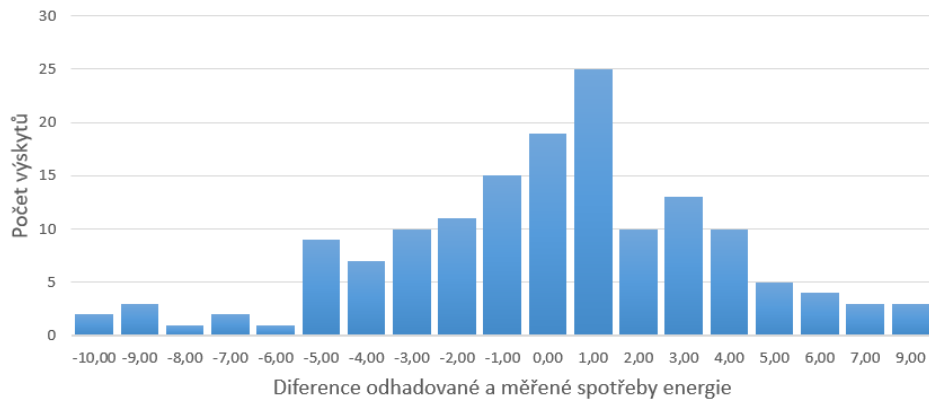
kde parametr α_i^u vyjadřuje část zátěže nezávislou na teplotě v konkrétní časový interval ve dni a $\sum_{j=1}^6 \beta_j^u T_{c,j}(t_i)$ vyjadřuje část zátěže, která je závislá na teplotě v konkrétní časový interval ve dni.

4.5 Výpočet směrodatných odchylek modelu

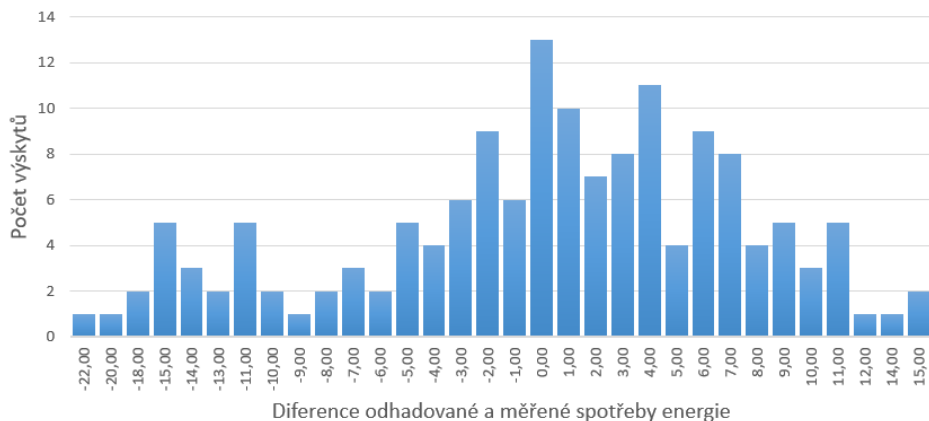
Pro využití testování hypotéz a metody CUSUM se SLR je nutné doplnit k metodě AKP výpočet směrodatné odchylky. Směrodatná odchylka je vypočtena z rozdílu odhadované a měřené spotřeby energie.

Z grafů (Obrázky 4.1, 4.2 a 4.3) je patrné, že se rozptyl zásadně liší v jednotlivých částech dne a v rámci režimů budovy. Dva z těchto grafů (Obrázek 4.1 a 4.2) znázorňují rozdíl odhadované a měřené spotřeby energie během obsazeného režimu, každý pro jiný časový úsek ve dni. Třetí graf

(Obrázek 4.3) obsahuje data z neobsazeného režimu. Data pro tyto grafy pocházejí z velké administrativní budovy, která funguje v režimu pětidenního pracovního týdne.

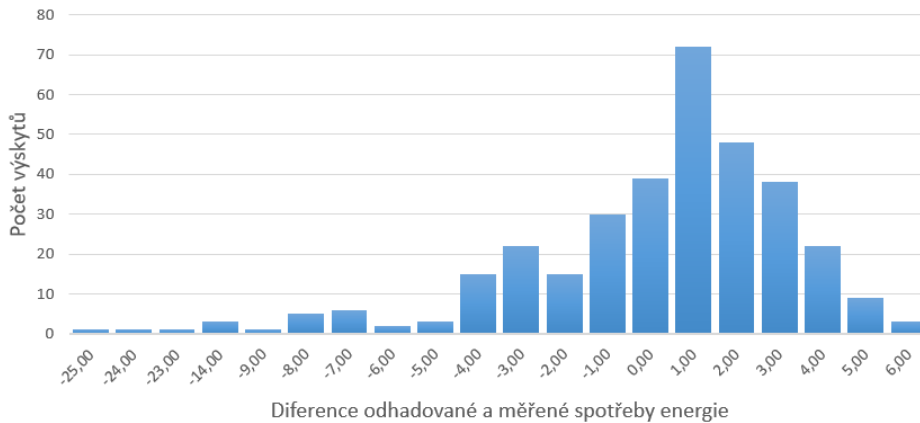


Obrázek 4.1: Histogram rozdílů odhadované a měřené spotřeby energie [kW] pro 15 minutový interval α_{497}^o v obsazeném režimu, který odpovídá pátku v době 4:00 – 4:15 v noci.



Obrázek 4.2: Histogram rozdílů odhadované a měřené spotřeby energie [kW] pro 15 minutový interval α_{417}^o v obsazeném režimu, který odpovídá čtvrtku v době 8:00 – 8:15 ráno.

Z porovnání grafů (Obrázek 4.1 a 4.2) je vidět rozdílný rozptyl pro denní a noční dobu v obsazeném režimu, kde rozptyl v denní dobu (Obrázek 4.2) několikanásobně převyšuje rozptyl v noční dobu. Tato ukázka vhodně ilustruje rozdíl mezi noční spotřebou energie budovy, kde budova nemá velké požadavky na spotřebu energie a nedochází k takové variabilitě dat, a denní spotřebou, kde velkou variabilitu dat způsobuje několik faktorů. Mezi takové faktory například patří neperiodická spotřeba energie zařízeními jako jsou počítače, tiskárny, kávovary či rychlovarné konvice.



Obrázek 4.3: Histogram rozdílů odhadované a měřené spotřeby energie [kW] pro 15 minutový interval α_{71}^u v neobsazeném režimu, který odpovídá době 17:00 – 17:15.

Z grafu (Obrázek 4.3) pro neobsazený režim lze pozorovat obdobně malý rozptyl jako v nočním provozu budovy v obsazeném režimu viz Obrázek 4.1, kde stejně jako pro noční provoz v nepracovní den dochází k malé variabilitě dat.

Na základě výše přiložených grafů (Obrázky 4.1, 4.2 a 4.3), jsou rozdíly odhadované a měřené spotřeby energie považovány za normální (Gaussovo) pravděpodobnostní rozdělení, toto rozdělení bylo dále uvažováno i při využití testování hypotéz a metody CUSUM se SLR. Testování hypotéz pomocí metody CUSUM se SLR umožňuje použití i jiných rozdělení než je rozdělení normální.

Směrodatné odchylky jsou brány v potaz pouze pro 15 minutové intervaly dat, uvažujme tedy že predikovaná spotřeba energie metodou AKP je střední hodnota a měřená spotřeba energie je odchylkou od střední hodnoty. Pro výpočet výběrové směrodatné odchylky platí následující vztah

$$s = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2}, \quad (4.3)$$

kde x_i je měřená spotřeba energie, \bar{x} predikovaná spotřeba energie a N počet měření. Jestliže jsou směrodatné odchylky uvažovány pouze pro 15 minutové intervaly, bude pro každý z těchto intervalů vypočítána směrodatná odchylka. Takto získáme směrodatné odchylky pro všechny intervaly z datové sady, která byla využita k odhadu parametrů modelu metodou AKP. Pro ukázkou, při roční datové sadě (52 týdnů) dostáváme v zjednodušeném případě pro výpočet směrodatné odchylky pro každý konkrétní 15 minutový interval 52 hodnot. V praxi je ovšem zapotřebí brát v potaz výskyt státních svátků, možný výpadek měření v různé časové úseky a také fakt, že v roční datové sadě není každý den obsažen stejným počtem. U klasického pětidenního týdne dostáváme pro výpočet konkrétního 15 minutového intervalu pro neobsazený

režim minimálně dvojnásobek hodnot pro výpočet směrodatné odchylky, jelikož každá sobota a neděle je brána jako nepracovní den a spotřeba energie v tyto dny je modelována jako jeden nepracovní den viz sekce 4.1. Názorná ukáзка predikce spotřeby energie s výpočtem směrodatných odchylek je graficky znázorněna na Obrázku 5.2.

Kapitola 5

Implementace modelu

V této kapitole je popsána implementace metody AKP navržené v kapitole 4. Dále bude stručně představeno prostředí SkySpark, které bylo k implementaci modelu využito.

5.1 Prostředí SkySpark

Prostředí SkySpark Analytics¹ je založené na výkonné Folio databázi, která byla navržena pro IoT (Internet of Things – síť zařízení, senzorů atd.). SkySpark pracuje s různými typy dat, nejčastější možností bývá připojení k chytrému čidlu, řídicímu systému či import historických dat ze souborů aplikace Microsoft Excel. Pro zpracování těchto dat je využíván průmyslový standard Project Haystack² pro sémantické značení dat. Tento standard je volně dostupný a slouží mimo jiné k efektivnímu zpracování dat získaných z IoT. Využití prostředí SkySpark umožňuje uživateli jednoduše analyzovat provozní data pomocí integrovaných funkcí. Pro pokročilejší uživatele je možné implementovat vlastní funkcionalitu pomocí skriptovacího jazyku AXON. Jednou z předností tohoto prostředí je velmi snadná vizualizace dat.

