

Fakulta elektrotechnická
KEE - Katedra elektroenergetiky

DIPLOMOVÁ PRÁCE

Využití real-time prediktivních simulací pro energetický management

Autor práce:	Michael Bárta
Vedoucí práce:	Ing. Václav Mužík Ph.D.
Konzultant práce:	Ing. Václav Mužík Ph.D.

ZÁPADOČESKÁ UNIVERZITA V PLZNI

Fakulta elektrotechnická
Akademický rok: 2022/2023

ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Bc. Michael BÁRTA**
Osobní číslo: **E21N0001P**
Studijní program: **N0713A060013 Výkonové systémy a elektroenergetika**
Specializace: **Elektroenergetika**
Téma práce: **Využití real-time prediktivních simulací pro energetický management**
Zadávací katedra: **Katedra elektroenergetiky**

Zásady pro vypracování

1. Zmapujte využití real-time prediktivních metod pro účely energetického managementu.
2. Provedte analýzu měřených vstupních dat a navrhnete vhodnou optimalizaci.
3. Vytvořte funkční real-time optimalizační algoritmus v prostředí MATLAB pro účely energetického managementu.
4. Popište výsledky a možnost nasazení v reálných podmínkách.

Rozsah diplomové práce: **40 – 60**
Rozsah grafických prací: **2**
Forma zpracování diplomové práce: **elektronická**

Seznam doporučené literatury:

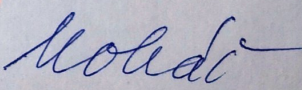
1. TSO, Geoffrey K.F. a Kelvin K.W. YAU, Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks, Elsevier Ltd. [online], 2006.
2. Parisio A., Rikos E. a L. Glielmo. A Model Predictive Control Approach to Microgrid Operation Optimization, v IEEE Transactions on Control Systems Technology, vol. 22, no. 5, pp. 1813-1827, 2014.
3. Müller V., „Parametrické modelování spotřeby elektrické energie pomocí prediktivních metod“, Diplomová práce, Západočeská univerzita v Plzni, 2021.

Vedoucí diplomové práce: **Ing. Václav Mužík, Ph.D.**
Research and Innovation Centre for Electrical
Engineering

Datum zadání diplomové práce: **7. října 2022**
Termín odevzdání diplomové práce: **26. května 2023**




Prof. Ing. Zdeněk Peroutka, Ph.D.
děkan


Doc. Ing. Karel Noháč, Ph.D.
vedoucí katedry

V Plzni dne 7. října 2022

Abstrakt

V této diplomové práci se budu věnovat problematice real-time predikce v energetice. Důvodem realizace této práce je absence této tematiky v širším povědomí a minimální využití v energetice. Práce je rozdělena na teoretickou a praktickou část.

V teoretické části pojednávám o problematice tématu neuronových sítí a částí potřebných a využitých v praktické části. V teoretické části jsou tedy zmíněny pojmy jako neuronová síť zpětného šíření, Fotovoltaika, pojem čtvrhodinové maximum a způsob jeho regulace a kondenzační baterie. Praktická část je pak zaměřena přímo na ukázkou predikce a návrh jejího využití pro regulaci.

Celou práci a její výsledky jsou pak shrnuty v závěru který je dále rozdělen na 3 části, kde první se zabývá čistě predikcí spotřeby objektu a možnostmi optimalizace. Druhá problematikou predikce fotovoltaické elektrárny. Třetí část je zaměřena na regulaci na základě predikce a jejím zhodnocení.

Klíčová slova

Neuronové Sítě, Predikce, Energetické systémy, Regulace, Řízení, Fotovoltaika, Kogenerační jednotky, energetické bateriové systémy, Čtvrhodinové maximum.

Abstract

In this master's thesis, I will focus on the issue of real-time prediction in the field of energy. The reason for undertaking this work is the lack of awareness and minimal utilization of this topic in the energy sector. The thesis is divided into a theoretical and practical part.

In the theoretical part, I discuss the issues related to neural networks and the components necessary and utilized in the practical part. Specifically, I address concepts such as backpropagation neural network, photovoltaics, the concept of quarter-hourly maximum, its regulation, and condensing batteries. The practical part is then focused on demonstrating the prediction and proposing its utilization.

The entire work and its results are summarized in the conclusion, which is further divided into three parts. The first part deals solely with the prediction of object consumption and optimization possibilities. The second part addresses the prediction of a photovoltaic power plant. The third part focuses on regulation based on prediction and its evaluation.

Keywords

Neural Networks, Prediction, Energy Systems, Regulation, Control, Photovoltaics, Cogeneration Unit, Battery systems, Four Hour Maximum.

Poděkování

Chtěl bych poděkovat hlavně svému vedoucímu práce doktorovi Václavu Mužíkovi za poskytnuté množství jeho času, odborné vedení a velkou trpělivost. Také bych chtěl poděkovat své rodině za podporu při studiu. A v poslední řadě bych rád poděkoval těm, co ve mně nevěřili a tím mi dodali energii tuto práci napsat.

Obsah

Seznam použitých symbolů a zkratk	vi
Seznam obrázků	vii
Seznam tabulek	viii
Úvod	1
1 Teoretický úvod k praktické části	2
1.1 Neuronové sítě	2
1.1.1 Obecný model umělého neuronu	2
1.1.2 Učení neuronových sítí	3
1.1.3 Metoda zpětného šíření	4
1.1.4 Levenberg-Marquardtův algoritmus (LV)	5
1.1.5 Problematika odbugování	5
1.1.6 Princip odbugování	5
1.1.7 Problematika overfittingu	6
1.1.8 Binární rozhodování NN	7
1.2 Akumulace elektrické energie v bateriích	7
1.2.1 Základní pojmy	8
1.2.2 Olověné akumulátory	9
1.2.3 Nikl - kadmiové baterie (Ni-Cd)	9
1.2.4 Lithium-iontové baterie (Li-Ion)	9
1.3 Kogenerační jednotka (KGJ)	10
1.3.1 Druhy kogeneračních jednotek a jejich využití	10
1.3.2 KGJ s organickým rankinovým cyklem	11
1.3.3 KGJ s plynovou turbínou	11
1.4 Fotovoltaické panely	13
1.4.1 Panely první generace	13
1.4.2 Panely druhá generace	13
1.4.3 Panely třetí generace	13
1.5 Čtvrthodinové maximum	13
1.5.1 Standartní regulace čtvrthodinového maxima	14
1.5.2 Regulace čtvrthodinového maxima kogenerační jednotkou	14
1.6 Ovládání baterie pro regulaci odběru	15
1.6.1 Peak-shaving	15

