

Západočeská univerzita v Plzni

Fakulta aplikovaných věd

Katedra kybernetiky

BAKALÁŘSKÁ PRÁCE

PLZEŇ, 2022

JAN LOUDA

ZÁPADOČESKÁ UNIVERZITA V PLZNI

Fakulta aplikovaných věd
Akademický rok: 2021/2022

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Jan LOUDA**
Osobní číslo: **A18B0518P**
Studijní program: **B3918 Aplikované vědy a informatika**
Studijní obor: **Kybernetika a řídicí technika**
Téma práce: **Možnosti využitelnosti metod umělé inteligence v oblasti chytrých sítí (SmartGrids)**
Zadávající katedra: **Katedra kybernetiky**

Zásady pro vypracování

1. Identifikujte případy užití z oblasti provozu a rozvoje chytrých sítí s potenciálem aplikace metod umělé inteligence.
2. Detailně analyzujte vybrané případy užití pro následné nasazení metod umělé inteligence.
3. Identifikujte a analyzujte dostupné open source nástroje umělé inteligence.
4. Vyřešte vybrané případy užití pomocí vhodně zvoleného open source nástroje.


Rozsah bakalářské práce: **30 – 40 stránek A4**
Rozsah grafických prací:
Forma zpracování bakalářské práce: **tištěná**

Seznam doporučené literatury:

1. Národní akční plán pro chytré sítě (NAP SG), MPO, 2016
2. Omitaomu, O.A.; Niu, H. Artificial Intelligence Techniques in Smart Grid: A Survey. Smart Cities 2021
3. Special Issue „The Artificial Intelligence Technologies for Electric Power Systems“, Energies, 2021

Vedoucí bakalářské práce: **Ing. Martin Střelec, Ph.D.**
Výzkumný program 1

Datum zadání bakalářské práce: **15. října 2021**
Termín odevzdání bakalářské práce: **23. května 2022**



Doc. Ing. Miloš Železný, Ph.D.
děkan




Prof. Ing. Josef Psutka, CSc.
vedoucí katedry

Prohlášení

Prohlašuji, že jsem bakalářskou práci vypracoval/a samostatně a všechny použité prameny jsem uvedl/a v seznamu použitých zdrojů.

V Plzni dne 12. 8. 2022.



.....

vlastnoruční podpis

Poděkování

Rád bych tímto poděkoval vedoucímu této bakalářské práce Ing. Martinu Střelcovi, Ph.D za jeho cenné rady a čas, který mi věnoval při konzultacích. Dále bych rád poděkoval společnosti ČEZ Distribuce, a. s. za poskytnutá anonymizovaná data. V neposlední řadě bych rád poděkoval mé rodině za stálou podporu po celé době studia.

Abstrakt

V teoretické části této bakalářské práce je nejprve krátce popsán současný stav přenosu elektřiny a nástup moderních chytrých sítí. Následně byly identifikovány případy užití funkcionalit chytrých sítí, kde byl vybrán jeden případ (modelování chování skupiny odběrných míst) pro detailní analýzu. Při té byli specifikováni relevantní účastníci trhu a jejich motivace znalosti chování skupiny odběrných míst. Cílem praktické části je vytvoření simulačních a predikčních modelů chování skupiny odběrných míst pro široké využití v oblasti jednotlivých stakeholderů. K tomu jsou využity metody strojového učení, jejichž výsledky jsou důkladně vyhodnoceny.

Klíčová slova

elektrická síť, chytrá síť, účastníci trhu s elektřinou, simulační model, predikční model, metody strojového učení

Abstract

The current status of the power system domain and transition toward modern smart grids are briefly described in the theoretical part of this bachelor's thesis. Then, use cases relevant to the smart grid domain were identified and one of them was chosen for detailed analysis (behavior modeling of customers group). In this use case, relevant market participants and their motivation in behavioral knowledge of a customer group were discussed. The goal of the practical part is the creation of simulation and prediction models of customer groups for wider use in various stakeholders' domains. Finally, selected machine learning methods were used for the development of appropriate data-driven models, which were properly validated and their quality was clearly assessed.

Key words

electrical network, smart grid, electricity market participants, simulation model, prediction model, machine learning methods

Obsah

1	Úvod do chytrých sítí	9
1.1	Popis tradiční elektrické sítě	9
1.2	Specifikace chytrých sítí	10
1.2.1	SGAM model	10
1.3	Případy užití v oblasti chytrých sítí	12
1.3.1	Identifikace kategorií případů užití	12
1.3.2	Odběrné místo	14
1.3.3	Chytrá odběrná místa	14
1.3.4	Chytré elektroměry	14
1.3.5	Cena elektřiny	15
1.3.6	Případy užití z pohledu účastníků trhu s elektřinou	16
2	Formulace úlohy	20
3	Metodika tvorby modelů spotřeby skupin odběrných míst	21
3.1	Průběhové měření	22
3.2	Primární segmentace	26
3.3	Clusterová analýza	33
3.4	Agregace měření	39
3.5	Data-driven model OM	41
4	Implementace modelu skupiny odběrných míst	54
4.1	High-level schéma	54
4.2	Technologický stack	54
4.3	Frameworky strojového učení	55
4.4	Implementované funkcionality	56

5 Závěr	57
A Vizualizace výsledků predikčních modelů pro jednotlivé shluky	63

Kapitola 1

Úvod do chytrých sítí

1.1 Popis tradiční elektrické sítě

Tradiční elektrická síť funguje na bázi jednosměrného přenosu elektřiny. Na výrobní straně jsou umístěny generátory elektrické energie a na druhé straně velké množství spotřebitelů. Fáze přenosu jsou:

- **Výroba elektřiny** - Samotný proces začíná v elektrárnách, ve kterých se elektřina vyrábí pomocí elektrických generátorů. Zde podle druhu primární energie pohánějící generátory se elektrárny dělí do několika kategorií jako například na - tepelné, jaderné a vodní. Dále se elektrárny rozlišují na zdroje paliva. Zde rozlišujeme obnovitelné a neobnovitelné zdroje. V České republice se zhruba 90% elektřiny vyrábí z neobnovitelných zdrojů. Z toho 50% tvoří tepelné elektrárny a 40% jaderné elektrárny. Zbýlých 10% pochází z obnovitelných zdrojů, kde 3 % tvoří spalování biomasy, zbylé obnovitelné zdroje tvoří solární, větrné a vodní elektrárny. [10]
- **Elektrizační soustava** - Elektrizační soustava je tvořena souhrnem zařízení pro dálkový přenos a následný rozvod elektrické energie. Jinými slovy jde o propojení výroben elektřiny s velkým počtem odběratelů. Podle napětí vedení rozdělujeme elektrizační soustavu na přenosovou a distribuční soustavu. [5]
 - **Přenosová soustava** - Přenosová soustava zabezpečuje přenos elektrické energie na velké vzdálenosti. Vedení zpravidla funguje na vysokém na-

pětí, díky kterému dochází k nízkým přenosovým ztrátám. Ztráty vzniklé při transportu elektřiny jsou závislé na odporu přenosového vedení a kvadrátu protékajícího proudu.

$$P_z = Z \cdot I^2 \quad (1.1)$$

kde P_z [W] je ztrátový výkon, který se transformuje na teplo, Z [Ω] je odpor přenosového vedení a I [A] je protékající proud. V České republice tvoří přenosovou soustavu vedení o napětí 400 kV a 220 kV. [5]

- **Distribuční soustava** - Distribuční soustava propojuje vysokonapěťové vedení s cílovými odběrateli elektřiny. Dosahuje toho postupným snižováním napětí, které zajišťují distribuční transformátory. Se snižováním napětí se také musí zmenšovat délka distribučního vedení, aby nedocházelo ke ztrátám elektřiny. [6]
- **Odběrná místa** - Odběrná místa jsou tvořena koncovými odběrateli. V klasickém pojetí distribuce jsou odběratelé pouhými konzumenty elektrické energie. [6]

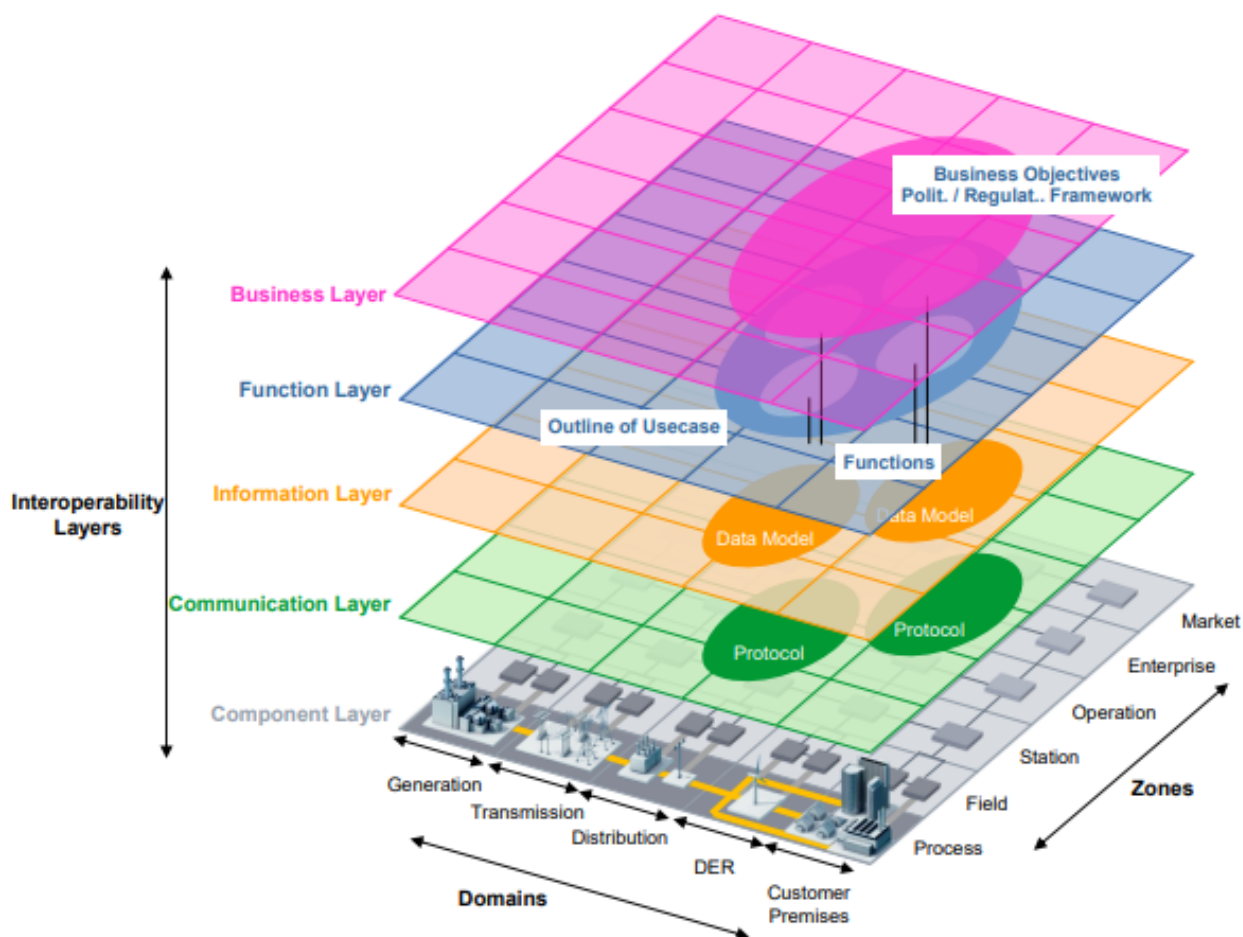
1.2 Specifikace chytrých sítí

Chytrá síť (SmartGrid) umožňuje obousměrný tok elektrické energie a informací za účelem vytvoření automatizované a decentralizované sítě. Chytrá síť využívá moderní informační technologie, díky kterým je schopna distribuovat elektřinu efektivnějším způsobem. Také je přizpůsobena rychle reagovat na nečekané události, jakými mohou například být výpadky distribuce elektřiny. Chytrou síť můžeme uvažovat jako elektrický systém využívající informační, obousměrné, kyberneticky bezpečné, komunikační technologie integrované do elektrické sítě. [8]