5.2 Trénování modelu

Metoda AKP byla implementována v prostředí SkySpark pomocí skriptovacího jazyku AXON s využitím interních knihoven. Prostředí SkySpark využívá několik knihoven, jednou z nich je knihovna Smile³ (Statistical Machine Intelligence and Learning Engine), která je použita k trénování modelů v této práci. Pro odhad parametrů pomocí metody nejmenších čtverců byly využity funkce z této knihovny – *mlOls* a *mlTrain*. Pro využití těchto funkcí bylo nutné sestavit vstupní matici hodnot obsahující teplotní intervaly pro obsazený i pro neobsazený režim s přiřazením konkrétních časových intervalů a spotřebou energie v daný časový interval.

Ukázku části vstupní matice lze vidět na Obrázku 5.1, kde první sloupec

¹<https://skyfoundry.com/>

²<https://project-haystack.org/>

³<https://haifengl.github.io/>

reprezentuje spotřebu energie v jednotlivých časových intervalech, sloupce $tcO1, \dots, tcO6$ odpovídají teplotním komponentám v obsazeném režimu, sloupce $tcU1, \dots, tcU6$ vyjadřují teplotní komponenty v neobsazeném režimu, sloupce $a096, a097, a098$ určují konkrétní 15 minutový interval v obsazeném režimu a sloupce $aU094, aU095$ interpretují konkrétní 15 minutový interval v neobsazeném režimu.

ENERGO ENE...	tcO1	tcO2	tcO3	tcO4	tcO5	tcO6	tcU1	tcU2	tcU3	tcU4	tcU5	tcU6	a096	a097	a098	aU094	aU095
0,022kW							2,167	2,167	0,667	0	0	0					
0,033kW							2,167	2,167	0,417	0	0	0					
0,022kW							2,167	2,167	0,167	0	0	0					
0,033kW							2,167	2,083	0	0	0	0					
0,078kW							2,167	1,833	0	0	0	0					
0,033kW							2,167	1,583	0	0	0	0					
0kW							2,167	1,333	0	0	0	0					
0,056kW							2,167	1,083	0	0	0	0					
0,067kW							2,167	0,833	0	0	0	0					
0,022kW							2,167	0,833	0	0	0	0					
0,011kW							2,167	0,833	0	0	0	0					
0,011kW							2,167	0,833	0	0	0	0					
0,011kW							2,167	0,833	0	0	0	0					
0,045kW							2,167	0,833	0	0	0	0					
0,033kW							2,167	0,833	0	0	0	0				1	
0,045kW							2,167	0,833	0	0	0	0					1
0,089kW	2,167	0,833	0	0	0	0							1				
0,078kW	2,167	0,833	0	0	0	0								1			
0,033kW	2,167	0,833	0	0	0	0									1		
0,067kW	2,167	0,833	0	0	0	0											
0,011kW	2,167	0,833	0	0	0	0											
0,056kW	2,167	0,583	0	0	0	0											
0,011kW	2,167	0,333	0	0	0	0											
0,078kW	2,167	0,083	0	0	0	0											
0,044kW	2	0	0	0	0	0											
0,056kW	2	0	0	0	0	0											
0,078kW	2	0	0	0	0	0											
0,0001kW	2	0	0	0	0	0											
0,044kW	2	0	0	0	0	0											
0,056kW	2	0	0	0	0	0											
17,81kW	2	0	0	0	0	0											
39,16kW	2	0	0	0	0	0											
43,24kW	2	0	0	0	0	0											

Obrázek 5.1: Ukázka vstupní matice pro odhad parametrů modelu metodou AKP v prostředí SkySpark.

5.3 Výstup metody AKP

Výstupem metody AKP je odhad parametrů α_i^o pro $i = 1, \dots, 672$, α_i^u pro $i = 1, \dots, 96$, β_j^o pro $j = 1, \dots, 6$, β_j^u pro $j = 1, \dots, 6$ a také konstantní člen. Parametry α_i^o přiřazují konkrétnímu 15 minutovému intervalu v obsazeném režimu spotřebu energie určující část základní spotřeby energie budovy. V neobsazeném režimu tomu odpovídají parametry α_i^u . Po částech spojitou a lineární závislost spotřeby energie na teplotě vyjadřují β_j^o a β_j^u , kde β_j^o odpovídá obsazenému režimu a β_j^u režimu neobsazenému.

V dalších sekcích je názorně ukázán vliv typu budovy na odhadnuté

parametry. Pro tuto ukázkou byly využity datové sady ze čtyř různých budov, které se navzájem liší co do množství spotřebované energie, tak i zařízeními využívaných pro chlazení či vytápění budovy. První budovou je administrativní budova, ve které většinu spotřeby energie tvoří elektrické vytápění. Druhou budovou je velká administrativní budova, ve které je naopak dominantní chladicí výkon pro udržování teplotního komfortu v budově. Další budovou je monoblok ČVUT Fakulty elektrotechnické a Fakulty strojní v Dejvicích, která je specifická velkým počtem faktorů promítajících se do spotřeby energie. Těmito faktory jsou například: hlavní provoz ve výukovém období (semestr mívá obvykle 14 výukových týdnů), výskyt několika týdnů prázdnin, velký počet laboratorních zařízení a počítačů fungujících v nepravidelných intervalech, servery, které i v neobsazeném režimu spotřebovávají několik stovek kW, a v neposlední řadě menší vytíženost v páteční dny. Posledním typem budovy je budova se sedmidenním provozem, jejíž spotřebu energie tvoří převážně chladicí výkon.

Křivky závislosti spotřeby energie na teplotě jsou omezeny nejnižší a nejvyšší teplotou vyskytnutou v množině trénovacích dat viz sekce 5.4.


■ 5.3.1 Malá administrativní budova využívající převážně topný výkon

Na Obrázcích 5.2, 5.3, 5.4 a 5.5 jsou graficky znázorněny závislosti spotřeby energie s využitím odhadnutých parametrů α^o , α^u , β^o a β^u modelu menší administrativní budovy. Na Obrázku 5.2 je graficky znázorněn vliv dne v týdnu a času během dne na spotřebu energie budovy v obsazeném režimu s využitím parametrů α^o . Z tohoto grafu lze vypočítat (pozn. administrativní budova je provozována v klasickém osmihodinovém provozu), že v ranních hodinách (zhruba kolem páté hodiny) dochází k zvyšování spotřeby energie, z důvodu docílení teplotního komfortu v budově do doby začátku osmihodinové pracovní doby.


Stejný trend můžeme vypočítat i ve večerních hodinách, kdy postupem času dochází k útlumu spotřeby energie po konci pracovní doby. Obrázek 5.3 názorně zobrazuje vliv času během dne na spotřebu energie budovy v neobsazeném režimu, kdy se spotřeba energie budovy oproti obsazenému režimu téměř nemění. V neobsazeném režimu musí být však brána v potaz možná spotřeba energie spojená s provozem serverů, vypočetních zařízení a dalších zařízení, které fungují i v neobsazeném režimu. U grafů zobrazujících vliv venkovní teploty na spotřebu energie s využitím parametrů β^o a β^u (Obrázek 5.4, 5.5) lze názorně ukázat vliv elektrického vytápění administrativní budovy, kde s nižší teplotou dochází k větší spotřebě energie, pro udržování teplotního komfortu v budově. Z obou grafů je zřejmé, že pro teplotu zhruba 17 °C, což je v obou grafech nejnižší bod (dále mrtvé pásmo), není spotřebována energie ani pro vytápění a ani pro chlazení. S výskytem nižších teplot od mrtvého pásma roste spotřeba energie pro vytápění budovy a naopak s výskytem vyšších teplot roste spotřeba energie pro chlazení budovy.

Rozdílem mezi režimy je výše spotřeby energie pro chlazení a pro vytápění.

Většina budov funguje v neobsazeném režimu v tzv. udržovacím provozu, kdy spotřeba energie budovy není nulová, ale dochází k udržování nižší požadované teploty než v obsazeném režimu, například z důvodů, aby při nízkých venkovních teplotách nedocházelo k promrzání budovy. Udržovací provoz budovy je také často používán z důvodu rychlejšího docílení teplotního komfortu při přechodu z neobsazeného režimu do režimu obsazeného, obvykle v řádu několika hodin. Při porovnání spotřeby energie pro oba režimy lze konstatovat, že spotřeba energie v obsazeném režimu je vyšší. Příčinou je různá požadovaná teplota pro teplotní komfort v budově v různých režimech. Stejný princip lze uvažovat i pro spotřebu energie pro vytápění, kde je pro nižší teploty v obsazeném režimu spotřebováno více energie.



Obrázek 5.2: Graf znázorňující vliv dne v týdnu a času během dne na spotřebu energie s využitím odhadnutých parametrů α_2^o modelu malé administrativní budovy v obsazeném režimu pro pětidenní pracovní týden, kde většinu spotřeby energie tvoří elektrické vytápění. Osa x interpretuje jednotlivé časové intervaly vizualizovány jako pracovní dny v týdnu a osa y spotřebu energie v daný časový úsek.



Obrázek 5.3: Graf znázorňující vliv dne v týdnu a času během dne na spotřebu energie s využitím odhadnutých parametrů α_2^u modelu malé administrativní budovy v neobsazeném režimu, kde většinu spotřeby energie tvoří elektrické vytápění. Osa x interpretuje jednotlivé časové intervaly vizualizovány v hodinách a osa y spotřebu energie v daný časový úsek.