1.6.2	Load-shifting	16
1.7	Definice Chyb	17
1.7.1	Absolutní chyba	17
1.7.2	Relativní chyba	17
2	Praktická část	18
2.1	Predikce spotřeby	18
2.1.1	Popis objektu	18
2.1.2	Neuronová síť spotřeby	19
2.1.3	Výsledky predikce spotřeby	19
2.1.4	Postupná predikce spotřeby	23
2.1.5	Vyhodnocení predikce spotřeby	24
2.2	Predikce výroby fotovoltaické elektrárny (FV)	26
2.2.1	Popis objektu FV	26
2.2.2	Neuronová Síť výroby FV	27
2.2.3	Výsledky predikce výroby FV	28
2.2.4	Dopočet Chybných dat FV	29
2.2.5	Zhodnocení predikce výroby FV	30
2.3	Využití NN pro regulaci	33
2.3.1	Záměr	33
2.3.2	Popis objektu FV	33
2.3.3	Neuronová Síť pro regulaci	33
2.3.4	Rozhodovací funkce If	34
2.3.5	Zhodnocení predikce regulace	35
3	Zmapování využití NN v energetice	38
3.1	Význam umělých neuronových sítí pro lokalizaci poruch přenosových soustav: Průzkum	38
3.2	Praktická metoda založená na strukturálních neuronových sítích pro optimalizaci provozu energetické soustavy	38
4	Závěr	40
4.1	Zhodnocení výsledků predikce spotřeby	40
4.2	Zhodnocení výsledků predikce výroby FV	40
4.3	Zhodnocení využití NN pro regulaci	41
4.4	Souhrn závěru	42
	Seznam použité literatury	44

Seznam použitých symbolů a zkratek

Značka	Popis	Jednotka
<i>ORC</i>	Organický Rankinův cyklus	-
<i>KGJ</i>	Kogenerační jednotka	-
<i>SW</i>	Software	-
<i>NN</i>	neurová síť (Neural Network)	-
<i>GAN</i>	Generická Síť (generative adversarial networks)	-
<i>KGJ</i>	Kogenerační jednotka	-
<i>BESS</i>	Bateriové uložení (Battery Energy Storage System)	-
<i>LV</i>	Levenberg-Marquardtův algoritmus	-
<i>BR</i>	(Bayesian Regularization)	-
<i>AAE</i>	Průměrná absolutní chyba (average absolute error)	kW
<i>ARE</i>	Průměrná relativní chyba (average relative error)	%
<i>MRE</i>	Maximální relativní chyba (Maximum relative error)	%

Seznam obrázků

1	Obecný model neuronu převzato z (8)	3
2	Gradientní metoda. převzato z (7)	4
3	Ukázka augmentace dat. převzato z (13)	6
4	Ukázka GAN. převzato z (13)	7
5	Proudění iontů (Li+) při jednotlivých stavech baterie. převzato z (6)	10
6	schéma zapojení ORC Kogenerační jednotky. převzato z (2)	11
7	Základní schéma Plynové turbíny. převzato z (3)	12
8	Základní schéma Plynové turbíny. převzato z (3)	15
9	Vyzualizace peak-shaving. převzato z (14)	16
10	Vyzualizace load-shifting. převzato z (14)	16
11	Ukázka nezávislosti spotřeby na teplotě (data duben 2021)	18
12	Výsledky jednotlivých typů NN na tréninkových datech (data 19.-21. duben 2021)	21
13	Výsledky jednotlivých typů NN na datech u učení (data 20.-22. duben 2022) . . .	22
14	Vyhodnocení chybovosti jednotlivých sítí pro jednotlivá data	23
15	Ukázka výsledků jednotlivých sítí pro jednotlivá data za období 20.- 22. dubna 2023	24
16	Vyhodnocení chybovosti přístupu bez přepočítávání neuronové sítě a s přístupem postupného trénování	25
17	Graf výsledků postupného trénování pro celý půlrok	25
18	Ukázka z naměřených dat za rok 2021 s hlavním důrazem na ukázkou chyb měření	27
19	Ukázka z výsledků predikce za 20. až 22. dubna roku 2021	28
20	Ukázka z naměřených dat za rok 2021 s důrazem na ukázkou chyb měření.	29
21	Ukázka dopočtených dat chybějících v měření.	30
22	Porovnání predikce na "neznámých" datech od 20. do 22. dubna 2022.	31
23	Celý půlrok roku 2022 od března do srpna predikovaných dopředu.	32
24	Rozhodovací funkce if.	34
25	Predikce stavu sítě z predikované bilance.	35
26	Predikce stavu sítě z reálné bilance.	36
27	Ukázka problému násobící chyby pro stav sítě.	36
28	Ukázka problému se spínáním baterie	37
29	(23)	38

Seznam tabulek

1	Tabulka ukazující vstupní data do NN pro predikci spotřeby	19
2	Tabulka ukazující vstupní data do NN pro predikci výroby FV	27

Úvod

Hlavním důvodem, proč jsem si zvolil toto téma je fakt, že neuronové sítě jsou zajímavým trendem. Poslední dobou není snad nikdo, kdo by v poslední době alespoň neslyšel o "chatGPT", který je na nich založený. Ale jak fungují? to byla hned první otázka, kterou jsem si položil a touto prací se snažím na ní odpovědět a zároveň ukázat cestu pro další práce, které se pokusí spojit problematiku energetiky a neuronových sítí. V práci se tedy pokouším o real-time predikci energetického systému.