1.2.1 SGAM model

SGAM model nám dává pohled na celkovou architekturu v oblasti chytrých sítí. Díky tomuto modelu můžeme pochopit celkový koncept chytrých sítí z různých pohledů. SGAM model se rozděluje na pět vrstev. Každá vrstva je dvoudimenzionálně

rozdělena na domény a zóny. Domény reprezentují řetězec vedení energie, kde výroba energie začíná generátory a končí u zákazníků. Zóny popisují správu informací uvnitř chytrých sítí. [19]



Obrázek 1.1: SGAM - vrstvy. [20]

Vrstvy

- **Business layer** - První vrstva zobrazuje obchodní pohled. Tento pohled zahrnuje regulaci, politiku, ekonomiku a různé obchodní modely. [19]

- **Function layer** - Další vrstva popisuje funkce a služby včetně jejich vztahů. Tyto funkce a služby vycházejí z obchodního pohledu a jsou nezávislé na fyzické implementaci. [19]
- **Information layer** - Tato vrstva popisuje používané a vyměňované informace mezi aktéry, v tomto případě mezi systémy a komponenty. Reprezentuje informační objekty nebo datové modely. [19]
- **Communication layer** - Komunikační vrstva se stará o výměnu informací mezi komponenty. Tato vrstva obsahuje komunikační protokoly a mechanismy pro výměnu dat. [19]
- **Component layer** - Tato vrstva popisuje fyzickou distribuci všech komponentů v oblasti chytrých sítí. Tyto komponenty dále využívají funkce, informace a komunikační prostředky z ostatních vrstev. [19]

1.3 Případy užití v oblasti chytrých sítí

1.3.1 Identifikace kategorií případů užití

Oblast chytrých sítí je velmi dynamickou a rozvíjející, kde s postupnou penetrací chytrých řešení výrazně narůstá i počet možných případů užití (use cases), které lze s novými technologiemi realizovat [23]. Množství případů užití funkcionalit chytré sítě lze však za pomoci SGAM modelu kategorizovat do skupin dle umístění v distribučním řetězci. Následující seznam obsahuje vybrané identifikované příklady užití:

- **Výroba** (Generation)
 - Optimalizace výroby
 - Monitorování stavu zařízení (health monitoring)
 - Detekce chyb zařízení
- **Přenos** (Transmission)
 - Vylepšená estimace stavu přenosové sítě
 - Congestion management

- Wide area monitoring
- **Distribuce** (Distribution)
 - Plánování a rozvoj distribuční soustavy
 - Flexibilní řízení distribuční soustavy
 - Asset management
- **Decentralizovaná výroba** (DER)
 - Predikce výroby obnovitelných zdrojů
 - Sledování stavu zařízení
- **Spotřeba** (Consumption)
 - Real-time energy management
 - Zachycení chování uživatele
 - Predikce spotřeby odběrného místa
 - Poskytování výkonové flexibility podpůrným službám
- **Tržní prostředí** (Market)
 - Predikce spotových cen
 - Detekce černých odběrů
 - Vylepšené uspořádání trhu
 - Segmentace spotřeb zákazníků

Výše uvedený seznam je pouze vybraným výčtem případů užití chytrých funkcionalit moderních elektrických sítí. Detailní analýza a popis jednotlivých případů užití široce převyšují rozsah a zaměření bakalářské práce. V následujícím textu se práce orientuje na stranu spotřeby (Consumption) a především pak na využití průběhového měření odběrných míst pro potřeby modelace chování zákazníka.

1.3.2 Odběrné místo

Odběrné místo je chápáno jako místo dodávky elektrické energie příslušející danému zákazníkovi. Zákazník může mít více odběrných míst, kde každé odběrné místo je vázáno smlouvou o dodávce elektrické energie za přesně stanovených odběrových a platebních podmínek. Smlouva zpravidla závisí na typu odběrného místa. Každé odběrné místo je charakterizováno jedinečným kódem a je vybaveno jističem a elektroměrem. Cena elektrické energie je ovlivněna poptávkou odběrných míst, kdy ve špičkách se zvyšuje zatížení rozvodné sítě, rostou náklady provozovatelů na výrobu a distribuci elektřiny, a tím stoupá cena elektřiny. Proto je dodávka rozčleněna na časové intervaly, ve kterých platí rozdílné ceny silové elektřiny. V energetických špičkách odebírá zákazník elektřinu ve vysokém tarifu, jinak odebírá elektřinu v tarifu nízkém. [12]

1.3.3 Chytrá odběrná místa

V tradiční elektrické síti byla odběrná místa vždy na konci distribuce jako konzumenti elektřiny. Jediným ukazatelem pro přenosové a distribuční společnosti byla celková spotřeba elektřiny. S příchodem moderních technologií se tato oblast rapidně rozšířila. V dnešní době již odběratel nemusí být pouhým konzumentem, ale elektřinu může pomocí mikrozdrojů vyrábět a dodávat zpět do sítě. Spotřeba elektřiny je řízena energetickým managementem, který v reálném čase získává informace o aktuální spotřebě a distribuční sazbě. Následně dokáže plánovat spouštění energeticky náročných spotřebičů podle aktuální vlastní výroby nebo ceny elektřiny na trhu. Dále se v chytrých odběrných místech stále častěji vyskytují akumulátory elektřiny, které slouží k vyrovnávání křivky výroby a spotřeby a podobně jako baterie elektrických aut poskytují kapacitu pro řízení celé moderní elektrizační soustavy. [9]

1.3.4 Chytré elektroměry

Chytré elektroměry mají oproti klasickým elektromechanickým měřičům následující výhody.

- Chytré elektroměry jsou méně náchylné k chybám. Spolehlivé informace získávají odběratelé i poskytovatelé služeb.

- Informace mohou být získány na dálku. Poskytovatelé služeb nemusí fyzicky kontrolovat stav elektroměru u odběratele.
- Manipulace s elektroměrem může být snadno odhalena poskytovatelem.
- Chytré elektroměry mohou být použity k řízení elektrické spotřeby.

Chytrý měřicí systém

Chytrý měřicí systém zahrnuje instalaci chytrých elektroměrů u odběrných míst. Slouží k pravidelnému čtení a procesování dat. Zákazníkovi dávají zpětnou vazbu o aktuální spotřebě elektřiny. Tento systém má především ekonomické a environmentální výhody. [8]

1.3.5 Cena elektřiny

Cena elektřiny je tvořena z regulované a neregulované části. Regulovaná část je tvořena poplatky spojenými s výrobou a distribucí elektřiny. Cenu této části určuje Energetický regulační úřad. Neregulovaná část představuje cenu za silovou elektřinu, kterou ovlivňuje dodavatel elektřiny. [13]

• **Regulovaná část**

- **Distribuční poplatky** - Největší složka je tvořena poplatky distributorům elektřiny, tyto poplatky se mohou podle oblastí a jednotlivých distributorů lišit.
- **Poplatek za rezervovaný příkon** - Pro odběrné místo je v rozvodné síti rezervováno určité množství energie. Nezáleží, zda toto množství odběrné místo spotřebuje či nikoliv. Výše tohoto poplatku závisí na velikosti hlavního jističe odběrného místa.
- **Příspěvek na výrobu z obnovitelných zdrojů** - Výkupní cena elektřiny z obnovitelných zdrojů je dotována právě z těchto příspěvků. Výši poplatku ovlivňuje velikost hlavního jističe.
- **Poplatek za systémové služby** - Z těchto poplatků je financován provoz a údržba České přenosové soustavy.
- **Poplatek operátorovi trhu** - Malý poplatek je brán společností Operátor trhu s elektřinou, který se stará o fungování trhu s elektřinou.

- **Neregulovaná část** - Tuto část představuje cena silové elektřiny. Jde o skutečně spotřebovanou elektřinu. Na celkové ceně se podílí okolo 44% a je vyplácena přímo dodavateli elektřiny. V případě dvoutarifní sazby je neregulovaná část složena z ceny elektřiny v nízkém a vysokém tarifu. [13]

1.3.6 Případy užití z pohledu účastníků trhu s elektřinou

Na začátku 21. století začala v České republice postupná liberalizace energetického sektoru. S účinností od 1.1.2001 začal platit Energetický zákon, který legislativně vymezuje český trh s elektřinou. Jednotliví účastníci trhu mají dle tohoto zákona jasně definované pravomoce. [16]

Pro většinu účastníků trhu s elektřinou je výhodné a mnohdy i potřebné znát charakteristiky a vzorce chování relevantních odběrných míst pro realizaci jejich komerčních či provozních aktivit. V následujícím textu jsou uvedeny motivace znalosti vzorce chování odběrného místa z pohledu jednotlivých zainteresovaných stran (stakeholderů).

Motivace jednotlivých stakeholderů:

- **Zákazník** - dle stávajících Evropských energetických strategií [22] je zákazník klíčovým prvkem energetické soustavy, kterému je poskytována ekonomicky dostupná, zabezpečená a čistá energie. Zákazníkovi jsou legislativně zajištěny podmínky pro minimalizaci nákladů na energie prostřednictvím možnosti zapojení do tržně-provozních mechanismů (např. demand response, dynamické tarify apod.). Pro efektivní rozhodování zákazníka v tržním prostředí je velmi výhodné znát svůj vzorec chování (např. profil spotřeby), který může modifikovat například za účelem minimalizace nákladů.
- **Obchodník s elektřinou** - Obchodník s elektřinou musí vlastnit licenci od Energetického regulačního úřadu, která trvá po dobu 5 let. Obchodník obchoduje s elektřinou na maloobchodním i velkoobchodním trhu. Veškeré transakce musí nahlásit operátorovi trhu. Obchodník má povinnost dodat sjednané množství elektřiny v kvalitě dané právními předpisy do odběrného místa, které je stanoveno zákazníkem. Pokud v síti vznikne nějaká neplánovaná změna (nedostatek nebo přebytek elektřiny), dojde k vyrovnání hladiny pomocí takzvané regulační elektřiny. Cena za tuto odchylku musí být následně

zúčtována subjektu, který ji způsobil. Tato odpovědnost může být přenášena, typicky domácnosti tuto odpovědnost přenášejí na obchodníky, se kterými mají uzavřenou smlouvu. V případě obchodníka je tedy velmi žádané znát vzorce chování zákazníků (resp. odběrných míst), pomocí kterých lze například predikovat jejich budoucí spotřebu nebo při znalosti chování typických skupin zákazníků vhodně nastavit obchodní tarify. [15, 16]

- **Agregátor** - je dalším licencovaným účastníkem trhu. Agregátor obchoduje s flexibilitou, která reprezentuje změnu množství elektřiny dodané nebo odebrané ze sítě oproti předpokládanému odběru nebo dodávky. Zde vstupují na trh také poskytovatelé flexibility, kteří poskytují flexibilitu sami nebo prostřednictvím agregátora. Agregátor nebo tyto poskytovatelé využívají zdrojů flexibility, konkrétně se jedná o spotřební zařízení, když je elektřiny v síti přebytek nebo o akumulátory elektřiny v momentě, kdy je v síti nedostatek. Agregátor může být integrovaný nebo nezávislý. Integrovaný agregátor přebírá odpovědnost za odchylku svých poskytovatelů flexibility. Nezávislý agregátor tuto odpovědnost nepřebírá, není tedy odpovědný za vzniklé odchylky vzniklé při spuštění zdrojů flexibility. Pro agregátora jsou očekávané vzorce chování zákazníků klíčovými informacemi pro stanovení potenciálu flexibility odběrných míst a jejich možných následných aktivací v nabízených službách. [18]
- **Provozovatel distribuční soustavy** - Provozovatel se stará o distribuci elektřiny ke konečným zákazníkům. V České republice jsou tři hlavní provozovatelé: ČEZ Distribuce, E.ON Distribuce a PRE Distribuce. Zákazník platí provozovateli poplatek za distribuci, který každý rok stanovuje Energetický regulační úřad. Provozovatel distribuční soustavy je dále zodpovědný za bezpečný a spolehlivý provoz soustavy, její budoucí plánování a rozvoj. Právě v efektivní rozvoj distribuční soustavy jsou klíčové znalosti chování odběrných míst v dané lokalitě. Naopak při provozu je důležité znát chování skupin odběrných míst pro vhodné nastavení struktury distribučních tarifů či pro efektivní zapínání vysokého a nízkého tarifu v dané lokalitě. [15]
- **Provozovatel přenosové soustavy** - Jediným provozovatelem přenosové sou-

stavy je ze zákona státem vlastněná společnost ČEPS a.s., která zajišťuje provoz přenosové soustavy a poskytuje přenosové a systémové služby jako například zaručení rovnováhy mezi výrobou a spotřebou elektřiny v reálném čase. Dále ČEPS obstarává přeshraniční přenosy elektřiny pro export a import elektřiny. Pro provozovatele přenosové soustavy je potřeba znalosti chování odběrných míst marginální, avšak v některých službách systémové rovnováhy vítaná. [15]