Obrázek 5.4: Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^o modelu malé administrativní budovy v obsazeném režimu, kde většinu spotřeby energie tvoří elektrické vytápění. Osa x interpretuje venkovní teplotu a osa y relativní změnu spotřeby energie pro danou venkovní teplotu.



Obrázek 5.5: Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^u modelu malé administrativní budovy v neobsazeném režimu, kde většinu spotřeby energie tvoří elektrické vytápění. Osa x interpretuje venkovní teplotu a osa y relativní změnu spotřeby energie pro danou venkovní teplotu.

5.3.2 Velká administrativní budova využívající převážně chladič výkon

Další budovou na které bude názorně ukázán vliv typu budovy na odhadnuté parametry je velká administrativní budova využívající spotřebu energie převážně pro chlazení fungující v klasickém osmihodinovém provozu. Z grafu (Obrázek 5.6) znázorňující vliv dne v týdnu a času během dne na spotřebu energie je zřejmé, že na rozdíl od přechodného typu budovy zde dochází k zvyšování spotřeby energie z důvodu docílení teplotního komfortu v čase začátku pracovní doby, již kolem druhé hodiny ranní. Hlavní rozdíl od předchozího typu budovy je ve spotřebě energie závislé na venkovní teplotě odpovídající parametrům β . Z grafů (Obrázek 5.7, 5.8) lze vypočítat, že se zvyšující se teplotou dochází k zvýšení spotřeby energie pro chlazení. V případě obsazeného režimu (Obrázek 5.7) dochází k strmějšímu růstu spotřeby energie z důvodu udržování teplotního komfortu, kdy v obsazeném režimu bude požadovaná teplota v budově nižší než v neobsazeném režimu. Pro nízké teploty je v neobsazeném režimu z grafu (Obrázek 5.8) patrné, že spotřeba energie není využívána k vytápění. Naopak z grafu (Obrázek 5.7) pro obsazený režim lze říci, že pro nízké teploty roste spotřeba energie. Na Obrázku 5.6 pro obsazený režim je znázorněn celý týden. Mohlo by se zdát, že v sobotu a neděli (neobsazený režim) dochází k větší spotřebě energie (pouze hodnota konstantního členu odhadnutého metodou nejmenších čtverců) než v pozdních večerních a brzkých ranních hodinách v obsazeném režimu. Obrázek 5.6, však interpretuje pouze vliv dne v týdnu a času během dne na spotřebu energie v obsazeném režimu. Neobsazené dny jsou zde ponechány pro lepší interpretovatelnost režimů budov.



Obrázek 5.6: Graf znázorňující vliv dne v týdnu a času během dne na spotřebu energie s využitím odhadnutých parametrů α_i^o modelu velké administrativní budovy v obsazeném režimu pro pětidenní pracovní týden, kde většinu spotřeby energie tvoří chladič výkon. Osa x interpretuje jednotlivé časové intervaly (15 minutové intervaly) vizualizované jako pracovní dny v týdnu a osa y spotřebu energie v daný časový úsek.




Obrázek 5.7: Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^o modelu velké administrativní budovy v obsazeném režimu, kde většinu spotřeby energie tvoří chladičový výkon. Osa x interpretuje venkovní teplotu a osa y relativní změnu spotřeby energie pro danou venkovní teplotu.



Obrázek 5.8: Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^u modelu velké administrativní budovy v neobsazeném režimu, kde většinu spotřeby energie tvoří chladičový výkon. Osa x interpretuje venkovní teplotu a osa y relativní změnu spotřeby energie pro danou venkovní teplotu.

5.3.3 Monoblok ČVUT Fakulty elektrotechnické a Fakulty strojní

Další ukázkou vlivu typu budovy na odhadnuté parametry je monoblok ČVUT Fakulty elektrotechnické a Fakulty strojní v Dejvicích. Z grafu (Obrázek 5.9) je patrný rozdíl mezi pátečním provozem a provozem v ostatní pracovní dny, kdy v pátek spotřeba energie nedosahuje takových hodnot. Dále je zřejmý dřívější útlum budovy. Z těchto pozorování lze usuzovat, že v páteční dny je oproti ostatním pracovním dnům zkrácený provoz. Z grafů (Obrázek 5.10,5.11) lze při vyšších teplotách vypočítat obdobné chování jako u velké administrativní budovy, kde většinu spotřeby energie tvoří chladicí výkon. Naopak u snižujících se teplot v obsazeném režimu lze vypočítat zvyšování spotřeby energie, což nelze s velkou pravděpodobností přisuzovat pouze spotřebě energie pro vytápění, jelikož k zvyšování dochází zhruba od 26 °C, kdy zde může hrát roli mnoho faktorů promítající se do spotřeby energie v budově.



Obrázek 5.9: Graf znázorňující vliv dne v týdnu a času během dne na spotřebu energie s využitím odhadnutých parametrů α_i^o modelu monobloku ČVUT Fakulty elektrotechnické a Fakulty strojní v obsazeném režimu pro pětidenní provoz. Osa x interpretuje jednotlivé časové intervaly (15 minutové intervaly) vizualizované jako pracovní dny v týdnu a osa y spotřebu energie v daný časový úsek.




Obrázek 5.10: Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^o modelu monobloku ČVUT Fakulty elektrotechnické a Fakulty strojní v obsazeném režimu. Osa x interpretuje venkovní teplotu a osa y relativní změnu spotřeby energie pro danou venkovní teplotu.



Obrázek 5.11: Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^u modelu monobloku ČVUT Fakulty elektrotechnické a Fakulty strojní v neobsazeném režimu. Osa x interpretuje venkovní teplotu a osa y relativní změnu spotřeby energie pro danou venkovní teplotu.

5.3.4 Budova se sedmidenním provozem

Poslední ukázka popisuje vliv budovy se sedmidenním provozem na odhadnuté parametry. Z grafu (Obrázek 5.12) je zřejmý rozdíl vůči předchozím typů budov, které byly provozovány v pětidenním režimu. Ze spotřeby energie lze konstatovat, že budova nefunguje v klasické pracovní době (8:00 – 16:30), ale má posunutou a prodlouženou pracovní dobu (9:00 – 20:00). Z grafu (Obrázek 5.13) vlivu venkovní teploty na spotřebu energie lze vypočítat, že budova využívá spotřebu energie převážně pro chlazení. Jelikož je budova provozována v sedmidenním provozu a v roce 2019 nebyla v neobsazeném režimu, jsou odhadnuté parametry pro neobsazený režim nulové.



Obrázek 5.12: Graf znázorňující vliv dne v týdnu a času během dne na spotřebu energie s využitím odhadnutých parametrů α_i^o modelu budovy se sedmidenním provozem. Osa x interpretuje jednotlivé časové intervaly (15 minutové intervaly) vizualizovány jako dny v týdnu a osa y spotřebu energie v daný časový úsek.



Obrázek 5.13: Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^u modelu budovy se sedmidenním provozem. Osa x interpretuje venkovní teplotu a osa y relativní změnu spotřeby energie pro danou venkovní teplotu.

5.3.5 Zhodnocení interpretovatelnosti modelu

Z grafů (Obrázky 5.4, 5.5, 5.7, 5.8, 5.10, 5.11 a 5.13) lze vypožorovat záporné hodnoty spotřeby energie, ke kterým dochází z důvodu, že při odhadu metodou nejmenších čtverců nelze nastavit dodatečné omezující podmínky optimalizace, tak aby odhadnuté parametry nebyly záporné. Tento problém by mohl být vyřešen použitím jiné optimalizační metody s omezující podmínkou.

Výskyt záporné spotřeby energie má negativní vliv na vysvětlitelnost dílčích grafů, ale nemá vliv na přesnost predikce spotřeby energie, a proto nebyla zvolena jiná optimalizační metoda.

Zobrazením koeficientů natrénovaných modelů viz Obrázek 5.7 a 5.9 lze velmi přehledně popsat předpokládané chování TZB. Tato skutečnost je především důležitá pro správce budov, jelikož umožňuje analýzu natrénovaného modelu na základě expertní znalosti. Zobrazení variability v jednotlivých časových úsecích umožňuje odhalení podezřelého chování, které může být následně konzultováno s expertem. Velká variabilita dat může být způsobena kromě neperiodického provozu budovy i chybami měřidel.

5.4 Predikce metodou AKP

Pro využití odhadnutých parametrů metodou AKP pro predikci spotřeby energie v konkrétní časový interval je ve SkySparku využita funkce knihovny Smile⁴ *mlPredict*, která vytvoří predikci spotřeby energie pro daný časový úsek. Pro využití této funkce je zapotřebí sestavit stejnou matici jako při trénování metody AKP viz sekce 5.2, ale bez měřených hodnot spotřeby energie. Při implementaci této části bylo zjištěno, že je nezbytné k odhadnutým parametrům při trénování modelu metodou AKP předat informaci pro jaký interval venkovních teplot byly vypočítávány teplotní komponenty a odhadnuty parametry modelu. Tyto informace jsou nutné k výpočtu teplotních komponent vstupní matice pro predikci spotřeby energie pomocí metody *mlPredict*.

Z tohoto důvodu bylo nutné upravit algoritmus 2 pro výpočet teplotních komponent tak, aby při výskytu nižších nebo vyšších venkovních teplot v časovém intervalu, pro který má být vypočítána spotřeba energie na základě metody AKP, nedocházelo k nesprávným výpočtům jednotlivých teplotních komponent. Bez modifikace algoritmu dochází při predikci k výpočtu rozdílných teplotních komponent než při trénování modelu. Při predikci části spotřeby energie závislé na venkovní teplotě mají teplotní komponenty rozdílnou váhu než v případě trénování modelu. Odhadnuté parametry β_j^o a β_j^u se liší. Algoritmus 3 je modifikace algoritmu 2, kde nově přidané proměnné T_{min}^p a T_{max}^p jsou nejnižší a nejvyšší vyskytnuté teploty při trénování modelu.