Práci jsem rozdělil na 3 části, kde první je teoretický úvod k práci. Druhý je praktická část, kde se snažím čtenáři ukázat možnosti predikce spotřeby objektu a výroby FV. Dále se v této části věnuji problematice rozhodování neuronových sítí a problému navazování sítí. V třetí části jen velice krátce zmapuji aktuální využití neuronových sítí v energetice.

Celou práci uzavře závěr, který shrnuje všechny problematiky uvažované v této práci a pojednává o možných důvodech chybovosti predikcí, možných způsobech zpřesnění atd. Pevně doufám, že po přečtení této práce budete mít alespoň základní představu o problematice neuronových sítí a uznáte tuto tematiku za zajímavou a užitečnou s jistým potenciálem pro energetiku.

1 Teoretický úvod k praktické části

V této kapitole bych rád představil témata, která považuji za nutná či užitečná pro porozumění praktické části a pro pochopení některých možností řešení při jejich realizaci. Převážně se tak bude jednat o výňatky z dost komplexních témat, která ne vždy plně vysvětlují celou problematiku.

1.1 Neuronové sítě

Pojem neuronová síť je jedním z nástrojů pro analýzu dat v různých oblastech a vznikla při snaze o napodobení neurofyziologie lidského mozku. Neuronové Sítě (NN) využívají analytické techniky modelované v závislosti na procesech učení v kognitivním systému a neurologických funkcích mozku. Umí tedy predikovat nová pozorování na základě využití předchozího učení této sítě. Fungují dobře hlavně pro nelineární funkce, kde nemáme znalost matematických funkcí popisujících fyzikální a matematické vztahy mezi vstupy a výstupy daného systému. (7)

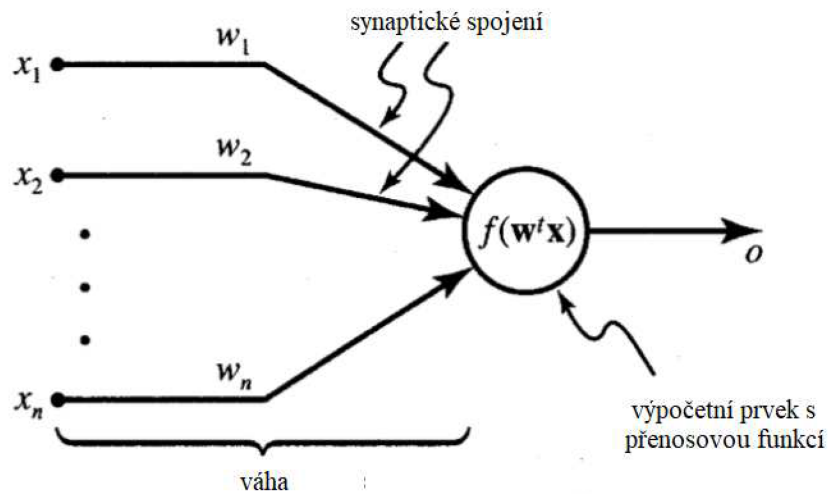
Jedná se o zajímavou metodu predikce, kterou jsme s dobrými daty a tedy dobrým naučením sítě, schopni dosáhnout vysoké přesnosti i bez znalosti jakékoliv fyzikální či matematické rovnice. Problém pak může být, pokud v systému dojde k takovému stavu, který nebyl součástí učení a byl tedy nepředvídatelný. (7)

1.1.1 Obecný model umělého neuronu

Jedná se o základní představu umělého neuronu, ze které vychází různé složitější druhy neuronových modelů a pro jeho jednoduchost je využito několik zjednodušení. Neuron samotný je základem modelu jako prvek zpracovávající vstupy modelu, které jsou přivádějí synaptické přípojnice. Všechny vstupní hodnoty mají určitou váhu, která násobí vstupní informaci. Model má pak pouze jeden výstup a jedná se pouze o jednosměrný tok dat. Přivedená data jsou integrována do neuronu, který stanovuje primární (přenosová) funkce. (8)

$$0 = f\left(\sum(w_i, x_i)\right) \quad (1)$$

V této funkci je pak \mathbf{w} vektor vah a \mathbf{x} je vektor vstupů. Schéma obecného modelu je vidět na obrázku 1. Neuronová síť je tedy síť primitivních funkcí, které přesně transformují vstupy na přesně definovaný výstup.



Obrázek 1: Obecný model neuronu převzato z (8)

1.1.2 Učení neuronových sítí

Učení neuronových sítí je proces, při kterém je cílem nastavit síť tak, aby dávala co nejpřesnější výsledky na základě zkušeností uložených v jejich matematickém ekvivalentu. Tento proces je jeden ze základních pojmů nutných pro celkové pochopení funkce těchto sítí. Při zahájení práce s neuronovou sítí jsou neurony "hloupé" a tedy jejich predikce by nebyla k ničemu. Proto je potřeba je takzvaně natrénovat. To se provádí tak, že do neuronové sítě pošleme přiměřené množství vstupních dat a k nim i data výstupní. Standardně se poskytují naměřená data jak predikovaná tak vstupní.

Toto učení můžeme přirovnat k aproximaci neznámé spojité funkce $h(x)$ o více proměnných jinou funkcí $H(w, x)$, kde, jak již víme, w je vektor vah a x je vektorem stupňů. Učení je pak nalezení takového váhového vektoru, který by poskytoval nejlepší možnou aproximaci neznámé funkce. Kvalita samotného naučení je funkce vzdálenosti mezi oběma rovnicemi, viz. rovnice 5. (7,8)

$$p(H(w, x), h(x)) \quad (2)$$


Učení NN je možné dvěma možnými způsoby. Prvním z nich je využití tzv. učitele, což je v podstatě zavedení zpětné vazby, která zná odchylku od skutečné hodnoty. Určuje tedy chybu sítě. Tato chyba slouží ke korekci síťových parametrů, z čehož by mělo plynout zmenšování této odchylky v dalších krocích. Druhý způsob nazvaný učení bez učitele se liší v tom, že požadovaný výsledek není známý. Chybové informace nemůžeme využít pro vylepšení výsledků sítě. V této metodě se pozorují odpovědi na výstupy a síť si je shromažďuje na základě jejich podobnosti. (7,8)