- **Operátor trhu s energiemi** - je státem vlastněná společnost, která byla na základě Energetického zákona založena v roce 2001. Tato společnost je licencována Energetickým regulačním úřadem. Operátor trhu má kompletní přehled o účastnících trhu, jakými jsou například výrobci nebo dodavatelé energie. Hlavním úkolem operátora trhu je organizovat krátkodobý trh s plynem a elektřinou. Dále vyhodnocuje odchylky, které následně poskytuje účastníkům trhu. Zodpovědní účastníci jsou za tyto odchylky povinni dle vyhodnocení zaplatit. OTE je také zodpovědná za administrativní činnosti, jakými jsou například vyplácení podpory POZE (podporovaných zdrojů energie). Z pohledu operátora trhu je potřeba znalosti vzorce chování odběrných míst či skupin odběrných míst klíčová v mnoha procesech jako je například vypořádání trhu, rozpočítání odpovědností za ochylku a další. [17]
- **Energetický regulační úřad (ERÚ)** - byl zřízen v roce 2001 dle Energetického zákona. Hlavním úkolem ERÚ je regulovat distribuční poplatky, které každý rok naceňuje. Dále podle zákona stanovuje výši podpory pro obnovitelné zdroje energie. Stejně jako operátor trhu má ERÚ celkový přehled o výrobcích elektřiny, obchodnících a dalších účastnících, které licencuje a následně dozoruje. ERÚ ochraňuje spotřebitele ve sporech s dodavatelem, případně s distributorem elektřiny. Pro některé činnosti ERÚ spojené se službami zákazníkům (např. cenová kalkulačka energií apod.) je podstatné znát vzorce chování zákazníka či skupin zákazníků pro kvalitní servis či rozhodnutí. [14]

Z výše uvedených příkladů jednotlivých stakeholderů lze vidět, že znalost vzorce chování odběrného místa či skupiny odběrných míst je klíčová a potřebná pro realizaci jejich provozních, tržních či regulatorních procesů. Model spotřeby odběrného místa lze chápat jako simulační či predikční. Simulační model využívá pro generování výstupu historických hodnot a je využíván spíše v procesech plánování či posouzení různých scénářů. Naopak predikční model předpovídá chování daného odběrného místa či odběrných míst s ohledem na očekávané hodnoty vstupních dat. Následující tabulka zachycuje primární využití modelu z pohledu jednotlivých stakeholderů.

	OM		Skupina OM	
	Simulační	Predikční	Simulační	Predikční
Zákazník	✓	✓		
Obchodník s elektřinou	✓	✓	✓	✓
Agregátor	✓	✓	✓	✓
Provozovatel distribuční soustavy	✓	✓	✓	
Provozovatel přenosové soustavy			✓	
Operátor trhu s energiemi	✓		✓	
Energetický regulační úřad (ERÚ)			✓	

Obrázek 1.2: Relevance modelů OM dle jednotlivých stakeholderů

Lze vidět, že simulační a predikční model skupiny odběrných míst je velmi dobře využitelný v mnoha oblastech a proto se mu budeme v následující části práce věnovat.

Kapitola 2

Formulace úlohy

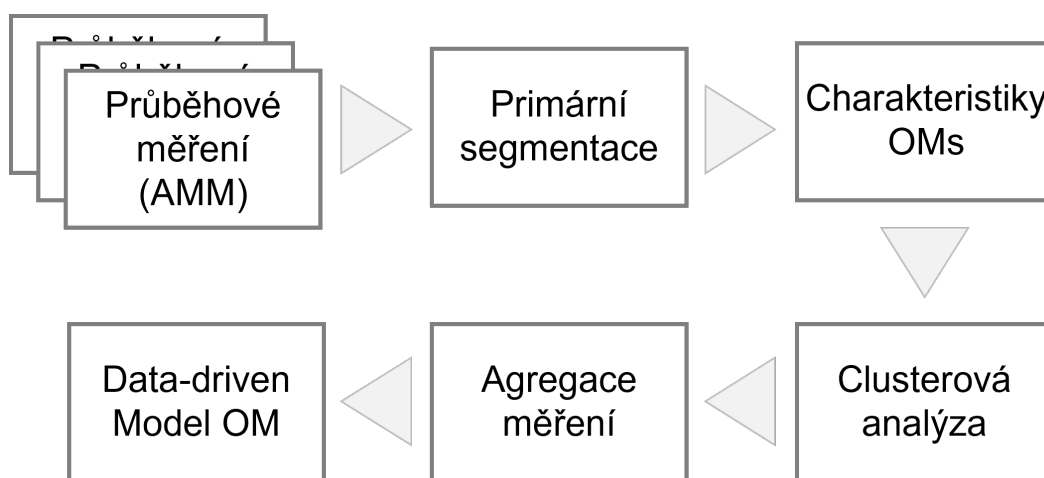
Pro realizaci praktické části byl vybrán use case, který se dotýká většiny stakeholderů v energetickém prostředí (detaily viz předchozí kapitola). Cílem praktické části je vytvořit, implementovat a otestovat metodiku pro modelování skupiny odběrných míst pro potřeby simulace či predikce chování vybraných skupin zákazníků. Pro vytvoření odpovídajících modelů budou využita reálná a anonymizovaná data z průběhového měření spotřeby získaná od společnosti ČEZ Distribuce. Cílová metodika bude obsahovat následující části:

- Zpracování měřených signálů průběhového měření spotřeby
- Vytvoření skupin zákazníků dle dostupných informací (např. distribuční sazba, velikost jističe apod.)
- V jednotlivých skupinách zákazníků
 - segmentovat odběrná místa s podobnými vzorci chování
 - vytvořit vhodný simulační model pro daný segment odběrných míst dané skupiny
 - vytvořit vhodný predikční model pro daný segment odběrných míst dané skupiny pro týdenní predikční horizont

Kapitola 3

Metodika tvorby modelů spotřeby skupin odběrných míst

V této sekci byla probírána realizace modelů vzorců chování odběrných míst. K sestavení těchto modelů bylo využito přístupu data-driven modelování, kde jednotlivé fáze jsou důkladně popsány v jednotlivých sekcích níže a graficky zobrazeny na obrázku 3.1.



Obrázek 3.1: Data-driven modelování zákazníka.

Tento přístup začíná zpracováním průběhového měření, které představuje měřené hodnoty činného výkonu na daném odběrném místě s určitou vzorkovací pe-

riodou¹. V tomto kroku je nutné surová data vhodným způsobem ošetřit a zpracovat, protože senzory provádějící odečty u odběrných míst, nejsou ideální a dochází u nich k výpadům nebo nepřesnostem měření. Těchto chyb je nezbytné se zbavit, neboť by nám záporně zasahovaly do následných experimentů. V další části je prováděna primární segmentace odběrných míst, které jsou na základě základních charakteristik odběrných míst rozděleny do disjunktních skupin. Toto rozdělení lze provádět například na základě distribučního tarifu, velikosti jističe nebo lokality, ve které se odběrné místo nachází. V navazující části se charakterizují průběhová měření spadající do jednotlivých skupin na základě výkonnostních indikátorů za uvažování kategorických proměnných vztahujících se k danému měření. Výkonnostními indikátory se rozumí například průměr, směrodatná odchylka, maximum, minimum či kvantily při uvažování kategorizace času měření dle fází dne, typu dne a ročního období.

Po charakterizaci průběhových měření se provede shluková (clusterová) analýza, která na základě výkonnostních ukazatelů identifikuje jednotlivé shluky měření. Výsledkem je rozdělení odběrných míst do k tříd, ve kterých jsou sdružena obdobná odběrná místa. Průběhová měření v jednotlivých clusterech se agregují a jsou dále poskytnuty metodám strojového učení za účelem vytvoření odběrového modelu dané skupiny.

3.1 Průběhové měření


Z databáze máme k dispozici 412 odběrných míst. U každého odběrného místa probíhalo odečtení aktuální spotřeby po 15 minutách. Celkem u každého odběrného místa došlo k odečtení 96krát za den, tedy za celý rok se jedná o 35036 odečtů. Měření byla prováděna technologicky nejvyspělejším systémem AMM, který plně používá obousměrnou komunikaci. [4]

Průběh spotřeby elektřiny měřený v energiích má neklesající křivku. Aktuální odečet elektřiny je roven součtu všech minulých odečtů s aktuálním odečtem. Průběh spotřeby měřen v energiích nám neposkytuje dostatečné informace o chování odběrného místa v aktuálních momentech, proto je průběh převáděn na výkon.

¹Vzorkovací perioda v případě průběhového měření je 15 minut, což odpovídá plánovaným obchodním intervalům trhu s elektřinou.

Vizualizace průběhu před úpravou:

Na grafu je zobrazen průběh spotřeby před úpravou, kde na x-ové ose je čas a na y-ové ose je spotřeba elektřiny v kilowatthodinách.



Obrázek 3.2: Průběh spotřeby elektřiny jednoho OM před úpravou.

Provedli jsme úpravu dat, díky které byly odstraněny chyby měření (outliery). Úprava byla provedena na základě algoritmu, který je popsán níže.


Algoritmus sloužící k odstranění outlierů:

Tento algoritmus byl navržen tak, aby efektivně odstranil chyby vyskytující se v průbězích spotřeby. Chybu měření si lze představit jako výpadek senzoru, při kterém dojde k náhlé velké změně odečtu. K vytvoření tohoto algoritmu jsme využili znalosti střední hodnoty a směrodatné odchylky. U každého průběhu byla vypočtena střední hodnota a směrodatná odchylka. Chyby měření mají vyšší hodnotu než

je součet střední hodnoty a směrodatné odchylky nebo mají zápornou hodnotu. Algoritmus tyto chyby nahradí datovým typem Nan (Not a Number).


Vizualizace průběhu po úpravě:

Na grafu je vyznačen průběh spotřeby po úpravě, kde na x-ové ose je čas a na y-ové ose je spotřeba elektřiny v kilowatthodinách.



Obrázek 3.3: Průběh spotřeby elektřiny jednoho OM po úpravě.

Průběh spotřeby elektřiny ve výkonu získáme derivací měřených průběhu v energiích a přenásobením vhodným koeficientem spojeným s periodou vzorkování. V našem případě jsou data vzorkována na 15 minutové bázi a měřená v kilowatthodinách. Tedy převod na kilowatty bude probíhat násobením derivace měření energie faktorem $k = 60/15 = 4$. Na grafu je zobrazen průběh spotřeby jednoho odběrného místa ve výkonu, kde na x-ové ose je čas a y-ové ose výkon v kilowattech.



Obrázek 3.4: Průběh spotřeby elektřiny jednoho OM v činném výkonu.

Na základě znalosti roční spotřeby bychom mohli průběhy spotřeby znormalizovat. V našem případě tuto normalizaci nemůžeme provést, jelikož nám chybějí vzorky měření.