Při řešení tohoto problému vyvstala otázka, co s nižšími nebo naopak vyššími teplotami, které se mohou vyskytnout v časovém intervalu pro predikci spotřeby energie a v časovém intervalu pro trénování takto nízké či vysoké teploty obsaženy nebyly. Pro tento problém jsou uvažovány dvě varianty, první varianta neomezuje první a poslední teplotní komponentu nejnižší nebo naopak nejvyšší venkovní teplotou vyskytnutou při trénování, a tím tedy extrapoluje výslednou část spotřeby energie závislou na teplotě. Druhou možností je první a poslední teplotní komponentu omezit venkovní teplotou. V případě využití první možnosti lze částečně kompenzovat případ, kdy byl model natrénován na časovém intervalu, ve kterém nebyl výskyt velmi nízkých nebo vysokých teplot. Příkladem může být trénovací úsek jeden rok, který byl v letních měsících teplotně podprůměrný a odhadování spotřeby energie bude prováděno pro časový interval s výskytem vyšších teplot. Použitím první metody může docházet k velmi nepřesným až nepravdivým odhadům spotřeby energie například, kdy je predikována spotřeba energie, které nelze z důvodu omezení chladicího zařízení dosáhnout. Z tohoto důvodu je použita druhá varianta, která neumožňuje extrapolaci dat. Na Obrázku 5.14 je graficky znázorněna ukázka využití první varianty s extrapolací s využitím dat velké administrativní budovy z Obrázku 5.7.

Pro následné využití vytvořeného modelu spotřeby energie metodou AKP pro testování hypotéz s využitím metody CUSUM se SLR byly při trénování modelu vypočteny směrodatné odchylky. K výpočtu směrodatných odchylek při trénování modelu bylo nutné udělat i predikci modelu ve stejném časovém

⁴<https://haifengl.github.io/>

Algorithm 3: Modifikovaný algoritmus pro výpočet teplotních komponent pro teplotu $T(t_i)$ využívaný pro predikci metodou AKP, kde je první a poslední komponenta omezena teplotou T_{min}^p resp. T_{max}^p .

Result: Teplotní komponenty $T_{c,m}(t_i), m = 1, \dots, 6$

```

if  $T(t_i) > B_1$  then
  |  $T_{c,1}(t_i) = B_1 - T_{min}$ 
else
  | if  $T(t_i) < B_1$  a  $T(t_i) > T_{min}^p$  then
  | |  $T_{c,1}(t_i) = T(t_i) - T_{min}$ 
  | else
  | |  $T_{c,1}(t_i) = 0$ 
  | pro  $m = 2, \dots, 6$  platí  $T_{c,m}(t_i) = 0$ 
  | end
if  $T(t_i) > B_n$  pro  $n = 2, \dots, 4$  then
  |  $T_{c,n}(t_i) = B_n - B_{n-1}$ 
else
  |  $T_{c,n}(t_i) = T(t_i) - B_{n-1}$  a pro  $m = (n + 1), \dots, 6$  platí  $T_{c,m}(t_i) = 0$ 
  | end
if  $T(t_i) > B_5$  a  $T(t_i) < T_{max}^p$  then
  |  $T_{c,5}(t_i) = B_5 - B_4$  a  $T_{c,6}(t_i) = T(t_i) - B_5$ 
else
  |  $T_{c,5}(t_i) = B_5 - B_4$  a  $T_{c,6}(t_i) = T_{max}^p$ 
end

```

úseku využitého při trénování. Výpočet směrodatných odchylek je proveden na základě návrhu v sekci 4.5, kde je směrodatná odchylka vypočtena pro jednotlivé 15 minutové intervaly. Výpočet směrodatných odchylek je proveden přes všechny rozdíly predikované spotřeby energie a měřené spotřeby energie. Predikce spotřeby energie byla vypočtena z parametrů α_i^o , α_i^u , β_j^o a β_j^u a sestavené vstupní matice pro funkci *mlPredict* popsané výše.



Obrázek 5.14: Graf znázorňující vliv venkovní teploty na spotřebu energie s využitím odhadnutých parametrů β_j^g modelu velké administrativní budovy v obsazeném režimu s extrapolací dat, kde většinu spotřeby energie tvoří chladičový výkon. Osa x interpretuje venkovní teplotu a osa y relativní spotřebu energie pro danou venkovní teplotu.

5.5 Výpočetní náročnost

Při aplikaci metody AKP na velké množství datových sad bylo potřeba vyřešit, jak efektivně trénovat modely. Použitím ročních datových sad trvá natrénování modelu společně s výpočtem směrodatných odchylek metodou AKP řádově jednotky až nízké desítky minut.

V této práci byly využity datové sady z desítek budov pro několik různých typů dat TZB, a bylo tedy nutné natrénovat stovky modelů. Při trénování modelů bylo zjištěno, že prostředí SkySpark s ohledem na výpočetní náročnost metody a hardwarové dispozice serveru umožňuje trénovat pouze dva modely na roční datové sadě zároveň.

Při paralelním spuštění trénování třetího modelu dojde serveru paměť a celé prostředí se stane pro ostatní uživatele nepoužitelné. Z tohoto důvodu byl vytvořen nástroj pro hromadnou identifikaci modelů, který rozvrhuje trénování jednotlivých modelů tak, aby byly modely natrénovány v minimálním čase při zachování funkčnosti serveru.

Kapitola 6

Nasazení metody AKP na měřená data TZB

V této kapitole jsou ukázány příklady použití metody AKP pro různé typy TZB dat, z kterých je následně vybrán nejvhodnější typ TZB pro testování hypotéz a detekci poruch. Dále zde jsou popsány jednotlivé testy pro detekci poruch, včetně ukázek detekovaných chyb.

Pro použití metody AKP je nutné disponovat datovou sadou měřených dat TZB. Datové sady použité v této práci byly poskytnuty firmou Energocentrum PLUS, s.r.o., která se mimo jiné zabývá správou a automatickou kontrolou provozu TZB. V této práci byly využity datové sady za rok 2019.

6.1 Zhodnocení využitelnosti metody pro různé typy TZB dat

Pro zhodnocení využitelnosti metody AKP pro různé typy TZB dat byl využit koeficient determinace R^2 vyjadřující míru kvality regresního modelu, pro který platí následující rovnice

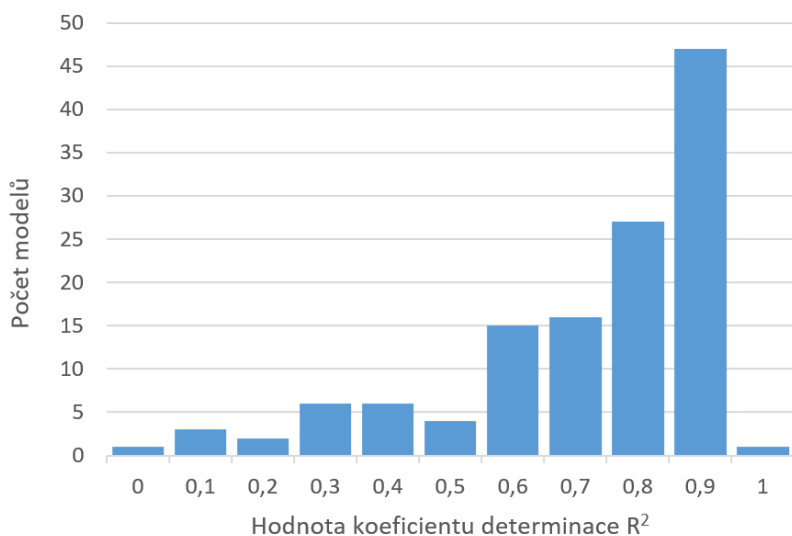
$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}, \quad (6.1)$$

kde y_i je měřená spotřeba energie, \hat{y}_i predikovaná spotřeba energie a \bar{y} je střední hodnota měřené spotřeby energie.

Metoda AKP byla aplikována na vybrané typy poskytnutých TZB dat, konkrétně elektroměry, teploměry vnitřní teploty a vodoměry. V této práci bylo využito 132 elektroměrů, 141 teploměrů vnitřní teploty a 43 vodoměrů, celkem tedy přes 300 různých datových sad TZB.


Při trénování a validaci modelu metodou AKP byla zaručena disjunktnost množin trénovacích a validačních datových sad. Naměřené hodnoty byly náhodně rozděleny mezi obě sady v poměru 70 : 30 ve prospěch trénovací sady.

Výsledné koeficienty determinace jsou graficky znázorněny na Obrázcích 6.1, 6.4 a 6.7. Pro jednotlivé typy TZB dat jsou zde ukázány vhodné a nevhodné datové sady pro použití metody AKP.




Obrázek 6.1: Histogram koeficientu determinace R^2 jednotlivých modelů využívajících měřených dat elektroměrů.

Z histogramu na Obrázku 6.1 lze vypožorovat, že více jak polovina modelů elektroměrů dosahuje koeficientu determinace R^2 mezi hodnotami $<0.8, 1>$. Příkladem datové sady elektroměru vhodné pro použití metody AKP je



Obrázek 6.2: Ukázka datové sady z elektroměru vhodné pro metodu AKP, osa x interpretuje jednotlivé časové intervaly vizualizované jako dny s režimem budovy a osa y spotřebu energie v daný časový interval.

na Obrázku 6.2, kde je graficky znázorněna měřená a predikovaná spotřeba energie pro jeden měsíc. Z Obrázku 6.2 je zřejmá velmi dobrá predikce spotřeby energie vůči měřené spotřebě energie, kde dochází k malým odchylkám v částech s častou a skokovou změnou měřené spotřeby energie.