1.1.3 Metoda zpětného šíření

Metoda zpětného šíření je způsob šíření chyb adaptačního algoritmu. Využívá se až v 80 procentech všech aplikací neuronových sítí. Je rozdělena do tří fází a to na dopředné šíření vstupního signálu trénovaného vzoru, zpětné šíření chyby a aktualizace váhových hodnot spojení. V průběhu dopředného šíření je vysílaný signál (vstupní data x_i) a přenesen ke všem neuronům vnitřní vrstvy. Ty pak spočítají svou aktivaci nebo-li výstup (y), čímž získáme odezvu neuronové sítě na vstupní data. Důležitý proces je pak stanovení synaptických vah (w). Ten souvisí s opačným šířením informace od vrstev vyšších k nižším při již je porovnávána aktivace s definovanou výstupní hodnotou nebo-li učebním vzorem. Tím je definována chyba neuronové sítě. (7)

Jednou z důležitých vlastností je zobecnění (generalizace), díky které jsme schopni odvodit výsledek i u těch situací (dat), které nebyli součástí učení. To způsobuje nastavení jednotlivých vah (w). Pro tento účel se stanovuje počet skrytých vrstev, který odpovídá složitosti sítě. Čím složitější problém, tím se obecně doporučuje větší počet těchto vrstev. (7)

Další pojem je pak tzv. overfitting (přeučení sítě). To je problém, protože se síť špatně generalizuje a to tím, že jsou moc zobecněné tréninková data včetně nepřesností a chyb. Minimalizace se pak řeší ideální velikostí sítě a následné omezení chyb se pak řeší gradientní metodou, u níž je nutná diferencovatelnost chybové funkce $E(w)$. Snažíme se proto získat takovou konfiguraci, pro kterou je chybová funkce minimální. (7)



Obrázek 2: Gradientní metoda. převzato z (7)

Jak je patrné z obrázku 4 snahou je dosažení co nejnižší chybové funkce a tím i chyby. Postupuje se tak, že se začne s náhodnou konfigurací $w(0)$ a tím získáme tečný vektor $\text{grad}(w_0)$ a posuneme se o epsilon čímž získáme $w(1)$ (7)

1.1.4 Levenberg-Marquardtův algoritmus (LV)

Jedná se o rozšířenou a vylepšenou metodu oproti standardní metodě zpětného šíření. Jedná se o neuronovou síť vhodnou k využití nelineárního cvičení algoritmů, kde se využívá jak gradientní metody, tak kvazi-Newtonova metody kombinovaně. Tato kombinace zajistí vysokou lokální rychlost konvergence a udrží se lepší celkový výkon. Kvazi-Newtonova metoda slouží k vyhledávání nul, maxim a minim funkcí. (7)

Hlavní myšlenkou u toho algoritmu je, že každá iterace, podél jednoho negativního směru gradientu není delší než je nutné. To umožňuje vyhledávat chyby ve směru zhoršování. Pomocí kombinace metod nejstrmějšího klesání a Gauss-Newtonovi metody dochází k efektivní konvergenci, jelikož se tím zlepšuje rychlost konvergence a zobecnění dat. Hlavním rozdílem mezi Levenberg-Marquardtův algoritmus a klasickou metodou zpětného šíření je rychlost konvergence dat a menší oscilace během trénování sítě, což z ní dělá metodu velice zajímavou.

1.1.5 Problematika odbugování

Jedním z dalších zajímavých témat ohledně neuronových sítí je tzv. odbugování neboli odstranění chyb. Hlavní proces pro odstranění chyb je závislý na typu využití neuronové sítě. Například, pokud se jedná o predikci trhu, může jít o finanční ztráty. U predikce energetického systému se bude jednat o chybu ohrožující stabilitu sítě. Nejedná se o nic nového, každý software (SW) tímto problémovým procesem musí projít. Na rozdíl od SW nejde u neuronových sítí odstranit bugy přímo, protože se nejedná o snadno upravitelnou část kódu. (10,11,12)

Obecně lze bugy modelu rozdělit na strukturální chyby a bugy v učení. Chyby strukturální jsou způsobeny suboptimálními strukturami modelu, jako je počet vrstev a propojení neuronů. Bohužel se obecně tyto chyby odstraňují jen velice těžko. Naopak chyby ve výcviku, které budou popsány v další části, vznikají v důsledku problémů ve výcvikovém procesu. (10,11,12)


Problémem chyb ve výcviku neboli během učení NN je, že strojové učení předpokládá vstupní data k učení a data reálného světa sledují stejnou nebo hodně podobnou "problematiku". To je ovšem problém převážně proto, že zisk těchto dat je v praxi nereálný, jsou tedy například příliš specifické nebo nemají dostatečnou rozlišovací schopnost. Hlavním principem dosažení nižší chybovosti je poskytnutí dostatečného množství tréninkových dat, která jsou co nejpodobnějších reálným stavům. To však neplatí vždy, což bude vysvětleno v dalších podkapitolách. (10,11,12)

1.1.6 Princip odbugování

Jak již bylo zmíněno v předchozí části, jediným způsobem, jak opravit chyby modelů NN, je poskytnout více výcvikových dat. Pro překonání problému nedostatku reprezentativních dat na-

vrhli výzkumníci mnoho technik augmentace nebo generování dat, které generují nové výcvikové vzorky podobná poskytnutým vstupním vzorkům. (10,11,12,13)

První metodu, kterou můžeme použít, je augmentace. Jedná se o jednoduchou metodu využívající převážně přidání tzv. šumových dat. Je to poměrně jednoduchý princip. Hlavní nevýhodou je, že se musí najít vhodná množina transformace, která daný bod příliš nezmění. Popsaná skutečnost je vidět na obrázku 3. (10,13)




Obrázek 3: Ukázka augmentace dat. převzato z (13)