3.2 Primární segmentace

Dále v této části byla provedena kategorizace odběrných míst. V dalších fázích budeme zkoumat, jak jsou si jednotlivé průběhy odběrných míst podobné. Proto k sobě přiřadíme odběrná místa, která mají podobné znaky. Kategorizace odběrných míst by mohla být provedena na základě distribuční sazby, lokality, ve kterém se odběrné místo nachází nebo na základě velikosti jističe, kterým disponuje odběrné místo. V našem případě jsou odběrná místa na stejném území, a tak vnější vlivy jako počasí by měly naše odběrná místa ovlivňovat velmi podobně. Informaci o velikosti jističe odběrného místa nemáme k dispozici. Odběrná místa tedy kategorizujeme dle distribuční sazby odběrného místa. Pokud bychom porovnávali průběhy běžné domácnosti s průběhy veřejného osvětlení, nedávalo by nám to významnou informaci o podobném chování zákazníků. Dále si charakterizujeme jednotlivé tarifní sazby, které máme k dispozici.

Seznam distribučních tarifů:

- **C01d a D01d** - U těchto sazeb hovoříme o provozovnách a domácnostech s nízkou spotřebou elektřiny. Jedná se o jednotarifní sazbu. To znamená, že se cena elektřiny během dne nemění. Primárně mluvíme o chatách, garážích a malých provozovnách. V naší databázi máme 11 odběrných míst s tarifem C01d a 41 odběrných míst s tarifem D01d. [2, 3]
- **C02d a D02d** - Tato sazba je v České republice nejvyužívanější. Narozdíl od předchozího tarifu může být k provozovně připojena výrobní elektřina a jistič nad 3 x 63 Ampér. Tato sazba má cenu elektřiny během dne pořád stejnou. Tarif s označením C02d používají provozovny firem. Tarif s označením D02d využívají běžné domácnosti. Jedná se tedy o ty provozovny a domácnosti, které mají běžné spotřebiče a spotřebu. Odběrná místa s tarifem D02d tvoří největší skupinu v naší databázi. Celkem máme k dispozici 180 odběrných míst s tímto tarifem. S tarifem C02d máme k použití 21 odběrných míst. Z celkových 412 odběrných míst tvoří téměř polovinu domácnosti a provozovny s běžnou spotřebou. [2, 3]
- **C03d** - U této sazby se jedná o provozovny firem s vysokou spotřebou. Vlastnosti této sazby jsou stejné jako u předchozí sazby, tedy cena elektřiny se

během dne nemění. V této kategorii známe pouze 2 odběrná místa s tímto tarifem. [3]

- **C25d a D25d** - U této sazby uvažujeme provozovny a domácnosti, které využívají elektřinu k ohřevu vody. Jedná se tedy o provozovny a domácnosti, které využívají elektrický bojler. Tato sazba je již dvoutarifní. To znamená, že 8 hodin denně je sazba v levnějším tarifu a zbylých 16 hodin v běžném režimu. V naší databázi jsou domácnosti, které využívají elektrický bojler druhou nejpočetnější skupinou, kdy tarifem D25d máme k dispozici 90 odběrných míst. Odběrná místa s tarifem C25d máme v databázi pouze 4. [2, 3]
- **D26d** - Tato sazba je pro domácnosti, které k vytápění využívají akumulární spotřebiče jako jsou například akumulární kamna. Opět se jedná o dvoutarifní sazbu, kdy se akumulární spotřebič nabíjí během těch 8 hodin, kdy je elektřina v levnějším tarifu. Z této kategorie máme pouze 1 domácnost s tímto tarifem. [2]
- **D35d** - Zde se jedná o domácnosti, které využívají kombinovaného vytápění. Jde o dvoutarifní sazbu, kdy se cena elektřiny 16 hodin pohybu v levnějším tarifu a zbylých 8 v běžném tarifu. V databázi máme k dispozici 4 odběrná místa s tímto tarifem. [2]
- **C45d a D45d** - Další sazba je pro domácnosti a provozovny, které používají přímotopné elektrické spotřebiče pro vytápění objektu. Hovoříme opět o dvoutarifní sazbě, kdy levnější tarif je 20 hodin denně a zbylé 4 hodiny jsou v běžném tarifu. Z této sazby máme k dispozici 15 domácností a 1 provozovnu. [2, 3]
- **C46d** - Jedná se o stejnou sazbu jako u C45d. Tedy jde o provozovny, které využívají přímotopné spotřebiče pro vytápění objektu. Z této kategorie máme v databázi pouze 1 provozovnu. [3]
- **D56D** - U této sazby se uvažují domácnosti, které využívají systém tepelného čerpadla pro vytápění objektu. Jedná se o dvoutarifní sazbu, kde 22 hodin denně je elektřina v levnějším tarifu. S touto sazbou máme v databázi 23 domácností. [2]


- **D57D** - Tato sazba je určena pro domácnosti, které používají elektřinu k vytápění. Stejně jako u tarifu D45d se jedná o dvoutarifní sazbu, kdy je levnější tarif 20 hodin denně. V databázi máme k dispozici 9 domácností. [2]
- **C62d** - Poslední sazba je určena veřejnému osvětlení. Jedná se o jednotarifní sazbu, tedy po celý den se cena elektřiny nemění. Z této sazby máme v databázi 2 odběrná místa. [3]

Distribuční sazba	Průměrná roční spotřeba [kWh]	Počet OM v databázi
C01d	3184	11
D01d	1879	41
C02d	10627	21
D02d	3109	180
C03d	17103	2
C25d	8519	4
D25d	3848	90
D26d	11280	1
D35d	12223	4
C45d	17505	1
D45d	10452	15
C46d	10922	1
D56d	13474	23
D57d	7875	9
C62d	47121	2

Tabulka 3.1: Tabulka průměrné spotřeby elektřiny podle distribuční sazby.

Do tabulky 3.1 byla vyobrazena průměrná spotřeba elektřiny dle tarifní sazby. Nejvíce relevantní jsou pro nás domácnosti s běžnou spotřebou, jelikož tato odběrná místa tvoří většinu v naší databázi. Dle největšího distributora elektřiny v České republice se průměrná roční spotřeba běžné domácnosti pohybuje kolem 3000 kWh [1]. To přibližně odpovídá průměru našich odběrných míst s tarifem D02d, kde průměrná roční spotřeba je 3109 kWh.

Pro vytvoření charakteristik odběrných míst jsme si vybrali odběrná místa z tarifu D02d, jelikož má ve zkoumaném vzorku dat dominantní zastoupení. Tedy dále budeme zkoumat pouze odběrná místa s tímto tarifem. Nejprve si určíme, podle čeho budeme odběrná místa charakterizovat. Odběrná místa budeme charakterizovat podle třech charakteristik. Jako první nás zajímá, jak se jednotlivá odběrná místa chovají, pokud je zrovna víkend nebo pracovní den. Dále se hodí odběrná místa charakterizovat podle ročního období. Nakonec budeme odběrná místa popisovat podle segmentu dne. Zřetelnější představu zobrazuje následující obrázek.



Obrázek 3.5: Vizualizace charakteristik OM. [11]


Popis jednotlivých charakteristik:

- **Segment dne** - Podle segmentu dne byla data rozdělena podle čtyř fází. První fázi tvoří ranní špička, tedy čas od 6:00 do 8:00. Druhou fázi představuje čas kolem poledne, přesně čas od 11:30 do 14:00. Třetí fázi tvoří odpolední hodiny od 15:00 do 16:00. Poslední fázi tvoří tři hodiny mezi 18:00 a 21:00. Celkem je tedy vektor segmentu dne tvořen čtyřmi prvky.
- **Roční období** - Dále byla data rozčleněna podle ročního období. Vektor ročních období je tvořen opět čtyřmi prvky. Tedy jaro, léto, podzim a zima.
- **Typ dne** - Poslední rozdělení dat bylo uděláno podle typu dne. Pokud je den sobota nebo neděle, byl den klasifikován jako nepracovní. Naopak pokud byl den v rozmezí pondělí až pátek, byl klasifikován jako pracovní. Vektor typu dne je tedy tvořen dvěma prvky.

Výslednou charakterizaci odběrného místa si lze představit jako krychli o rozměrech $4 \times 4 \times 2$, kde první vektor tvoří segment dne s velikostí 4, druhý vektor tvoří roční období s velikostí 4 a poslední vektor tvoří typ dne s velikostí 2. Jednotlivé buňky či výřezy uvedené krychle definují dimenzi pohledu na vybranou skupinu dat, která bude využita v následné implementaci.

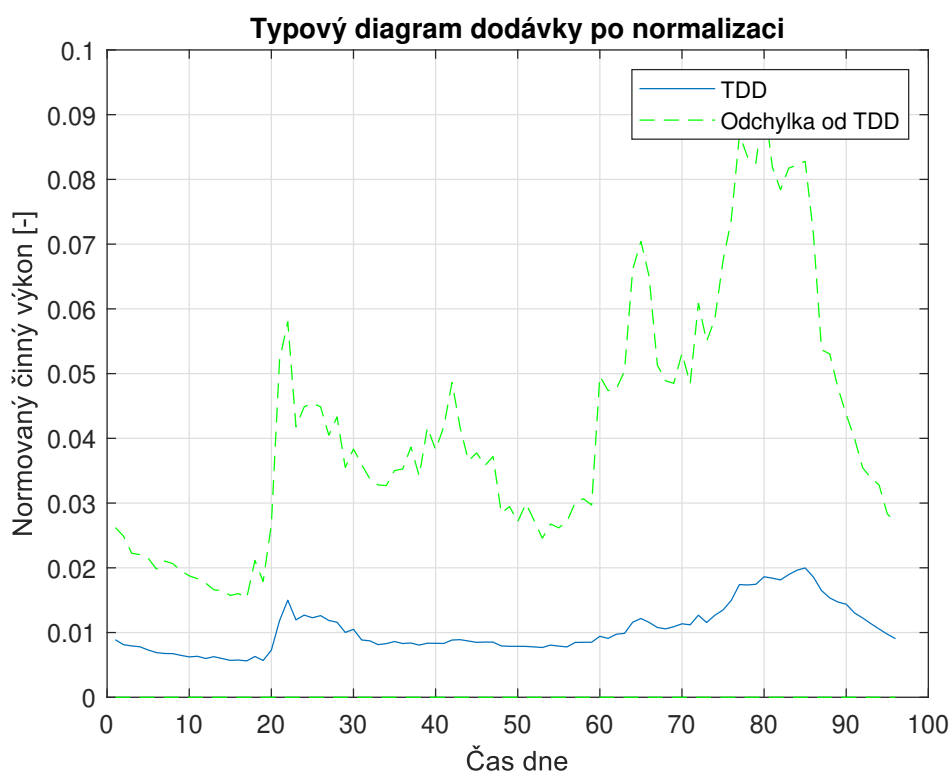
Typový diagram dodávky:

U každého odběrného místa jsme vytvořili typový diagram dodávky (TDD). Vycházeli jsme z pracovních dnů, kdy jsme si u každého odběrného místa vypočetli z dostupných pracovních dní 96 průměrných hodnot, které charakterizují průměrný pracovní den. Na grafech níže jsou zobrazeny vytvořené typové diagramy dodávek. Modře je vyznačena střední hodnota TDD a zeleně je vyznačeno pásmo věrohodnosti (99,7% kvantil). X-ovou osu tvoří čas dne po 15 minutách. Y-ovou osu představuje normovaný výkon.



Obrázek 3.6: Typový diagram dodávky

Ukázalo se, že pro potřeby navazující kategorizace je nutné vytvořené TDD znormovat. Normalizace provádíme, abychom relativní průběhy odběrných míst měli v porovnatelném rozsahu. Kdyby bylo chování dvou odběrných míst podobné, avšak s jinou absolutní hodnotou odebíraného výkonu, navazující metody shlukové analýzy by tato odběrná místa neklasifikovala jako podobná, jelikož by od sebe byla příliš daleko. K normalizaci použijeme podíl součtu středních hodnot průběhů v jednotlivých hodinách dne.



Obrázek 3.7: Typový diagram dodávky po normalizaci

3.3 Clusterová analýza

Vytvořené TDD z předchozí kapitoly použijeme jako vstupní data metody pro vytvoření shluků. Konkrétně využijeme shlukovací metodu zvanou k-means, která podobné TDD přiřadí do společných shluků. Funkčnost metody je posána níže.