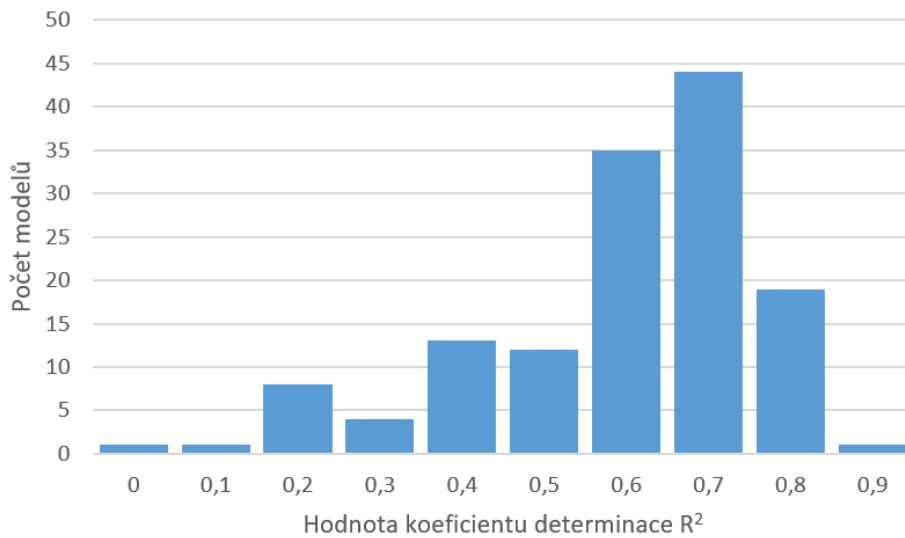
Obrázek 6.3: Ukázka datové sady z elektroměru nevhodné pro metodu AKP, osa x interpretuje jednotlivé časové intervaly vizualizované jako dny s režimem budovy a osa y spotřebu energie v daný časový interval.

Druhým příkladem datové sady elektroměru je nevhodné použití metody AKP znázorněné na Obrázku 6.3, kde predikovaná spotřeba energie neodpovídá měřené spotřebě energie. Důvodem je značná neperiodicita měřené spotřeby energie, která způsobuje špatnou predikci modelu. Tento problém je patrný při porovnání první poloviny grafu, kde se měřená spotřeba energie náhodně mění s druhou polovinou grafu, kde lze pozorovat náznaky periodického chování.

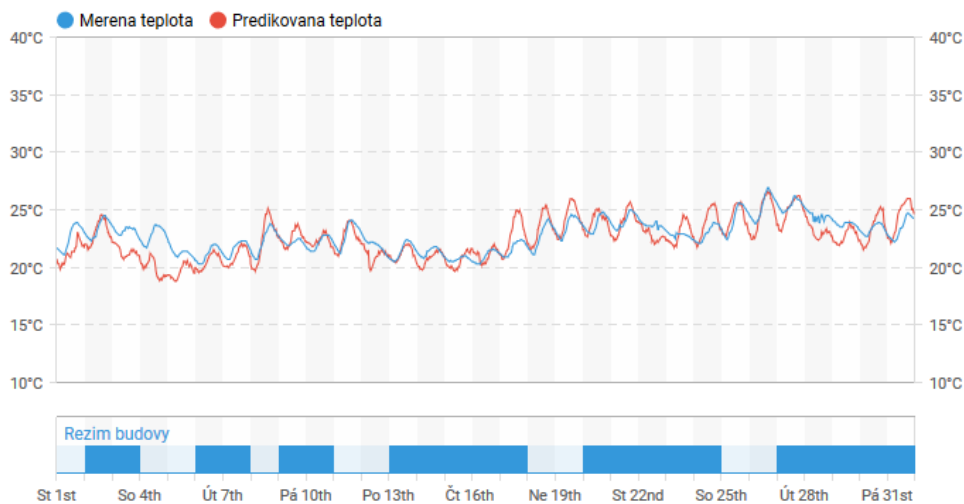
Druhým typem dat TZB využitých v této práci jsou teploměry vnitřní teploty. Metoda AKP byla navržena především pro modelování spotřeb energie (elektrické energie, vody a tepla). Modelování vnitřní teploty je použito pouze pro zhodnocení využitelnosti metody i na jiné typy TZB dat. Z histogramu na Obrázku 6.4 lze říci, že koeficient determinace většiny modelů teploměrů dosahuje hodnot $\langle 0.6, 0.8 \rangle$. Při porovnání výsledků modelů elektroměrů a modelů vnitřní teploty můžeme konstatovat, že metoda AKP dosahuje lepších výsledků pro datové sady elektroměrů. Metodu AKP je vhodné využít pro predikci vnitřní teploty v budovách, kde vnitřní teplota nemá velkou variabilitu viz Obrázek 6.5, 6.6.

Na Obrázku 6.5 je graficky znázorněna měřená a predikovaná vnitřní teplota pro model teploměru vnitřní teploty s vyšším koeficientem determinace. Z Obrázku 6.5 lze vypořadovat částečnou shodu predikce modelu s měřenými hodnotami. Obdobně jako u elektroměrů, může horší predikci způsobit neperiodicita měřených dat, avšak u teploměrů vnitřní teploty lze předpokládat nízkou variabilitu při správném řízení systémů budov. Nízká variabilita může snížit chybu v rozdílu predikované a měřené teploty.

Příklad datové sady z teploměru vnitřní teploty nevhodné pro metodu AKP lze vidět na Obrázku 6.6, z kterého je patrná chybná predikce modelu, kde je predikovaná vnitřní teplota posunuta od měřené vnitřní teploty o několik stupňů. Jedním z důvodů špatné predikce modelu je velká variabilita dat




Obrázek 6.4: Histogram koeficientu determinace R^2 jednotlivých modelů využívajících měřených dat teploměrů vnitřní teploty.



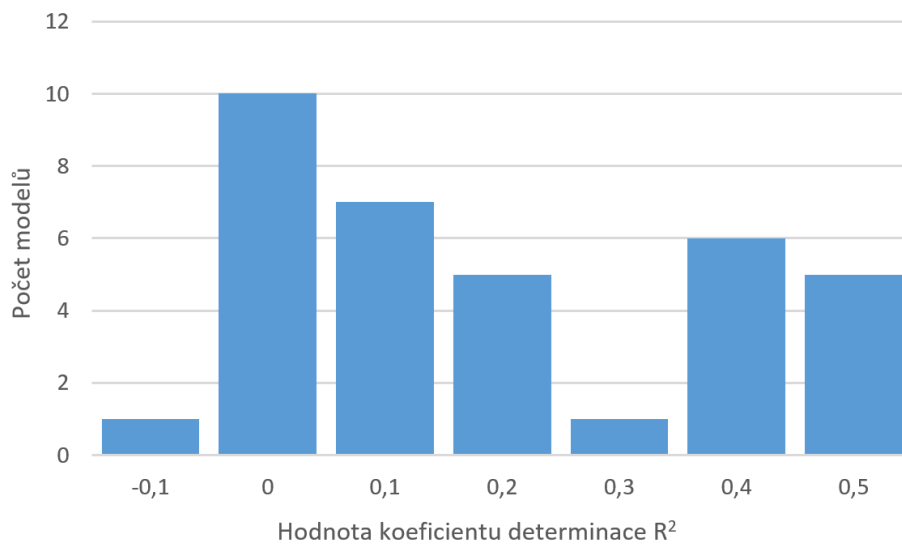
Obrázek 6.5: Ukázka datové sady z teploměru vnitřní teploty vhodné pro metodu AKP, osa x interpretuje jednotlivé časové intervaly vizualizované jako dny s režimem budovy a osa y vnitřní teplotu v daný časový interval.

vnitřní teploty v jednotlivých týdnech i v jednotlivých dnech viz Obrázek 6.6. Dalším důvodem špatné predikce je velký rozptyl hodnot vnitřní teploty přes celou datovou sadu, která má následně velký vliv na posun predikce vnitřní teploty. Částečným řešením v tomto případě by mohlo být vytvoření modelu metodou AKP pro jednotlivé roční období zvlášť.

Z histogramu na Obrázku 6.7 je zřejmé, že využití metody AKP k vytvoření modelů spotřeby vody z datových sad vodoměrů využité v této práci a následně predikci není vhodné. Jedním z důvodů je fakt, že většina poskytnutých




Obrázek 6.6: Ukázka datové sady z teploměru vnitřní teploty nevhodné pro metodu AKP, osa x interpretuje jednotlivé časové intervaly vizualizované jako dny s režimem budovy a osa y vnitřní teplotu v daný časový interval.



Obrázek 6.7: Histogram koeficientu determinace R^2 jednotlivých modelů využívajících měřených dat vodoměrů.

vodoměrů reprezentuje měření s málo častým a nízkým odběrem vody viz Obrázek 6.8.

Na základě zhodnocení histogramů koeficientu determinace R^2 pro použité typy TZB byly pro další využití vybrány pouze elektroměry. Na datových sadách elektroměrů je demonstrováno testování hypotéz s detekcí neprovedení útlumu a změny střední hodnoty v sekci 6.2.



Obrázek 6.8: Ukázka datové sady z vodoměru nevhodné pro metodu AKP, osa x interpretuje jednotlivé časové intervaly vizualizované jako dny s režimem budovy a osa y spotřebu vody v daný časový interval.