Druhou metodou je tedy generace dat. Nejčastěji se využívají GAN modely, které dosahují dobrých výsledků hlavně u vizuálních problémů například pro rozpoznávání obrázků. Princip GAN je založen na dvou neuronových sítích pracujících společně. První jako generátor, který se snaží vygenerovat neoptimálnější data tak, aby je druhá síť jako diskriminátor nerozeznal od dat původních viz obr. 4. Více do hloubky je pak tento princip popsán v (13). Mnoho zdrojů popisuje, že je tato metoda poměrně efektivní. Například v (10) je popsán rozdíl u rozpoznávání čísel, kde byl problém u rozpoznání čísla 5. Zde NN vykazovala jen 74 procentní úspěšnost. Při využití generování dalších dat pomocí GAN došlo sice k delším dobám výpočtu, ale přesnost dosahuje až k 94 procentům. (10,11,12,13)

1.1.7 Problematika overfittingu

Overfitting neboli přeučení je pojem popisující problém s přesností modelu NN při učení. Hlavní příčinou je, že neuronovou síť učíme na sérii dat, abychom predikovali jinou obvykle následující



Obrázek 4: Ukázka GAN. převzato z (13)

sérii dat. Pokud se přitom snažíme najít největší přizpůsobení trénovacím datům, hrozí riziko, že se přizpůsobíme šumu v datech a NN si zapamatuje různé anomálie. Tento jev se nazývá overfitting. (7,17,18)

Velice zjednodušeně se dá jev popsat tak, že pokud bude síť obsahovat příliš velký počet skrytých neuronů, tato síť nejčastěji nebude mít problém navést a reprezentovat závislosti v trénovacích datech, ale její schopnost generalizace, tedy schopnost vystihnout správný výsledek na nových datech, bude pravděpodobně horší. (17,19)

Z těchto důvodů není cílovou funkcí funkce minimalizace chyby na testovacích datech. Pro řešení tohoto problému byly představeny různé penalizační členy, jako jsou metody regularizace, metody minimální délky popisu, generalizovaná křížová validace a další. Většina těchto členů se snaží predikovat přesnost modelu NN na neviditelných datech s ohledem na výkon na trénovacích datech. Při začlenění těchto korekčních členů do funkce můžeme využít optimalizačního algoritmu pro optimalizaci. Problémem je však složitost výpočtu. Další možností je využití jednoduchých algoritmů sestupu po gradientu a tzv. hladových algoritmů zahrnujících optimalizační členy. Tento postup je suboptimální při hledání nejmenší rozhodovacího stromu, který vyhovuje datům. Velice zajímavé je, že při řešení neuronových sítí je optimální nebyť optimální. (17,18)

1.1.8 Binární rozhodování NN

Uvažování neuronové funkce, jejíž výstupy jsou binární tedy 1 nebo 0, je vhodné pro rozhodovací funkce. Hlavním faktorem je to, že každý neuron má vlastní booleovský obvod, který funkci reprezentuje. Vložený booleovský obvod nemusí být zpracovatelný, avšak NN tento obvod překompileje do zpracovatelného obvodu tím, že na obvod uplatní další postupy děje v oblasti znalostní kompilace, dokud obvod nebude zpracovatelný. Poté dochází k ověření a vysvětlení rozhodnutí vlastnostmi obvodu. (21, 22)

1.2 Akumulace elektrické energie v bateriích

V této podkapitole se budu zabývat různými typy baterií, které jsou využívány pro energetické systémy. Zároveň se je zde pokusím porovnat mezi sebou a tím definovat, pro jaké účely by měly být jednotlivé typy použity. Jako první definujeme základní pojmy, které jsou důležité pro pochopení a porovnání baterií. Druhy článků jsou rozděleny na primární a sekundární. Primární články jsou ty, které nelze opětovně dobíjet. Sekundární pak využívají takové technologie, u

kterých je opětovné dobíjení možné.

1.2.1 Základní pojmy

V této části se pokusím vysvětlit důležité základní pojmy, které budou nadále uplatněny v popisu jednotlivých typů baterií a jejich rozdílech.

1. Článek baterie
 - Nejmenší část baterie - článek, který se dále spojuje do větší jednotky - baterie pomocí sério-paralelního zapojení. (4)
2. Hloubka vybití
 - Tento pojem určuje množství vybité energie vzhledem k celkové kapacitě baterie. Často se udává v procentech. (4)
3. Počet cyklů
 - Jedná se o počet cyklů (vybití a nabíjení) na specifikovanou hloubku vybití, než změřená kapacita klesne na 80 procent nominální kapacity baterie. (4)
4. Nominální kapacita
 - Množství energie, kterou baterie uchovává v plně nabitém stavu. (4)
5. Stav nabití
 - Určuje množství nabitě energie vůči maximálnímu množství energie baterie. (4)
6. Energetická hustota
 - Nominální energie na jednotku objemu baterie. (4)
7. Samovybití
 - Samovybití je vlastnost všech baterií, jedná se především o velikost parazitního odporu, který výrazně zvyšuje právě samovybití. (4,6)
8. Životnost článků
 - Životnost akumulátorů je definována především počtem cyklů, velikostí přebíjení, teplotou prostředí a provozními teplotami. Jedním ze sledovaných parametrů je pak napětí baterie, které může výrazně naznačovat výrazné stárnutí baterie. (6)
9. Nežádoucí stavy
 - Nežádoucí stavy jsou stavy, které mají negativní vliv na kapacitu a životnost článku. Prvním z nich je přebíjení tedy stav, kdy se snažíme do článku vnést více energie než je jeho nominální hodnota. Druhým je pak podbíjení tedy vybití pod mez minimálního nabití. Poslední jev se nazývá nadproudové zatížení nastává v momentě kdy zatěžujeme článek nadměrným proudem, který následně způsobuje značný ohřev. Zahřívání může vést ke snížení životnosti, ale také k možnému fyzickému poškození baterie. (6)

1.2.2 Olověné akumulátory

Tyto akumulátory využívají jako elektrolyt vodu zředěnou kyselinou sírovou. Obě elektrody jsou pak tvořeny různými strukturami olova. Olověné baterie jsou historicky nejpoužívanější ve fotovoltaických systémech převážně díky relativně nízkému samovybití. To však neplatí při výrazném zvýšení teploty. Nevýhodou těchto akumulátorů je omezený počet cyklů, především pak při vyšší hloubce vybití. Proto se dnes olověné akumulátory využívají převážně jako záložní zdroj, který se udržuje v nabitém stavu. Další možností využití je v automobilech. (4, 5)