Metoda k-means:

Metoda *k-means* je jednou ze základních metod používaných ve strojovém učení. Tato metoda je iterační, metoda se provádí několikrát s jinými počátečními body. Po ukončení metody bychom měli dostat optimální středy shluků (centroidy) s minimální kritériální funkcí. Jedinou nevýhodou této metody je počáteční znalost počtu shluků, to značí k v názvu metody.

V metodě *k-means* minimalizujeme ukazatel kvality J .

$$J = \sum_{i=1}^T J_i = \sum_{i=1}^T \sum_{x \in X_i} d^2(x, \mu_i) \quad (3.1)$$

kde T je celkový počet shluků, μ_i je střední hodnota i -tého shluku (centroidu), J_i je hodnota kritéria i -tého shluku a X je množina obrazů i -tého shluku.

Fáze metody:

- **Počet shluků** - V prvním kroku je volen počet shluků do kterých jsou data rozdělována. Optimální počet shluků k je možné určit experimentálně.
- **Počáteční body** - Počáteční body jsou náhodně vybrány podle zvoleného počtu k . Tyto body jsou označeny jako centroidy shluků.
- **Přirazení bodů do shluků a výpočet ukazatele kvality** - Jednotlivé body jsou přiřazovány k centroidům, ke kterým mají nejbližší vzdálenost. Tato vzdálenost je volena uživatelem. Nejčastěji je používána euclidovská vzdálenost. Ukazatel kvality J je vypočítán sumou jednotlivých kritériálních funkcí J_i , které jsou definovány jako suma kvadrátů vzdáleností všech bodů v shluku T_i od centroidu μ_i .
- **Výpočet nových centroidů** - U každého shluku je vypočítána střední hodnota, což je nový centroid shluku. K nově vytvořeným centroidům se přiřadí body do shluků a vypočte se nová kritériální funkce J , jak tomu bylo v předchozím kroku.
- **Konvergence algoritmu** - Pokud jsou centroidy v kroku $k+1$ stejné jako v kroku k , tak algoritmus dokonvergoval s ukazatelem kvality J , jinak se opět

vypočítají středy nových centroidů a nový ukazatel kvality J a algoritmus pokračuje.

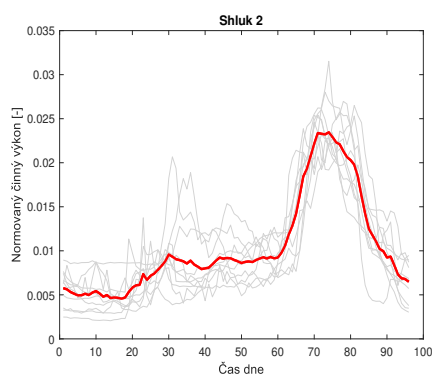
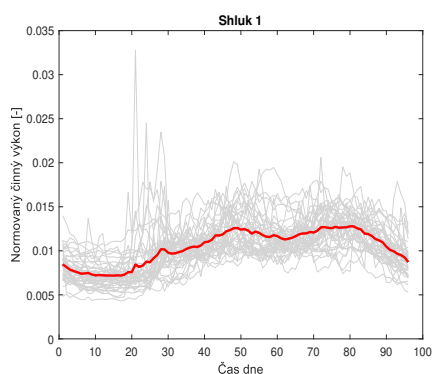
Podle metody *k-means* byly naše TDD rozděleny do shluků. Počet shluků nebyl předem známý, proto jsme experimentálně měnili parametr k . Došli jsme k závěru, že optimální počet shluků je roven $k = 6$.



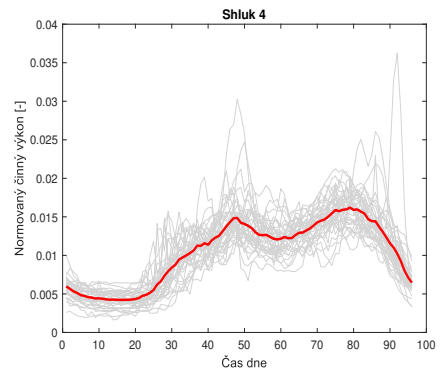

Vektor příznaků:

Nyní si z každého normalizovaného TDD vytvoříme takzvaný vektor příznaků (feature), který nám charakterizuje jednotlivé odběrné místo. Při cílených experimentech byly sestavovány různé vektory příznaků z charakteristik průběhu TDD (např. minimální hodnota, maximální hodnota, medián či quantily apod.) Na základě výsledku experimentů byl zvolen finální feature vektor, který je tvořen pouze středními hodnotami TDD, jelikož rozšíření feature vektoru o další příznaky nám nedalo lepší výsledky.

Vizualizace shluků:

Po provedení shlukové analýzy za použití metody *k-means* byly získány jednotlivé shluky, které jsou vyobrazeny na obrázcích níže. Červená čára vyznačuje střední hodnotu TDD daného daného shluku. Šedé čáry jsou tvořeny jednotlivými normalizovanými TDD. Na vodorovné je zobrazen čas dne po 15 minutách. Horizontální osu představuje normovaný výkon.

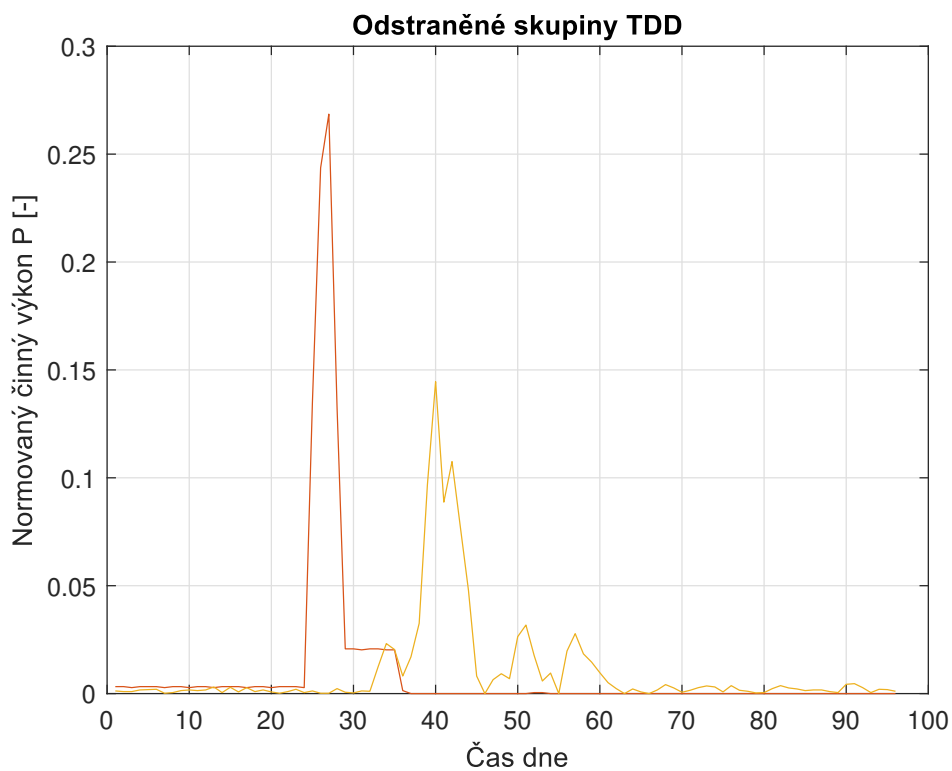




Některé typové diagramy dodávek byly z experimentu vyřazeny, jelikož vykazovaly netypické chování a metoda k-means je vyhodnotila jako samostatné shluky.

Vizualizace odstraněných TDD:

Na následujícím obrázku jsou zobrazeny odstraněné TDD. X-ová osa představuje čas dne po 15 minutách. Y-ová osa tvoří normovaný činný výkon.



Obrázek 3.8: Odstraněné feature vektory.

Analýza finálních shluků



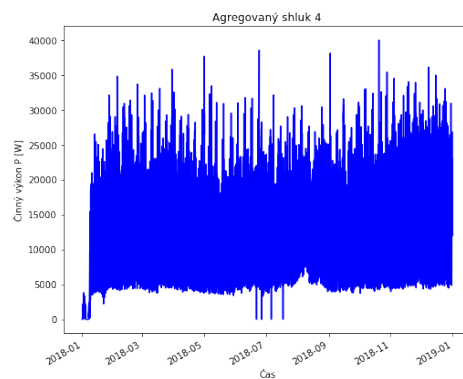



Charakteristiky finálních shluků jsou popsány v následující tabulce. Z celkových 6 shluků můžeme považovat 4 shluky za dominantní, jelikož z celkové spotřeby elektřiny je každý z nich zastoupen minimálně z 20 %. Odstraněná měření představují pouhé 2,8 % z celkové spotřeby elektřiny.

	Počet OM	Celková roční spotřeba[kWh]	Průměrná roční spotřeba OM [kWh]	Zastoupení spotřeby shluku [%]
Shluk 1	41	111674	2723	20
Shluk 2	10	34351	3435	6,1
Shluk 3	40	118659	2967	21,2
Shluk 4	36	123423	3428	22,1
Shluk 5	35	125612	3589	22,4
Shluk 6	14	30066	2148	5,4
Odstraněno	4	15803	3951	2,8
Celkem	180	559588	22241	100

3.4 Agregace měření

V této sekci jsme přešli od feature vektorů k průběhovému měření ve výkonu. Ze shlukové analýzy víme, jaké průběhy měření jsou si podobné. Průběhová měření v jednotlivých shlucích byla z agregována (sečtena). Tím byl získán agregovaný průběh spotřeby reprezentující daný shluk. Na obrázcích níže jsou zobrazeny agregované shluky. Vodorovná osa představuje čas a Horizontální osa prezentuje spotřebovaný výkon celého shluku.

Vizualizace agregovaných shluků

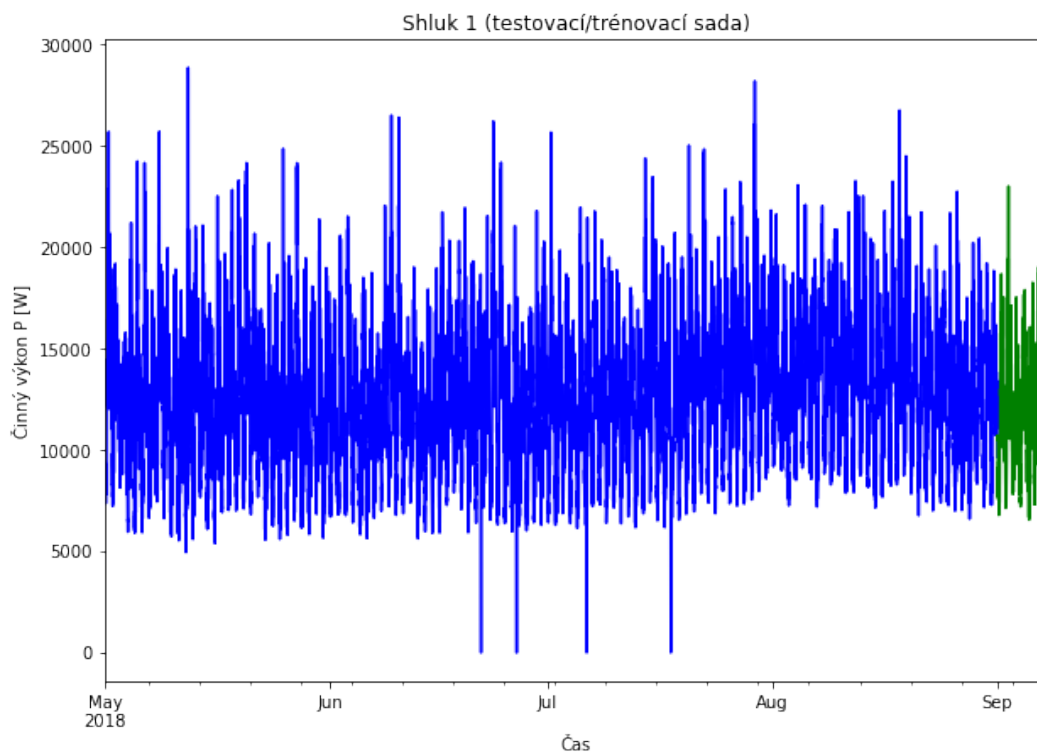


3.5 Data-driven model OM

V této sekci je popsáno vytvoření data-driven modelu odběrného místa. Pro jednoduchost a přehlednost experimentu byl vybrán shluk 1.