6.2 Testování hypotéz

V této části jsou uvedeny testy s využitím testování hypotéz spolu s ukázkami jednotlivých testů.

Metoda AKP byla navržena pro možné využití testování hypotéz k detekci neprovedení útlumu a odchylení měřené spotřeby od predikované hodnoty. Pro tento účel byla k deterministické části modelu přidána stochastická část v podobě směrodatné odchylky vypočítané z rozdílu odhadované a měřené spotřeby energie při trénování modelu.


Prvním testem je test změny střední hodnoty, kde testovanou hypotézou H_0 je predikovaná spotřeba energie metodou AKP proti měřené spotřebě energie. Alternativní hypotézou H_1 je predikovaná spotřeba energie metodou AKP, jejíž střední hodnota je změněna. Detekce změny střední hodnoty je kontrolována metodou CUSUM se SLR viz sekce 3.3.3, kde logaritmus poměru věrohodností odpovídá rovnici (3.5). Dalším využitím testování hypotéz je detekce neprovedení útlumu, kde testovanou hypotézou je predikovaná spotřeba energie v neobsazeném režimu a alternativní hypotézou je predikovaná spotřeba energie v obsazeném režimu. U tohoto testování hypotéz není rozptyl jednotlivých predikcí spotřeby energie stejný a nelze tedy využít rovnici pro změnu střední hodnoty viz rovnice (3.5). Je tedy nutné využít obecnou rovnici (3.6) s různými středními hodnotami a rozptyly viz sekce 3.3.2. Obdobně jako u testu změny střední hodnoty je k detekci neprovedení útlumu využita metoda CUSUM se SLR.

S využitím metody CUSUM se SLR, je nutné určit rozhodovací úroveň, kdy je zamítnuta testovaná hypotéza a přijatá alternativní hypotéza. Rozhodovací úroveň pro jednotlivé testy byly určeny na základě expertních znalostí.

6.2.1 Test změny střední hodnoty

Test změny střední hodnoty je využit pro detekci různých hodnot změny střední hodnoty. Na Obrázcích 6.9, 6.10 a 6.11 jsou uvedeny úspěšně detekované příklady zvýšení střední hodnoty o 50 % a 100 % a také snížení střední hodnoty o 50 %.


Prvním příkladem je testování snížení střední hodnoty predikované spotřeby energie o 50 %. Obrázek 6.9 odpovídá časovému úseku 10 dnů v druhé polovině března 2020. V horním podgrafu (Obrázku 6.9) jsou tři průběhy, měřená spotřeba energie, predikovaná spotřeba energie na základě modelu a predikovaná spotřeba energie se změnou střední hodnoty. Z první poloviny grafu lze vypožorovat, že měřená spotřeba energie odpovídá predikované spotřebě energie. Změna nastává v druhé polovině grafu, kde od 24.03.2020 dochází ke snížení spotřeby energie mimo provozní dobu budovy. K detekci této chyby byla využita metoda CUSUM se SLR. V grafu (Obrázek 6.9) je znázorněna hodnota logaritmu poměru věrohodností a hodnota metody CUSUM se SLR. Hodnota CUSUM se SLR je se začátkem nového dne nulována. Logaritmus poměru věrohodností vyjadřuje jaké hypotéze odpovídá měřená spotřeba energie. Pomocí metody CUSUM se SLR a stanovené rozhodovací úrovně je detekováno, kdy měřená spotřeba energie odpovídá alternativní hypotéze se změnou střední hodnoty. Detekce chyby je graficky znázorněna na Obrázku 6.9.



Obrázek 6.9: Detekce snížení střední hodnoty predikované spotřeby energie o 50 %, kde horní podgraf zobrazuje měřenou spotřebu energie, predikovanou spotřebu energie modelem a predikovanou spotřebu energie se změnou střední hodnoty. Prostřední podgraf zobrazuje vypočítaný logaritmus poměru věrohodností a hodnotu metody CUSUM se SLR. Spodní podgraf zobrazuje detekci poruchy.

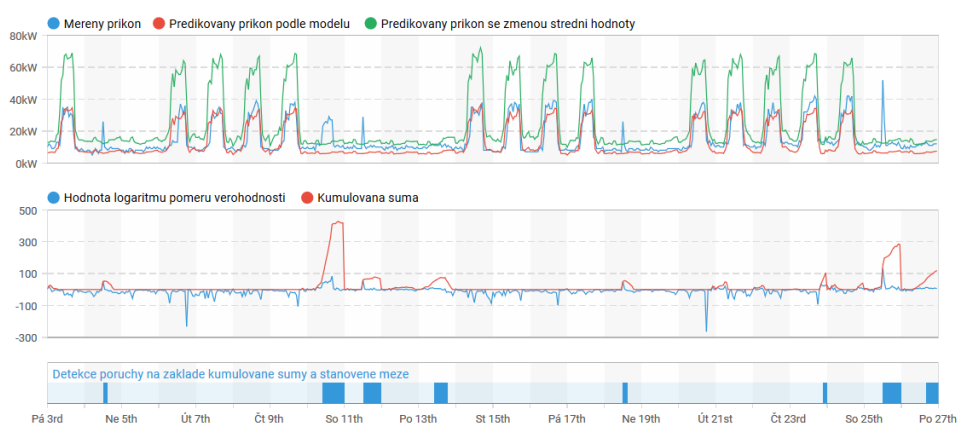
Dalším příkladem testování změny střední hodnoty predikované spotřeby energie je zvýšení o 50 %. Obrázek 6.10 odpovídá časovému úseku v dubnu 2020. Z horního grafu (Obrázek 6.10) lze vypožorovat, že pro první čtyři dny

z časového úseku nedochází k detekci poruchy, jelikož měřená spotřeba energie odpovídá nebo je menší než predikovaná spotřeba energie modelem. Toto neplatí v následujících dnech, kdy se měřená spotřeba energie rapidně zvýší. Detekce změny střední hodnoty je znázorněna v spodním podgrafu Obrázku 6.10. Mimo očividných změn měřené energie je z Obrázku 6.10 zřejmé možné neprovedení útlumu, které je ukázáno v následující sekci 6.2.2.



Obrázek 6.10: Detekce zvýšení střední hodnoty predikované spotřeby energie o 50 %, kde horní podgraf zobrazuje měřenou spotřebu energie, predikovanou spotřebu energie modelem a predikovanou spotřebu energie se změnou střední hodnoty. Prostřední podgraf zobrazuje vypočítaný logaritmus poměru věrohodností a hodnotu metody CUSUM se SLR. Spodní podgraf zobrazuje detekci poruchy.


Posledním příkladem je testování zvýšení změny střední hodnoty o 100 %. Obrázek 6.11 odpovídá časovému úseku v dubnu 2020. Z grafu (Obrázek 6.11) lze říci, že v neobsazeném režimu budovy dochází k prudkým výkyvům měřené spotřeby energie, která několikanásobně převyšuje alternativní hypotézu se změnou střední hodnoty o 100 %. Detekce chyb je znázorněna v grafu (Obrázek 6.11). V tomto případě je velmi důležité správné zvolení rozhodovací úrovně, jelikož vysoká hodnota rozhodovací úrovně by neumožnila detekovat některé výkyvy trvající kratší dobu. V praxi mohou nastat různé scénáře. Například může docházet k chvilkovým a nezajímavým výkyvům, které můžou při špatném nastavení rozhodovací úrovně způsobovat chybné detekce, nebo naopak může docházet k velkým změnám, kde včasná detekce chyb může znamenat značnou úsporu spotřeby energie.



Obrázek 6.11: Detekce zvýšení střední hodnoty predikované spotřeby energie o 100 %, horní podgraf zobrazuje měřenou spotřebu energie, predikovanou spotřebu energie modelem a predikovanou spotřebu energie se změnou střední hodnoty. Prostřední podgraf zobrazuje vypočítaný logaritmus poměru věrohodností a hodnotu metody CUSUM se SLR. Spodní podgraf zobrazuje detekci poruchy.

6.2.2 Test neprovedení útlumu


Na uvedených Obrázcích 6.12, 6.14 a 6.13 jsou graficky znázorněny úspěšné detekce, kdy spotřeba energie budovy v neobsazeném režim odpovídala více alternativní hypotéze, tedy spotřebě energie v pracovní den.



Obrázek 6.12: Detekce neprovedení útlumu v neobsazeném režimu, konkrétně Velikonoční pátek v roce 2020, kde horní podgraf zobrazuje měřenou spotřebu energie, predikovanou spotřebu energie při provedení útlumu a predikovanou spotřebu energie v obsazeném režimu. Prostřední podgraf zobrazuje vypočítaný logaritmus poměru věrohodností a hodnotu metody CUSUM se SLR. Spodní podgraf zobrazuje detekci poruchy.