1.2.3 Nikl - kadmiové baterie (Ni-Cd)

Elektrolytem pro tyto baterie je hydroxid draselný. Kladná elektroda je tvořena hydroxidem nikelnatým a záporná pak kadmium. Jedná se o baterie s poměrně velkou životností (tedy počtem cyklů), zároveň pak nejsou náročné na údržbu. Další výhodou je snášenlivost vysokých nabíjecích proudů a tedy snížení doby nabíjení. Rovněž tento typ akumulátoru snese velké teplotní rozdíly až v rozmezí -20 do 45°C. Nevýhodou je hlavně cena, jedovatost kadmia a memory effect, který při opakování vybití na určitou hloubku vybití trvale sníží napětí baterie. Z důvodu memory effectu se většinou Ni-Cd baterie používají jen k úplnému vybití a nabíjení. Tento typ baterií se dá skladovat vybitý bez většího vlivu na životnost. (4, 5)

Zajímavou alternativou jsou Ni-MH akumulátory, které mají větší kapacitu na nižší prostorovou náročnost tedy energetickou hustotu a neobsahují kadmium, které je jedovaté. Avšak nejsou vhodné pro vysoké nabíjecí a vybíjecí proudy. Jejich využití je v telefonech nebo akumulacním nářadí. (4, 5)

1.2.4 Lithium-iontové baterie (Li-Ion)

Lithium-iontové baterie mají kladnou katodu tvořenou kovovými oxidy lithia a zápornou uhlíkem. Při vybíjení a nabíjení se mezi katodou a anodou pohybují ionty. Napětí článku je 3,6V. Hlavní výhodou je poměrně vysoký počet cyklů, které dosahují i 500 a více cyklů. Další výhodou je vysoká energie na kilogram, kde lithium-iontové baterie dosahují okolo 150 Wh/kg. Samovybití těchto baterií je pak taktéž na nízké úrovni okolo 2 až 3 procent. Zároveň se dají provozovat od -20 do 60°C, což je dost velký tepelný rozsah. Mezi nevýhody pak nesporně patří vysoká pořizovací cena a tepelná nestabilita kovových oxidů lithia při přebíjení a podbíjení. Jedná se o aktuálně nejpoužívanější typ baterií s využitím různých druhů kovových oxidů lithia v kombinaci s jinými materiály jako například lithium-železo fosfátové baterie atd. Využívají se v přenosných zařízeních jako jsou telefony a elektrické ruční nářadí, ale také v energetice ať už v domácí kombinaci s fotovoltaickými panely, nebo pro podporu stability sítě. (4, 5, 6)



Obrázek 5: Proudění iontů (Li^+) při jednotlivých stavech baterie. převzato z (6)

1.3 Kogenerační jednotka (KGJ)

Význam slova kogenerace je současná výroba tepla a elektřiny většinou v řádu do 1000 kW fungující na principu spalovacího motoru. Základní výhodou KGJ je pak vyšší účinnost, která se dokonce v některých případech blíží až účinnosti samotného paliva. Hlavní nevýhodou je vstupní investice a samotná složitost zařízení. (2)

1.3.1 Druhy kogeneračních jednotek a jejich využití

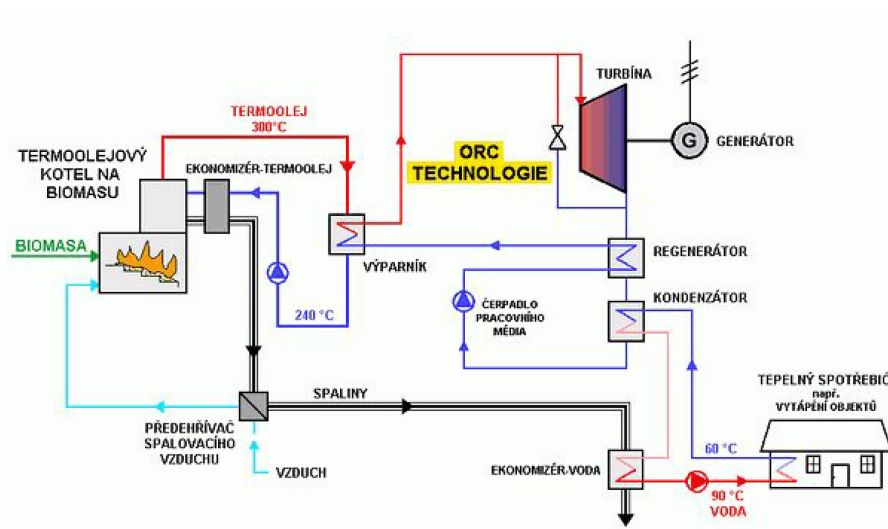
V této podkapitole se budu věnovat jednotlivým typům kogeneračních jednotek. Rozeberu zde jen ty nejzajímavější typy.

1. KGJ s parní turbínou
 - Využívají se pro velké teplotenské výkony a mezi její základní rozdílové části patří parní kotel a parní turbíny. Z toho plyne, že médiem pro vytápění je vodní pára, nebo musíme do obvodu přidat výměník pro předání energie mezi párou a výhřevnou vodou.
2. KGJ s parním strojem
 - U KGJ s parním strojem vykonává parní stroj funkci přeměny tepelné energie na mechanickou. Obecně se jedná spíše o speciální realizaci, která za běžných okolností není moc vhodná.
3. KGJ s organickým Rankinovým cyklem - ORC
 - Tomuto typu se budu dále věnovat v podkapitole 3.3.2, kde ji rozeberu více dopodrobna.
4. KGJ s plynovou turbínou
 - Podobně jako předchozí bod si i plynová turbína zaslouží větší rozvedení viz. podkapitola 3.3.3.