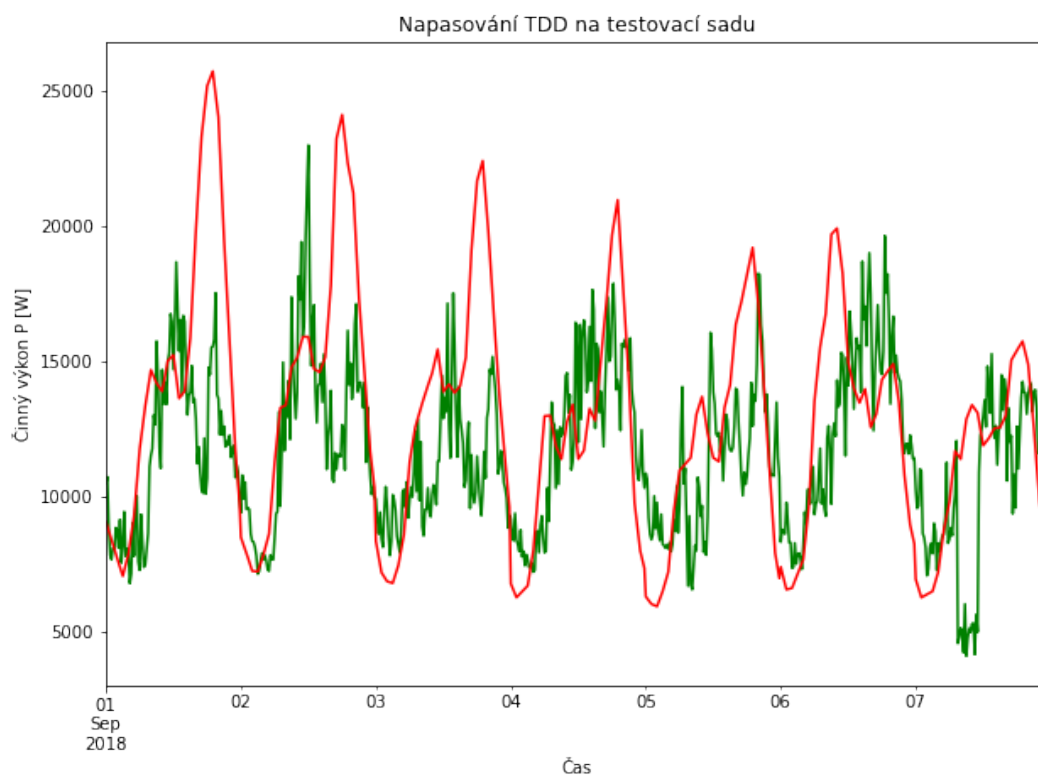
Rozdělení agregovaného shluku

Nejprve bylo provedeno rozdělení agregovaného průběhu na trénovací a testovací sadu v časovém intervalu, ve kterém jsou průběhová měření úplná. Na obrázku níže je trénovací sada popsána modrou barvou a testovací sada barvou zelenou. Trénovací sada je tvořena spotřebou od května do 3. týdne v září. Poslední týden v září je obsažen v testovací sadě. Vodorovnou osu tvoří čas a horizontální osu představuje spotřebovaný výkon celého shluku 1.



Napasování TDD na testovací sadu

Věřejně dostupný typový diagram dodávky zveřejněn operátorem trhu (OTE) byl napasován na vytvořenou testovací sadu, a to multiplikativně na základě spotřebované energie za dané období. Červenou barvou je vyobrazen přizpůsobený TDD získaný od OTE a zelenou barvou je znázorněna testovací sada (poslední týden v září). V grafu je na vodorovné ose čas, ve kterém se nachází testovací sada a na horizontální ose je spotřebovaný výkon.



Vytvoření modelu a použití metod strojového učení

V další fázi byl vytvořen predikční a simulační model, který byl natrénován pomocí trénovací sady. Vektor vstupních dat obsahoval pouze minimum informací a to pouze teplotu a časové údaje (hodina dne, den v týdnu apod.). Situace odpovídá dostupným údajům v daném čase a odběrném místě. Po natrénování modelu byly

provedeny predikce na testovací i testovací sadě použitím metod strojového učení.


Použité metody:

- **Linear Regression** - Tato metoda aproximuje data vhodnou parametrickou přímkou minimalizující kritérium sumy kvadrátů odchylek.
- **Gradient Boosted Trees** - Gradientní stromy jsou iterační metody, kdy je v aktuálním kroku vytvořen nový strom, který opravuje strom předchozí. Opět je minimalizováno jedno z kritérií. My jsme použili kritérium nejmenších čtverců a absolutní kritérium.
- **SVR** - Tato metoda je podobná lineární regrese, akorát místo minimalizace sumy kvadrátů odchylek se minimalizuje vektor koeficientů. Lze si definovat, jak velká odchylka bude v našem modelu akceptována.
- **Ensemble** - Ensemble kombinuje více metod zvolené uživatelem k nalezení optimálního modelu.


S ohledem na limitovaný rozsah bakalářské práce lze více informací o použitých metodách nalézt například v [24], [25].

Vizualizace výsledků shluku 1


V této části byly zobrazeny výsledky predikčních modelů vytvořené pomocí metod popsanych výše. V grafech je popsán průběhový diagram, kde na vodorovné ose je čas a na vertikální ose je spotřebovaný výkon. Modrou barvou je vyznačena testovací sada, zelenou barvou je zobrazen TDD od OTE a červenou barvou vyznačen predikční model, vytvořen pomocí metody vyznačené v legendě grafu.




Obrázek 3.9: Predikční model vytvořen metodou lineární regrese. Použitou metodou došlo ke zhoršení predikce oproti TDD od OTE. Tuto metodu můžeme považovat za nedostatečnou.




Obrázek 3.10: Predikční model vytvořen metodou gradientního stromu minimalizující absolutní kritérium. Touto metodou došlo k výraznému zlepšení oproti predikci vytvořené operátorem trhu.



Obrázek 3.11: Predikční model vytvořen metodou gradientního stromu minimalizující kritérium nejmenších čtverců. Touto metodou byl vytvořen velmi dobře predikující model.



Obrázek 3.12: Predikční model vytvořen metodou SVR. Model vytvořen touto metodou hůře reaguje na velké změny, avšak nejlépe vykompenzoval poruchu měření.



Obrázek 3.13: Predikční model vytvořen kombinací metody lineární regrese a Hist-GradientBoostingRegressor. Kombinací metod jsme získali velmi dobrý predikční model.

Definice míry kvality:

K vyhodnocení přesnosti predikčních modelů se užívají základní metriky - vychýlení (strannost, bias) a variabilita (variance). Oba pohledy využívají charakteristiky absolutní chyby predikce (rozdíl mezi predikovanou a skutečnou hodnotou). Nicméně pro efektivnější prezentaci a vyhodnocení kvality predikce se využívají i další metriky jako MAE, MAPE apod., které jsou diskutovány dále.

- **Absolutní chyba** - Absolutní chyba je počítána pomocí vzorce:

$$e(t) = \hat{y}(t) - y(t), \quad (3.2)$$

kde $y(t)$ skutečná hodnota a $\hat{y}(t)$ je hodnota predikovaná.

- **Bias** - Bias je definován jako střední hodnota absolutní chyby predikce. Naznačuje jak je model natrénován. Bias je počítán pomocí vzorce:

$$bias(t) = \frac{1}{N} \cdot \sum_{k=1}^N e(t-k), \quad (3.3)$$

kde N je počet uvažovaných vzorků výběrového souboru.

- **Variance** - Variance ukazuje jak bude natrénovaný model reagovat na testovací sadu. Čím je variance větší, tím hůř bude model predikovat konzistentně. Variance je počítána pomocí vzorce:

$$var(t) = \frac{1}{N} \cdot \sum_{k=1}^N (y(t-k) - bias(t-k))^2, \quad (3.4)$$

kde N je počet uvažovaných vzorků výběrového souboru

- **Mean Absolute Error (MAE)** - Tato míra je definována jako střední absolutní chybu odhadu. Potlačuje vliv outlierů a vyhodnocuje spíše robustnost odhadu. Tato metrika je počítána pomocí vzorce:

$$MAE(t) = \frac{1}{N} \cdot \sum_{k=1}^N |e(t-k)|, \quad (3.5)$$

kde N je počet uvažovaných vzorků výběrového souboru

- **Mean Absolute Percentage Error (MAPE)** - Tato míra slouží pro porovnání přesnosti predikčních modelů na jednotlivých datových sadách. Je velmi dobře interpretovatelná a robustní. Tato metrika je počítána pomocí vzorce:

$$MAPE(t) = \frac{1}{N} \cdot \sum_{k=1}^N \left| \frac{e(t-k)}{y(t-k)} \right| \cdot 100, \quad (3.6)$$

kde N je počet uvažovaných vzorků výběrového souboru

- **Root Mean Squared Error (RMSE)** - Tato metrika počítá průměrný kvadrát chyb odhadu. Větší váha je dáována odlehlým měřením, proto je vhodný k posouzení stability modelu. Tato metrika je počítána pomocí vzorce:

$$RMSE(t) = \sqrt{\frac{1}{N} \cdot \sum_{k=1}^N e(t-k)^2}, \quad (3.7)$$

kde N je počet uvažovaných vzorků výběrového souboru

- **MAX Absolute Error (Max AE)** - Tato metrika je počítána pomocí vzorce:

$$e_{MAX} = \max(|y(t) - \hat{y}(t)|), \quad (3.8)$$

kde $y(t)$ skutečná hodnota a $\hat{y}(t)$ je hodnota predikovaná.