Prvním příkladem je neprovedení útlumu o Velkém pátku (státní svátek), kde v horní podgrafu (Obrázek 6.12) jsou tři průběhy, měřená spotřeba energie v neobsazeném režimu, predikovaná spotřeba energie na základě

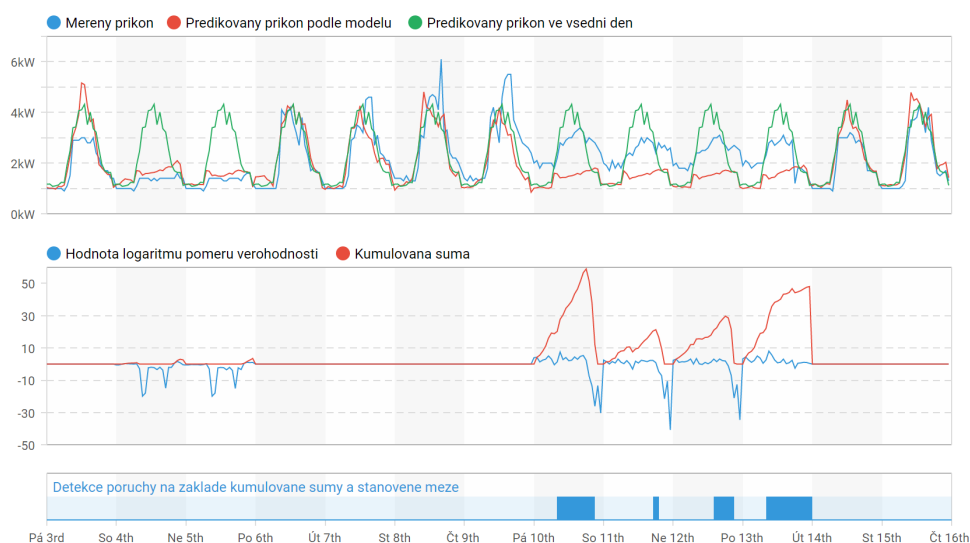
modelu v neobsazeném režimu a alternativní spotřeba energie odpovídající spotřebě energie v obsazeném režimu. Z těchto průběhů lze vypočítat, že měřená spotřeba energie neodpovídá predikované spotřebě energie, a došlo k neprovedení útlumu. Pro detekci chyby byla využita metoda CUSUM se SLR. V grafu (Obrázek 6.12) je znázorněna hodnota logaritmu poměru věrohodností a hodnota metody CUSUM se SLR. Logaritmus poměru věrohodností vyjadřuje jaké hypotéze odpovídá měřená spotřeba energie. Pomocí metody CUSUM se SLR a stanovené rozhodovací úrovně je detekováno, kdy měřená spotřeba energie odpovídá více alternativní hypotéze graficky znázorněné ve spodním podgrafu (Obrázek 6.12).



Obrázek 6.13: Detekce neprovedení útlumu o Velikonočních svátcích, konkrétně Velikonoční svátky v roce 2020, kde horní podgraf zobrazuje měřenou spotřebu energie, predikovanou spotřebu energie při provedení útlumu a predikovanou spotřebu energie v obsazeném režimu. Prostřední podgraf zobrazuje vypočítávaný logaritmus poměru věrohodností a hodnotu metody CUSUM se SLR. Spodní podgraf zobrazuje detekci poruchy.

Dalším příkladem detekce neprovedení útlumu je neprovedení útlumu o Velikonočních svátcích v roce 2020. Na Obrázku 6.13 je graficky znázorněna spotřeba energie pro Velikonoční svátky, kde první a poslední den jsou pracovní dny, a zbylé dny nepracovní. Z Obrázku 6.13 je zřejmé neprovedení útlumu o Velkém pátku a Velikonočním pondělí (statní svátky), o víkendových dnech (sobota a neděle) je útlum proveden. Obdobně jako v předchozím případě je zde graficky znázorněn logaritmus poměru věrohodností a CUSUM se SLR, kde s využitím rozhodovací úrovně dochází k detekci chyb.

Posledním příkladem detekce neprovedení útlumu je částečné neprovedení útlumu. Na Obrázku 6.14 je graficky znázorněna spotřeba pro 14 denní úsek v roce 2020, ve kterém se nachází i Velikonoce. V první polovině časového úseku lze konstatovat úspěšné provedení útlumu spotřeby energie o víkendu. V druhé části úseku, kde je znázorněna i spotřeba energie o Velikonočních svátcích lze vypočítat, že měřená spotřeba energie neodpovídá predikované spotřebě



Obrázek 6.14: Detekce neprovedení částečného útlumu o Velikonočních svátcích, konkrétně Velikonoční svátky v roce 2020, kde horní podgraf zobrazuje měřenou spotřebu energie, predikovanou spotřebu energie při provedení útlumu a predikovanou spotřebu energie v obsazeném režimu. Prostřední podgraf zobrazuje vypočítávaný logaritmus poměru věrohodností a hodnotu metody CUSUM se SLR. Spodní podgraf zobrazuje detekci poruchy.

energie v neobsazeném režimu a ani predikované spotřebě energie ve všední den. V tomto případě je velmi důležité mít vhodně zvolenou rozhodovací úroveň, kdy dochází k detekci chyb, jelikož při příliš vysoké hodnotě rozhodovací úrovně nedochází k detekci neprovedení útlumu.


6.2.3 Využití metody AKP pro analýzu dopadu pandemie COVID-19 na spotřebu elektrické energie kancelářských budov

V předchozích sekcích 6.2.1, 6.2.2 byly představeny testy s využitím testování hypotéz, konkrétně test na změnu střední hodnoty a test neprovedení útlumu. Pro jednotlivé testy byly ukázány úspěšné detekce na reálných datech TZB. Ukázky byly podrobně popsány.

Ve dnech, kdy byla psána tato práce, bylo dění v České republice a ve světě ovlivněno pandemií COVID-19. Součástí této práce je demonstrovat použití navržené metody AKP na reálná data TZB. S již zmíněnou pandemií COVID-19, kvůli které byl v České republice 12.03.2020 zaveden nouzový stav, docházelo k omezení počtu lidí v budovách, v některých případech i uzavření celých budov. Tato opatření měla velký dopad na změnu provozu budov, což bylo možné s využitím testování hypotéz, metody CUSUM se SLR a natrénovaného modelu metodou AKP na datové sadě pro rok 2019 detekovat.

Na Obrázcích 6.15 a 6.16 jsou zobrazeny detekované změny chování budovy. V případě Obrázku 6.15 byl k detekci změny chování využit test změny střední hodnoty, konkrétně test snížení střední hodnoty o 20 %. Z Obrázku

6.15 pro první čtvrtletí roku 2020 je patrné, že v lednu a únoru nedocházelo k detekcím změny střední hodnoty. Avšak se zavedením opatření vlivem pandemie COVID-19 v březnu 2020, došlo u většiny budov ke skokovému snížení střední hodnoty měřené spotřeby energie v obsazeném režimu, které bylo úspěšně detekováno.

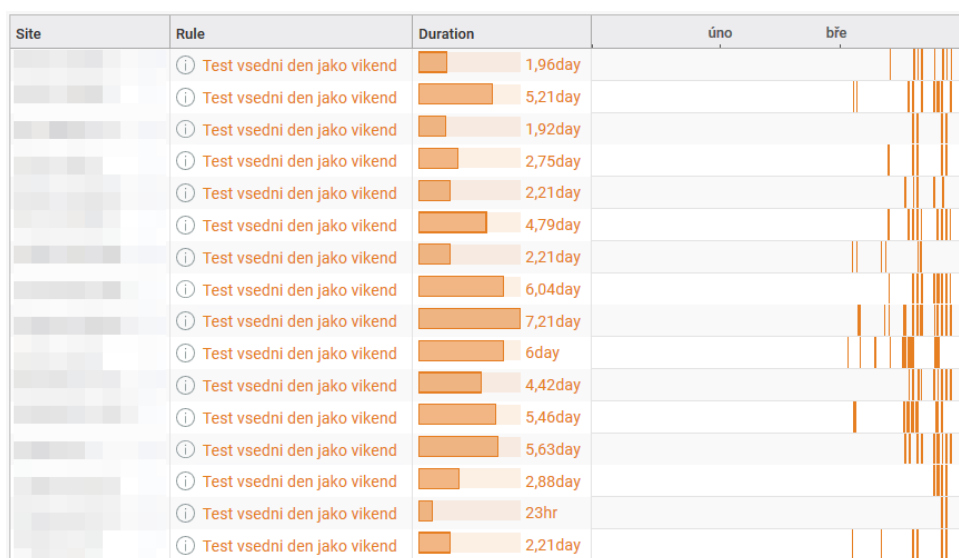


Obrázek 6.15: Detekce změny střední hodnoty spotřeby elektrické energie vlivem pandemie COVID-19 v prvním čtvrtletí roku 2020, kde graf zobrazuje detekované chyby v jednotlivých dnech pro různé budovy.

V případě Obrázku 6.16 byl využit test víkendové spotřeby energie. Tento test je založený na testu neprovedení útlumu viz sekce 6.2.2. Rozdílem mezi těmito testy je záměna testovné a alternativní hypotézy, kde u testu neprovedení útlumu byla testovanou hypotézou predikovaná spotřeba energie v neobsazeném režimu a alternativní hypotézou byla predikovaná spotřeba energie v obsazeném režimu.

Z Obrázku 6.16 pro první čtvrtletí roku 2020 lze vypočítat úspěšné detekce víkendové spotřeby energie od poloviny března 2020, kde se zavedením

restrikcí vlivem pandemie COVID-19 došlo ke změně provozování budov, ne-li k jejich úplnému uzavření.



Obrázek 6.16: Detekce víkendové spotřeby energie ve všední dny způsobené vlivem pandemie COVID-19 v prvním čtvrtletí roku 2020, kde graf zobrazuje detekované chyby v jednotlivých dnech pro různé budovy.

6.3 Diskuze

Z koeficientů determinace natrénovaných modelů metodou AKP je zřejmé, že nejlepší výsledky dosahuje metoda při využití dat z elektroměrů. Více než 50 % natrénovaných modelů dosahovalo koeficientu determinace nejméně 0.8. Natrénované modely dokázaly na validační množině velmi přesně postihnout chování TZB a je možné jejich využití pro detekci neočekávaných změn spotřeby elektrické energie.

Využití teploměrů vnitřní teploty budov vedlo na méně přesné modely. I přes relativně horší výsledky oproti elektroměrům je využití metody vhodné a obzvláště v případech, kdy se teplota v budově výrazně nemění v rámci roku. Pro některé z analyzovaných TZB by bylo třeba vytvořit model pro jednotlivá roční období zvlášť, protože budova není provozována stejně v průběhu roku.