5. KGJ s palivovými články
 - Jedná se o zajímavý přístup k KGJ. Palivové články zde vytvářejí elektrickou energii pomocí konverze chemické energie na elektrickou. Technologie je obecně zajímavá, ale jejím problémem je vysoká cena palivových článků.
6. KGJ s pístovými spalovacími motory
 - Principem této KGJ je klasický spalovací motor spojen s generátorem. Největší výhodou je jednoduchost, nenáročnost a snadná dostupnost.
7. KGJ s plynovým motorem
 - KGJ s plynovým motorem využívá pístového motoru a generátoru na společné hřídeli. Teplo se získává z chladicího okruhu motoru, Jedná se o využití tepelných ztrát nejen však motoru, ale také chlazení oleje, výstupních spalin a někdy i chlazení generátoru. (2)

1.3.2 KGJ s organickým rankinovým cyklem

Díky využití ORC dokáže KGJ pracovat s nižšími teplotami a je tedy vhodná pro spalování biomasy a dalších podobných paliv. Jedná se o podobný systém používaný u běžných elektráren a tepláren s tím rozdílem, že je zde místo vody použito organické medium tedy olej. Obecně má tento typ KGJ vysokou účinnost a nízké otáčky. Výkon bývá až do stovek KW. (2)




Obrázek 6: schéma zapojení ORC Kogenerační jednotky. převzato z (2)

1.3.3 KGJ s plynovou turbínou

Tato KGJ využívá jako pracovní látku plyn. Většinou se jedná o vzduch hlavně z důvodu jednoduchého přístupu a možnosti využít otevřený cyklus. Funguje na principu spalování při vysokém tlaku ve spalovací komoře, kde vznikají horké spaliny, které v turbíně převedou energii na mechanickou a ta v generátoru na elektrickou. Zbytkové teplo se dá využít přes výměník pro ohřev vody. Je možné využít jak otevřený tak uzavřený cyklus, kde každý z cyklů má své výhody.

Pokud ve výměníku využijeme energii na ohřátí vody až do stavu syté páry, můžeme využít další turbíny a generátor a tím dostaneme paro-plynou kogenerační jednotku. Ta pak dosahuje vysokých účinností, má ale také vyšší pořizovací náklady. (2,3)



Obrázek 7: Základní schéma Plynové turbíny. převzato z (3)

1.4 Fotovoltaické panely

Tady si rozebereme základní typy panelů a jejich běžné využití. Fotovoltaické panely jsou v dnešní době velkým tématem. Jedná se o jeden ze základních obnovitelných zdrojů využívající světlo slunce pro tvorbu elektrické energie. V závislosti na typu panelu se pak liší účinnosti při různých osvitech.

1.4.1 Panely první generace

Jedná se o krystalické křemíkové desky. Články pak rozdělujeme na monokrystalické a polykrystalické. Účinnost těchto panelů je mezi 16 až 19 procenty, Výhodou je že mají dlouhou stabilitu a životnost. Naopak nevýhodou je hlavně vysoká spotřeba křemíku. I přesto, že jsou poměrně drahé, stále se jedná o jeden z nejpoužívanějších typů. (9)

1.4.2 Panely druhá generace

Jejich koncept vznikl hlavně z důvodu šetření polovodičovým materiálem a snížení ceny samotných panelů. Tento typ panelů je v principu až 1000 krát tenčí díky novým technologiím. Hlavně se jedná o články z amorfního, mikrokrystalického křemíku nebo směsných polovodičových materiálů. Jednou z velkých výhod je možnost nanášení těchto tenkých vrstev na různé podklady. Mezi možné podklady patří například sklo, plast nebo i textil. Bohužel se tento typ panelů nevyrovnává první generaci co se týká účinnosti, která se zde pohybuje pouze okolo 10 procent. Další nevýhodou je nižší životnost. Přesto se jedná o zajímavý koncept se zajímavou využitelností. (9)

1.4.3 Panely třetí generace

Hlavním důvodem pro vytvoření této generace bylo snaha o zvýšení účinnosti, na rozdíl od druhé generace, kdy bylo snahou snížit spotřebu materiálu. Hlavními technologiemi, které tyto články využívají jsou vícevrstvé a koncentrátorové články. Tyto technologie však zatím nejsou komerčně dostupné. U vícevrstvých článků dochází k využití více vrstev světla, v každé vrstvě dochází k využití jiného spektra. Teoretické maximum účinnosti při využití této technologie je až 68 procent. Koncentrátorové články využívají k vyššímu výkonu tok světla zrcadla nebo fresnelovy čočky. Obecně se jedná o zajímavý koncept. Otázkou však bude celková cena těchto panelů. (9)

1.5 Čtvrthodinové maximum

Jedná se o jeden ze základních nákladů spojených s odběrem elektrické energie pro střední a velké odběratele. Zjednodušeně se jedná o maximální odebraný výkon za období 15 minut. Tedy

nezáleží na tom, jaký byl okamžitý výkon v určitých okamžicích ani na průběhu, ale pouze na celkovém odebraném výkonu. Tato hodnota měří a vyhodnocuje se v průběhu celého týdne, není-li smlouvou stanoveno jinak. Každý odběratel si může vybrat mezi dvěma variantami vyhodnocení spotřeby a tedy i platby podle:

1. Naměřené maximální hodnoty čtvrt hodinového odběru
 - U tohoto typu vyhodnocení není pevně stanovené maximum, ale zároveň se většinou jedná o výrazně dražší variantu.
2. Dohodnuté maximální hodnoty čtvrt hodinového odběru
 - Zde je předem smluvně dohodnutý maximální výkon, který může odběratel odebrat v období 15 minut. Jedná se o běžnější variantu, a pokud odběratel pravidelně nepřekračuje dohodnutý výkon, která je zároveň levnější. (1)

1.5.1 Standartní regulace čtvrt hodinového maxima


Na základě výše zmíněných důvodů je pro odběratele důležité, aby sám sledoval a reguloval odebíraný výkon, a tak se nedopouštěl překračování stanoveného maxima. Na trhu se již dnes pohybuje spousta firem zabývajících se právě touto regulací. Hlavním způsobem regulace je ořezávání výkonových špiček. Toho se docílí spínáním a odpínáním jednotlivých spotřebičů na základě potřeby. Používají se dva základní režimy. (1)