Klasifikátory		Trénovací množina						Testovací množina						
Název	Čas trénování [s]	Bias [kW]	Variance [kW ²]	Max AE [kW]	MAE [kW]	MAPE [%]	RMSE [kW]	Bias [kW]	Variance [kW ²]	Max AE [kW]	MAE [kW]	MAPE [%]	RMSE [kW]	
Shluk 1	<i>TDD (baseline)</i>	0,09	10,95	15,60	2,50	20,23	3,31	-1,35	15,00	14,64	2,96	28,15	4,10	
	Linear Regression	0,0060	7,75	17,69	2,14	17,96	2,78	-0,68	6,60	11,06	2,06	20,62	2,66	
	HistGBRegressor (abs)	2,1510	0,14	2,39	10,65	1,10	8,65	1,55	-0,54	4,76	12,69	1,54	15,68	2,25
	HistGBRegressor (sqr,standard)	2,2730	0,01	1,52	8,22	0,92	7,44	1,23	-0,70	5,24	12,69	1,64	16,56	2,39
	SVR (n:standard)	7,1890	0,19	3,88	14,73	1,45	11,40	1,98	-0,15	6,30	8,78	1,85	17,48	2,51
	Ensemble	69,0530	0,14	2,54	11,33	1,15	9,12	1,60	-0,55	4,56	12,15	1,53	15,69	2,20
Shluk 2	<i>TDD (baseline)</i>	0,03	2,12	10,15	1,08	45,80	1,46	0,04	2,55	7,27	1,17	44,92	1,60	
	Linear Regression	0,0120	0,01	2,40	10,59	1,15	47,58	1,55	-0,14	3,48	7,73	1,47	60,47	1,87
	HistGBRegressor (abs)	9,1560	0,14	0,77	8,63	0,54	17,07	0,89	-0,16	1,91	5,99	1,04	41,77	1,39
	HistGBRegressor (sqr,standard)	1,4630	0,01	0,57	7,38	0,53	18,83	0,76	-0,42	1,80	5,59	1,06	43,94	1,40
	SVR (n:standard)	7,0290	0,21	1,29	10,03	0,77	25,24	1,15	0,39	2,84	8,00	1,25	45,26	1,73
	Ensemble	77,9930	0,11	0,90	9,10	0,64	22,31	0,95	-0,15	2,01	6,31	1,07	43,52	1,43
Shluk 3	<i>TDD (baseline)</i>	0,08	20,89	23,65	3,45	41,56	4,57	-0,55	19,73	14,42	3,41	45,86	4,48	
	Linear Regression	0,0150	0,02	12,22	21,09	2,64	34,01	3,50	-1,27	17,79	14,51	3,50	48,81	4,41
	HistGBRegressor (abs)	8,3830	0,16	2,97	12,37	1,14	15,93	1,73	-0,30	8,43	14,78	2,11	29,30	2,92
	HistGBRegressor (sqr,standard)	1,9060	0,02	2,15	9,85	1,07	13,10	1,47	-0,43	8,05	12,23	2,09	29,76	2,87
	SVR (n:standard)	7,0730	0,27	7,24	17,78	1,92	25,63	2,70	-0,19	13,99	14,60	2,74	32,53	3,75
	Ensemble	78,6470	0,14	3,41	13,97	1,28	17,90	1,85	-0,44	8,97	14,77	2,25	31,79	3,03
Shluk 4	<i>TDD (baseline)</i>	0,09	16,03	20,16	3,09	28,04	4,01	-0,95	17,06	21,90	3,37	34,97	4,24	
	Linear Regression	0,0110	0,03	16,54	25,28	3,10	29,51	4,07	-0,10	19,84	26,92	3,36	33,49	4,46
	HistGBRegressor (abs)	2,0280	0,16	3,48	12,79	1,29	10,09	1,87	-0,32	9,36	14,16	2,17	19,79	3,08
	HistGBRegressor (sqr,standard)	1,6520	0,01	2,38	9,65	1,13	9,25	1,54	-0,53	10,12	14,75	2,29	21,06	3,22
	SVR (n:standard)	7,1580	0,21	7,51	21,07	1,98	15,90	2,75	-0,79	11,52	18,57	2,71	27,06	3,48
	Ensemble	71,0520	0,05	3,60	13,13	1,34	10,70	1,90	-0,39	9,14	14,91	2,15	19,88	3,05
Shluk 5	<i>TDD (baseline)</i>	0,10	19,66	16,41	3,49	30,12	4,44	-0,74	17,55	13,09	3,40	31,42	4,25	
	Linear Regression	0,0110	0,02	7,99	15,96	2,19	19,42	2,83	-1,48	10,01	10,78	2,91	28,85	3,50
	HistGBRegressor (abs)	4,2220	0,17	2,87	16,21	1,18	10,49	1,70	-0,26	6,82	11,95	1,93	16,99	2,63
	HistGBRegressor (sqr,standard)	3,0840	0,01	1,82	11,04	1,02	8,91	1,35	-0,25	7,29	11,95	1,98	17,26	2,71
	SVR (n:standard)	7,3410	0,26	5,23	15,20	1,71	14,74	2,30	-1,29	7,71	10,49	2,44	22,69	3,06
	Ensemble	75,5840	-0,01	3,32	15,93	1,34	12,11	1,82	-0,75	6,76	11,41	2,08	19,25	2,71
Shluk 6	<i>TDD (baseline)</i>	0,02	1,63	7,96	0,90	39,72	1,27	-0,13	1,80	5,87	0,99	46,50	1,35	
	Linear Regression	0,0100	0,01	1,95	8,67	1,03	49,25	1,40	0,09	2,12	7,05	1,06	50,76	1,46
	HistGBRegressor (abs)	2,9270	0,13	0,65	5,61	0,50	18,36	0,82	0,00	0,99	4,13	0,67	27,54	1,00
	HistGBRegressor (sqr,standard)	1,5480	0,00	0,44	4,26	0,46	18,50	0,66	-0,12	1,04	4,35	0,70	30,49	1,02
	SVR (n:standard)	7,2510	0,19	1,14	8,38	0,71	27,05	1,08	0,27	1,47	6,27	0,83	35,12	1,24
	Ensemble	72,7460	0,02	0,69	5,83	0,54	21,85	0,83	-0,08	1,01	4,22	0,69	29,87	1,01

Klasifikátory		Trénovací množina						Testovací množina						
Název	Čas trénování [s]	Bias [%]	Variance [%]	Max AE [%]	MAE [%]	MAPE [%]	RMSE [%]	Bias [%]	Variance [%]	Max AE [%]	MAE [%]	MAPE [%]	RMSE [%]	
Shluk 1	<i>TDD (baseline)</i>	-	-	-	-	-	-	-	-	-	-	-	-	
	Linear Regression	0,0060	70%	29%	-13%	14%	11%	16%	49%	56%	24%	30%	27%	35%
	HistGBRegressor (abs)	2,1510	-46%	78%	32%	56%	57%	53%	60%	68%	13%	48%	44%	45%
	HistGBRegressor (sqr,standard)	2,2730	84%	86%	47%	63%	63%	63%	48%	65%	13%	45%	41%	42%
	SVR (n:standard)	7,1890	-106%	65%	6%	42%	44%	40%	88%	58%	40%	37%	38%	39%
	Ensemble	69,0530	-49%	77%	27%	54%	55%	52%	59%	70%	17%	48%	44%	46%
Shluk 2	<i>TDD (baseline)</i>	-	-	-	-	-	-	-	-	-	-	-	-	
	Linear Regression	0,0120	72%	-13%	-4%	-7%	-4%	-6%	447%	-36%	-6%	-26%	-35%	-17%
	HistGBRegressor (abs)	9,1560	-460%	64%	15%	50%	63%	39%	475%	25%	18%	11%	7%	13%
	HistGBRegressor (sqr,standard)	1,4630	75%	73%	27%	51%	59%	48%	1112%	30%	23%	9%	2%	12%
	SVR (n:standard)	7,0290	-711%	39%	1%	29%	45%	21%	-834%	-11%	-10%	-7%	-1%	-8%
	Ensemble	77,9930	-321%	57%	10%	41%	51%	34%	460%	21%	13%	8%	3%	11%
Shluk 3	<i>TDD (baseline)</i>	-	-	-	-	-	-	-	-	-	-	-	-	
	Linear Regression	0,0150	75%	42%	11%	24%	18%	24%	-133%	10%	-1%	-3%	-6%	2%
	HistGBRegressor (abs)	8,3830	-102%	86%	48%	67%	62%	62%	45%	57%	-3%	38%	36%	35%
	HistGBRegressor (sqr,standard)	1,9060	81%	90%	58%	69%	68%	68%	21%	59%	15%	39%	35%	36%
	SVR (n:standard)	7,0730	-235%	65%	25%	44%	38%	41%	65%	29%	-1%	20%	29%	16%
	Ensemble	78,6470	-76%	84%	41%	63%	57%	59%	20%	55%	-2%	34%	31%	32%
Shluk 4	<i>TDD (baseline)</i>	-	-	-	-	-	-	-	-	-	-	-	-	
	Linear Regression	0,0110	66%	-3%	-25%	0%	-5%	-2%	89%	-16%	-23%	1%	4%	-5%
	HistGBRegressor (abs)	2,0280	-74%	78%	37%	58%	64%	53%	67%	45%	35%	36%	43%	27%
	HistGBRegressor (sqr,standard)	1,6520	85%	85%	52%	63%	67%	62%	44%	41%	33%	32%	40%	24%
	SVR (n:standard)	7,1580	-137%	53%	-5%	36%	43%	31%	17%	32%	15%	20%	23%	18%
	Ensemble	71,0520	44%	78%	35%	57%	62%	53%	59%	46%	32%	36%	43%	28%
Shluk 5	<i>TDD (baseline)</i>	-	-	-	-	-	-	-	-	-	-	-	-	
	Linear Regression	0,0110	76%	59%	3%	37%	36%	36%	-100%	43%	18%	14%	8%	18%
	HistGBRegressor (abs)	4,2220	-78%	85%	1%	66%	65%	62%	64%	61%	9%	43%	46%	38%
	HistGBRegressor (sqr,standard)	3,0840	89%	91%	33%	71%	70%	70%	67%	58%	9%	42%	45%	36%
	SVR (n:standard)	7,3410	-160%	73%	7%	51%	51%	48%	-74%	56%	20%	28%	28%	28%
	Ensemble	75,5840	105%	83%	3%	62%	60%	59%	-2%	62%	13%	39%	39%	36%
Shluk 6	<i>TDD (baseline)</i>	-	-	-	-	-	-	-	-	-	-	-	-	
	Linear Regression	0,0100	67%	-20%	-9%	-14%	-24%	-10%	168%	-18%	-20%	-7%	-9%	-8%
	HistGBRegressor (abs)	2,9270	-628%	60%	30%	44%	54%	36%	103%	45%	30%	33%	41%	26%
	HistGBRegressor (sqr,standard)	1,5480	95%	73%	46%	49%	53%	48%	9%	42%	26%	29%	34%	24%
	SVR (n:standard)	7,2510	-1001%	30%	-5%	22%	32%	15%	309%	18%	-7%	16%	24%	8%
	Ensemble	72,7460	1%	58%	27%	40%	45%	35%	39%	44%	28%	30%	36%	25%

Vyhodnocení výsledků

Grafické výsledky všech predikčních modelů jsou vyobrazeny v příloze. Výsledky měř kvality a procentuální změny byly zaznamenány do tabulek výše. Z grafů je vidět, že nejlepší predikční modely byly vytvořeny použitím metod gradientních stromů, kde nejlepší výsledek je dán gradientním stromem minimalizující kritérium kvadrátů odchylek. Naopak nejhůře vyšla metoda lineární regrese, která bohužel vůbec neodpovídá testované sadě. Kombinací metod bylo dosaženo velmi slušného predikčního modelu. Všechny metody dokázaly vykompenzovat chybu měření, která nastala v 7. dnu testovací sady. Oproti typovému diagramu dodávky došlo k výraznému zlepšení. Můžeme tedy usuzovat, že pokud by účastníci trhu využily námi vytvořený predikční model, došlo by k efektivnějšímu nákupu elektřiny ze strany obchodníků, a tím i ušetření nákladů, které by jinak byly použity na kompenzaci vytvořené odchylky.

Kapitola 4

Implementace modelu skupiny odběrných míst

V této sekci byly popsány jednotlivé softwarové nástroje, které byly využity k vypracování praktické části. Dále byly stručně charakterizovány frameworky strojového učení, implementované funkcionality a datové struktury.

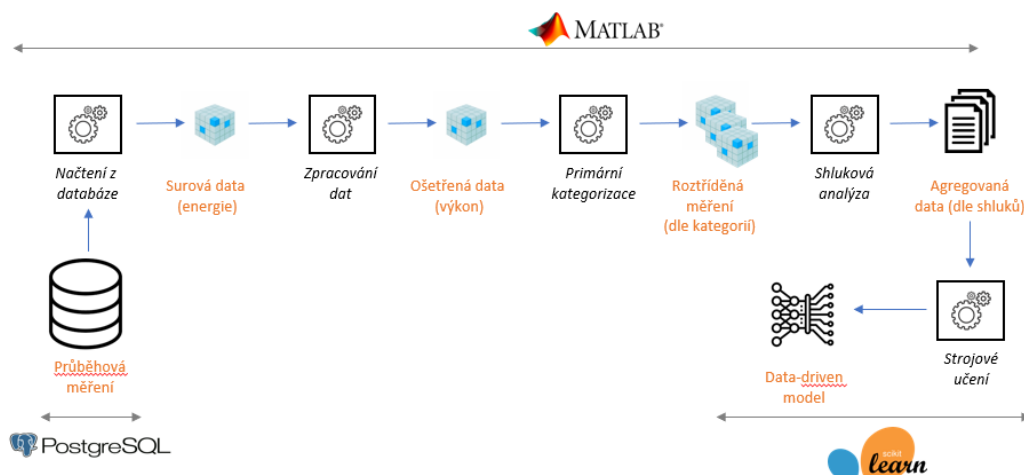
4.1 High-level schéma

High-level schéma vyobrazuje proces od samotných průběhových měření po vytvoření data-driven modelu. Dále toto schéma znázorňuje, jaké vývojové prostředí byly využity pro konkrétní implementaci.