Využití vodoměrů se ukázalo jako nevhodné. Většina modelovaných TZB obsahovala neperiodické a poměrně malé odběry. Je možné, že je tato metoda využitelná i na datech z vodoměrů, ale bylo by zapotřebí provést experiment s využitím TZB s výrazně větším a pravidelnějším odběrem.

Pomocí modelů trénovaných s využitím dat z elektroměrů bylo provedeno několik testů. Prvním z těchto testů byl test detekce změny střední hodnoty, kde alternativní hypotézu představovala predikce navýšená o 50 či 100 %. Na příkladech s využitím reálných dat je zobrazeno (Obrázky 6.9, 6.10 a 6.11) jak tato detekce vypadá v prostředí SkySpark. Drobnou modifikací tohoto

testu je i detekce snížení spotřeby energie. Tato detekce je demonstrována v sekci věnované vlivům pandemie COVID-19 (6.2.3).

Druhým testem je detekce neprovedení útlumu. Ve státní svátek, kdy jsou budovy zavřeny by spotřeba energie měla odpovídat neobsazenému režimu. Alternativní hypotéza říká, že k útlumu nedošlo a spotřeba energie bude stejná jako v obsazeném režimu. Při tomto testu je důležité správně zvolit rozhodovací úroveň. Kombinace správně zvolené rozhodovací úrovně a přesného modelu umožňuje rychlou detekci neprovedení útlumu, která může upozornit provozovatele budovy v reálném čase a tím zabránit plýtvání energií.

Poslední testem je detekce uzavřené budovy. Tento test je de facto shodným s detekcí neprovedení útlumu, s tím rozdílem, že je prohozena testovaná a alternativní hypotéza. Pomocí tohoto testu lze velmi snadno detekovat, kdy byly budovy uzavřeny kvůli mimořádnému stavu.

Kapitola 7

Závěr

Diagnostika provozu TZB je klíčová pro zaručení energeticky efektivního provozu. S využitím modelování lze detekovat odchylky chování budovy od predikovaného modelu, které mohou být způsobené závadou systému či špatným provozem. Cílem této práce bylo vytvoření statistické metody pro automatickou kontrolu provozu TZB. Hlavní detekovanou závadou je neprovedení útlumu, která je v praxi velmi častá a způsobuje značné plýtvání energií.

V první části práce byly představeny chyby provozu TZB společně s jejich příčinami, kde na základě literatury bylo odhadnuto způsobené plýtvání energií. Následně byly popsány metody pro modelování TZB a to včetně dennostupňové metody a metody LBNL-4944E. Nakonec byly představeny statistické metody detekce poruch.

V další části práce byla navržena metoda AKP pro detekci poruch vycházející z metody LBNL-4944E. Tato metoda je velice univerzální a byla rozšířena tak, aby ji bylo možné využít i na budovy, které jsou provozovány i v jiném než klasickém pětidenním provozu. Toto umožňuje modelovat závislosti TZB například nemocnic, či budov provozovaných ve vícesměnném režimu.

Navržená metoda byla implementována v prostředí SkySpark pomocí skriptovacího jazyku AXON a využitím integrovaných knihoven. Prostředí SkySpark umožňuje snadnou vizualizaci predikovaných spotřeb energie a také obsahuje nástroje pro automatickou online kontrolu zařízení.

Metoda AKP byla validována na více než 300 datových sadách reálných zařízení TZB. Pro validaci byly využity datové sady o délce jednoho roku, které v součtu obsahují více než 10 milionů záznamů. Zátěžový profil budov byl vytvořen pomocí dat z elektroměrů, vodoměrů a teploměrů vnitřní teploty. Nejlepších výsledků dosahovala tato metoda při využití dat z elektroměrů. Využití datových sad z teploměrů vnitřních teplot vedlo k horší přesnosti natrénovaných modelů, ale výsledky byly stále použitelné například pro detekci provedení útlumu. Překvapivě ještě horších výsledků dosahovala metoda AKP při využití datových sad z vodoměrů.

Navrženou metodu AKP lze snadno modifikovat tak, aby výsledná zátěž byla závislá nejenom na časovém intervalu a venkovní teplotě, ale také například na vlhkosti venkovního vzduchu. U budov s velmi rozdílným provozem v určitá roční období (zimní stadion) je vhodné natrénovat modely

pro jednotlivá období zvlášť na základě expertní znalosti dané budovy. V případě nekvalitního či nespolehlivého měřidla je žádoucí provést filtraci vstupních dat. Tyto modifikace mohou vést k zpřesnění modelu a s tím spojené spolehlivější a rychlejší detekci poruch.



Literatura

- [1] A. Afram and F. Janabi-Sharifi. Review of modeling methods for hvac systems. *Applied Thermal Engineering*, 67(1):507 – 519, 2014.
- [2] F. Bijma, M. Jonker, and A. van der Vaart. *An introduction to mathematical statistics*. Amsterdam University Press, 2017.
- [3] P. Duchesne. *Statistical modeling and analysis for complex data problems*. Springer, New York, 2005.
- [4] N. E. Fernandez, S. Katipamula, W. Wang, Y. Xie, M. Zhao, and C. D. Corbin. Impacts of commercial building controls on energy savings and peak load reduction. 05 2017.
- [5] J. Granderson, G. Lin, R. Singla, E. Mayhorn, P. Ehrlich, D. Vrabie, and S. Frank. Commercial fault detection and diagnostics tools: What they offer, how they differ, and what’s still needed. <https://doi.org/10.20357/B7V88H>, Sep 2018.
- [6] V. Havlena. Estimation, Filtering, and Detection. https://moodle.fel.cvut.cz/pluginfile.php/210736/mod_page/content/42/EFD_slides_20191203.pdf [online], Dec 2019. Naposledy navštíveno 20. 5. 2020.
- [7] J. Hodbod. Automatizovaná kontrola provozu TZB. <https://www.tzb-info.cz/facility-management/18878-automatizovana-kontrola-provozu-tzb> [online]. Naposledy navštíveno 5. 2. 2020.
- [8] D. Hrozek. Demand side response (odezva strany spotřeby). <https://oenergetice.cz/technologie/demand-side-response-dsr> [online], Jul 2016. Naposledy navštíveno 14. 5. 2020.
- [9] R. Jagpal. Technical synthesis report annex 34: computer aided evaluation of hvac system performance. *Energy Conservation in Buildings and Community Systems Programme (IEA ECBCS)*, International Energy Agency, 2006.

- [10] D. Johansson. *Cold Climate HVAC 2018 : sustainable buildings in cold climates*. Springer, Cham, 2019.
- [11] Y.-J. Kim, K.-U. Ahn, and C.-S. Park. Decision making of hvac system using bayesian markov chain monte carlo method. *Energy and Buildings*, 72:112 – 121, 2014.
- [12] J. L. Mathieu, P. N. Price, S. Kiliccote, and M. A. Piette. Quantifying changes in building electricity use, with application to demand response. *IEEE Transactions on Smart Grid*, 2:507–518, 09/2011 2011.
- [13] C. Miller, Z. Nagy, and A. Schlueter. Automated daily pattern filtering of measured building performance data. *Automation in Construction*, 49:1 – 17, 2015.
- [14] L. Pérez-Lombard, J. Ortiz, and C. Pout. A review on buildings energy consumption information. *Energy and Buildings*, 40:394–398, 01 2008.
- [15] B. Software. Linear Regression Analysis of Energy Consumption Data. <https://www.degreedays.net/regression-analysis#no-day-normalization> [online]. Naposledy navštíveno 8. 2. 2020.
- [16] J. Suykens. *Nonlinear modeling : advanced black-box techniques*. Kluwer Academic Publishers, Boston, 1998.
- [17] L. Tintěra. Denostupně - teorie k výpočetní pomůcce. <https://vytapeni.tzb-info.cz/teorie-a-schemata/2592-denostupne-teorie-k-vypocetni-pomucce> [online]. Naposledy navštíveno 6. 2. 2020.
- [18] V. Venkatasubramanian, R. Rengaswamy, and S. N. Kavuri. A review of process fault detection and diagnosis: Part ii: Qualitative models and search strategies. *Computers & chemical engineering*, 27(3):313–326, 2003.
- [19] V. Venkatasubramanian, R. Rengaswamy, S. N. Kavuri, and K. Yin. A review of process fault detection and diagnosis: Part iii: Process history based methods. *Computers & chemical engineering*, 27(3):327–346, 2003.
- [20] V. Venkatasubramanian, R. Rengaswamy, K. Yin, and S. N. Kavuri. A review of process fault detection and diagnosis: Part i: Quantitative model-based methods. *Computers & chemical engineering*, 27(3):293–311, 2003.
- [21] L. Xiao and S. Wang. Progress and methodologies of lifecycle commissioning of hvac systems to enhance building sustainability. *Renewable and Sustainable Energy Reviews*, 13:1144–1149, 06 2009.
- [22] J. Šíroký. Inovativní přístupy k vyhodnocení měřených dat během otopné sezony. <https://vytapeni.tzb-info.cz/mereni-a-regulace/19915> [online]. Naposledy navštíveno 4. 2. 2020.

- [23] J. Široký. Aktivní detekce poruch a řízení. <http://hdl.handle.net/11025/10781> [online], Jun 2013. Naposledy navštíveno 15. 5. 2020.



Příloha A

Přiložené soubory na CD

Na přiloženém CD jsou umístěny tyto soubory:

- Diplomová práce v elektronické podobě.
- Zdrojové kódy implementované metody AKP.