4.2 Technologický stack

V této části jsou popsány jednotlivé vývojové prostředí a jejich využití v bakalářské práci. Celkem byly použity 3 vývojové prostředí.

- **PostgreSQL** - Primární data byla uložena v tomto databázovém prostředí. Pomocí SQL dotazů byly z databáze vybrány průběhová měření a příslušné informace o odběrných místech.
- **Matlab** - Ve vývojovém prostředí Matlab bylo prováděno načtení dat z databáze, zpracování dat, primární kategorizace a shluková analýza.



Obrázek 4.1: High-level schéma

- **Jupyter notebook/scikit learn** - V prostředí Jupyter notebook bylo provedeno vytvoření data-driven modelů pomocí frameworku scikit learn, který nám poskytl velkou škálu metod strojového učení.

4.3 Frameworky strojového učení

V této podkapitole byly popsány 3 základní frameworky strojového učení. Všechny tyto frameworky jsou typu *open source*. Jde tedy o softwary, jejichž zdrojový kód je volně přístupný. Jednotlivé popisy vychází ze studie využitelnosti přístupů umělé inteligence.

- **TensorFlow** - Disponuje komplexním a flexibilním systémem nástrojů, knihoven a komunitních zdrojů, který umožňuje výzkumníkům využívat nejmodernější technologie strojového učení a vývojářům snadno vytvářet a nasazovat aplikace strojového učení v Pythonu. Jedná se o nejpoužívanější open source nástroj v oblasti neuronových sítí. Má detailně dokumentované API a rozsáhlou knihovnu příkladů modelů z nejrůznějších oblastí. [21]
- **PyTorch** - Urychluje cestu od výzkumných prototypů do produkčního prostředí. Poskytuje širokou paletu nástrojů pro tvorbu modelů - neuronových

sítí, deep learningu a zpětnovazebního učení. Nabízí podrobně dokumentované API s řadou příkladů z oblasti zpracování řeči, obrazu, textu a dalších. [21]

- **Scikit-learn** - Knihovna, která podporuje strojové učení s učitelem i bez učitele. Poskytuje také různé nástroje pro přizpůsobení modelu, předzpracování dat, výběr a vyhodnocení modelu a mnoho dalších nástrojů. K dispozici je podrobná dokumentace API, široké spektrum ukázkových příkladů a návodů. [21]

4.4 Implementované funkcionality

V této části byli stručně popsány implementované funkcionality.

- **Načtení dat** - Pro načtení dat z databáze byly vytvořeny specializované skripty v Matlabu, díky kterým byla získána surová data.
- **Zpracování dat** - Vstupem této funkce byla surová data, která byla následně zbavena chyb měření. Navíc při úpravě došlo k převedení dat z energie na výkon. Výstupem byly tedy ošetřená data ve výkonu.
- **Primární kategorizace** - V této funkci byla ošetřená data rozdělena do jednotlivých primárních kategorií (např. podle sazby).
- **Shluková analýza** - Vstupem této funkce byla data jedné kategorie, která byla následně rozdělena do shluků dle použitých feature vektorů.
- **Strojové učení** - Jednotlivé shluky byly zagregovány a rozděleny na testovací a trénovací sady. Na tyto sady byly použity metody strojového učení a získány příslušné modely.

Kapitola 5

Závěr

Bakalářská práce je tvořena z teoretické a praktické části. V teoretické části byl nejprve popsán současný stav elektrické soustavy od výroby elektřiny až po koncového zákazníka. Následně byla specifikována chytrá síť a s ní spojený abstraktní model SGAM. V souladu se zadáním byly identifikovány případy užití provozu chytrých sítí, přičemž byl vybrán jeden případ užití pro realizaci - modelování chování skupiny odběrných míst. Při analýze daného případu užití byly charakterizováni jednotliví účastníci trhu s elektřinou a jejich motivace znalosti chování odběratele či skupiny odběratelů. Cílem praktické části bylo vytvořit, implementovat a otestovat metodiku pro modelované skupiny odběrných míst pro potřeby simulace či predikce chování vybraných skupin zákazníků. Pro vytvoření těchto modelů byla použita reálná a anonymizovaná data z průběhového měření získaná od společnost ČEZ Distribuce a.s. Nejprve byla načtena průběhová měření spotřeby z databáze. Tyto data byla následně zpracována a segmentována dle distribuční sazby. Tím byla odběrná místa klasifikována do společných skupin. Dále byla vybrána dominantní skupina s tarifem D02d, se kterou byla prováděna clusterová analýza. Z jednotlivých odběrných míst byly vytvořeny typové diagramy dodávek, které byly následně znormálovány a roztrženy do shluků. Jednotlivé shluky byly zregrované a rozděleny na trénovací a testovací sady. Dále byly popsány dostupné open source frameworky strojového učení, ze kterých byl k následnému vytvoření simulačních a predikčních modelů využit framework scikit learn. Pro vyhodnocení metod byly použity různé míry kvality, pomocí kterých byly sumarizovány výsledky jednotlivých modelů. Z výsledků je patrné, že simulační i predikční modely jsou výrazně přesnější než současně využívané typové diagramy dodávky, které jsou vytvářeny operátorem trhu.

Jemnější disagregace typového diagramu dodávky a zpřesnění odhadu spotřeby má výrazný dopad na zkvalitnění tržních a provozních procesů z pohledu jednotlivých stakeholderů.

Literatura

- [1] *Jaká je průměrná spotřeba elektřiny u rodinného domu?*[online]
<https://www.cez.cz/cs/clanky/jaka-je-prumerna-spotreba-elektriny-u-rodinneho-domu-157416>
- [2] *Přehled distribučních sazeb elektřiny*[online]
<https://www.cez.cz/cs/podpora/vsechny-clanky/prehled-distribucnich-sazeb-elektriny-93426>
- [3] *Přehled distribučních sazeb*[online]
<https://www.cezesco.cz/cs/podpora/prehled-distribucni-sazeb-elektriny-152491>
- [4] *Vysoké učení technické v Brně – VUT. Vysoké učení technické v Brně* [online].
Copyright © 2022 VUT [cit. 31.07.2022].
https://www.vut.cz/www_base/zav_prace_soubor_verejne.php?file_id=57357
- [5] *Svět Energie - Svět energie.cz* [online]
<https://www.svetenergie.cz/cz/energetika-zblizka/distribuce-elektriny/distribuce-elektricke-energie-podrobne/elektrizacni-a-prenosova-soustava/vyklad>
- [6] *Svět Energie - Svět energie.cz* [online]
<https://www.svetenergie.cz/cz/energetika-zblizka/distribuce-elektriny/distribuce-elektricke-energie-podrobne/distribucni-soustava/vyklad>

- [7] *Národní energetický mix — Čeština. [online]. Copyright © OTE, a.s., 2018 [cit. 31.07.2022].*
<https://www.ote-cr.cz/cs/statistika/narodni-energeticky-mix>
- [8] *FANG, Xi, Satyajayant MISRA, Guoliang XUE a Dejun YANG. Smart Grid — The New and Improved Power Grid: A Survey. IEEE Communications Surveys & Tutorials [online]. 2012, 14(4), 944-980 [cit. 2022-08-14]. ISSN 1553-877X.*
Dostupné z: doi:10.1109/SURV.2011.101911.00087
- [9] *Decentralizovaná energetika 3D. Svět Energie - Svět energie.cz [online].*
<https://www.svetenergie.cz/3d/decentralizovana-energetika/>
- [10] *Národní energetický mix — Čeština. [online]. Copyright © OTE, a.s., 2018 [cit. 31.07.2022].*
<https://www.ote-cr.cz/cs/statistika/narodni-energeticky-mix>
- [11] *PyPI Package and Documentation Storage [online]. Copyright ©AWW [cit. 31.07.2022].*
https://pythonhosted.org/cubes/_images/cube-dims_and_cell.png
- [12] *Výklad - Energetika zblízka - Svět energie.cz. Svět Energie - Svět energie.cz [online]. Copyright © IKvyatkovskaya [cit. 31.07.2022].*
<https://www.svetenergie.cz/cz/energetika-zblizka/distribuce-elektriny/distribuce-elektricke-energie-podrobne/odberna-mista/vyklad>
- [13] *Z čeho se skládá cena elektřiny? | E.ON. [online].*
<https://www.eon.cz/radce/zelena-energie/ceny-energie/z-ceho-se-sklada-cena-elektriny/>
- [14] *O ERÚ | eru.cz. Energetický regulační úřad | eru.cz [online]. Copyright © Energetický regulační úřad [cit. 31.07.2022].*
<https://www.eru.cz/o-eru#pravomoc-a-pusobnost-eru>
- [15] *Trh s elektřinou - specifiky, účastníci trhu a rozdělení. oEnergetice.cz - denní zpravodajství z energetiky [online].*
<https://oenergetice.cz/trh-s-elektrinou/trh-s-elektrinou>

- [16] *Obchodní podmínky obchodníka s elektřinou*
https://www.cez.cz/edee/content/file/pece-a-podpora/cezprodej_opoe_20110430.pdf
- [17] *Základní údaje — Čeština. [online]. Copyright © OTE, a.s., 2018 [cit. 31.07.2022].*
<https://www.ote-cr.cz/cs/o-spolecnosti/zakladni-udaje>
- [18] *Ministerstvo průmyslu a obchodu [online]. Copyright ©d [cit. 31.07.2022].*
<https://www.mpo.cz/assets/cz/energetika/strategicke-a-koncepcni-dokumenty/narodni-akcni-plan-pro-chytre-site/2020/1/Role-agregatora-v-ceske-energetice.pdf>
- [19] *GOTTSCHALK, Marion, Mathias USLAR a Christina DELFS. The Smart Grid Architecture Model – SGAM. In: GOTTSCHALK, Marion, Mathias USLAR a Christina DELFS. The Use Case and Smart Grid Architecture Model Approach [online]. Cham: Springer International Publishing, 2017, 2017-01-13, s. 41-61 [cit. 2022-08-14]. SpringerBriefs in Energy. ISBN 978-3-319-49228-5. Dostupné z: doi:10.1007/978-3-319-49229-2_3*
- [20] *HOOSHYAR, Hossein a Luigi VANFRETTI. A SGAM-based architecture for synchrophasor applications facilitating TSO/DSO interactions. In: 2017 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT) [online]. IEEE, 2017, 2017, s. 1-5 [cit. 2022-08-14]. ISBN 978-1-5386-2890-4. Dostupné z: doi:10.1109/ISGT.2017.8085977*
- [21] *Studie využitelnosti přístupů umělé inteligence v ČEPS a.s., Střelec et. a.l.2020*
- [22] *Energy union[online]*
https://energy.ec.europa.eu/topics/energy-strategy/energy-union_en
- [23] *BAYINDIR, R., I. COLAK, G. FULLI a K. DEMIRTAS. Smart grid technologies and applications. Renewable and Sustainable Energy Reviews [online]. 2016, 66, 499-516 [cit. 2022-08-15]. ISSN 13640321. Dostupné z: doi:10.1016/j.rser.2016.08.002*
- [24] *NASTESKI, Vladimir. An overview of the supervised machine learning methods. HORIZONS.B [online]. 2017, 4, 51-62 [cit. 2022-08-15]. ISSN*

18578578.

Dostupné z: doi:10.20544/HORIZONS.B.04.1.17.P05

- [25] *ELITH, J., J. R. LEATHWICK a T. HASTIE. A working guide to boosted regression trees. Journal of Animal Ecology [online]. 2008, 77(4), 802-813 [cit. 2022-08-15]. ISSN 0021-8790. Dostupné z: doi:10.1111/j.1365-2656.2008.01390.x*






Příloha A

Vizualizace výsledků predikčních modelů pro jednotlivé shluky






Seznam příloh

- Příloha 1 - Predikční modely shluku 2
- Příloha 2 - Predikční modely shluku 3
- Příloha 3 - Predikční modely shluku 4
- Příloha 4 - Predikční modely shluku 5
- Příloha 5 - Predikční modely shluku 6






Příloha 1








Příloha 2



Příloha 3



Příloha 4



Příloha 5