1. Hladinový režim
 - K aktivaci/zásahu dochází, pokud pokud měřený interval dosáhne předem nastavené hodnoty. Opětovné připojení spotřebiče nebo-li odstranění zásahu pak nastává na začátku dalšího měřeného intervalu. Jedná se o poměrně jednoduchý způsob řízení.
2. Trendový režim (1)
 - K regulaci/zásahu zde dochází tehdy, když je výpočtem zjištěno, že dosavadní velikost odběru by měla za následek překročení stanoveného čtvrt hodinového maxima. K odstranění zásahu/regulace, dochází v momentě, kdy připojení neohrozí překročení sjednaného limitu případně na začátku dalšího intervalu. (1)

Pro regulaci se standardně používají spotřebiče, jejichž vyřazení nezpůsobí vážně ekonomické ztráty, omezení či narušení technologie nebo jinak neomezí odběratele. (1)

1.5.2 Regulace čtvrt hodinového maxima kogenerační jednotkou

Jedná se o aktivní regulaci, kde zdrojem, který musí zvýšit svůj výkon, je kogenerační jednotka. Jedná se o způsob, kdy při vyhodnocení rizika překročení čtvrt hodinového maxima zvýší kogenerační jednotka svůj elektrický výkon, čímž se pokusí pokrýt tento výkon, který by jinak přesáhl čtvrt hodinové maximum. Pokud však dojde k vyhodnocení, že poskytnutý výkon je nedostatečný,



Obrázek 8: Základní schéma Plynové turbíny. převzato z (3)


musí dojít k odepnutí určité spotřeby, pokud se chceme vyhnout platbě za vyšší čtvrt hodinový odběr než by nasmlouván. (4)

1.6 Ovládání baterie pro regulaci odběru

Tuto část jsem do práce přidal hlavně jako ukázkou principu, jak se následně s baterií pracuje. Hlavním principem je využití kapacity baterie k pokrytí určité části vyšších výkonů. Tedy nejdůležitějším pojmem je lokální výkonová bilance, která nám udává, že všechnen výkon, který jen nad námi stanoveným limitem, musí být schopna a připravena pokrýt v tomto případě baterie. V principu se pak může jednat jak o pozitivní výchylku, kdy potřebujeme ze sítě odebrat výkon například z fotovoltaiky, tak naopak negativní, kdy je naopak energie potřeba dodat. (14)

1.6.1 Peak-shaving


Peak-shaving je často využívaná technika, kterou spotřebitel využívá k rychlému a krátkodobému snížení spotřeby energie, aby se vyhnul prudkému nárůstu spotřeby. Existují tři způsoby, jak toho lze dosáhnout. Prvním způsobem je dočasné omezení výroby energie, což znamená, že spotřebitel sníží produkci nebo využívá některé energeticky náročné procesy jen po dobu špičkového odběru. Druhým způsobem je aktivace systému výroby energie na místě, což znamená, že spotřebitel využívá vlastní zdroje energie, jako je například kogenerační jednotka, během špičkových období. Třetím a pro tuto kapitolu tím hlavním způsobem je akumulace energie, kdy spotřebitel ukládá energii do baterií nebo jiných úložišť energie a poté ji využívá během špičkové poptávky. Tímto způsobem se spotřebitel může vyhnout významným nárůstům spotřeby energie a lépe řídit svou spotřebu. (14,15)



Obrázek 9: Vyzualizace peak-shaving. převzato z (14)

1.6.2 Load-shifting

V energetickém systému existují dva režimy bateriového úložiště (BESS). Při nízké zátěži BESS funguje jako odběr, který absorbuje přebytečnou energii v systému a nabíjí se. Tímto způsobem BESS akumuluje energii pro pozdější využití. Naopak při špičkové zátěži BESS přepíná do režimu vybíjení a slouží jako generátor, který dodává energii a kompenzuje nedostatek v systému. Díky těmto režimům je BESS schopno přesouvat energii mezi obdobími s nízkou a vysokou poptávkou. Paralelně s tím existuje metoda load-shiftingu, která se zaměřuje na krátkodobé snížení spotřeby elektrické energie. Tato metoda přesouvá množství energie do doby s nižší poptávkou nebo využívá přebytky energie v systému. Cílem je optimalizovat spotřebu a efektivně využívat dostupnou energii. Kombinací těchto technik lze dosáhnout lepšího řízení a využití energie v energetickém systému. (14,16)



Obrázek 10: Vyzualizace load-shifting. převzato z (14)

1.7 Definice Chyb

Pro tuto práci definuji dva druhy vyhodnocení chyb, Absolutní a relativní. Obvykle jde o vyhodnocení chyby měření, ale pro tuto práci se bude jednat o chybu predikce.

1.7.1 Absolutní chyba

Absolutní chyba může nabývat pouze kladné hodnoty. Je vyjádřena ve stejných jednotkách jako hodnota původní. Udáváme jako rozdíl naměřené hodnoty od skutečné. Pro lepší práci při vyhodnocení jí pak dále definuji jako absolutní hodnotu tohoto rozdílu. (7,20)

$$\Delta X = |X - X'| \quad (3)$$

1.7.2 Relativní chyba

Relativní chyba se pak udává, jako absolutní chyba poměrem vztažená k velikosti skutečné hodnoty. To znamená, že tato chyba je bezrozměrná nebo se případně dá násobit 100 pro procentuální vyjádření. Opět jsem pak využil absolutní hodnoty pro jednodušší práci s výsledky. (7,20)

$$\delta X = \frac{|\Delta X|}{X} \quad (4)$$


2 Praktická část

2.1 Predikce spotřeby

V této kapitole se zabývám možností predikce spotřeby objektu pomocí neuronové sítě v programu MATLAB a zvláště jeho funkce nftool.

2.1.1 Popis objektu

Objekt - nemocnice, jejíž data využívám pro predikci spotřeby se nachází v Čechách, avšak pro zachování anonymity nebudu zmiňovat přesnou lokaci. Dostupná jsem měl naměřená data po 15 minutách za rok 2021 a 2022. Na začátku měření docházelo k chybám a častým výpadkům a proto jsem použil jen data od března 2021 do konce roku 2022. Vzhledem k problému, který se touto prací snažím řešit, jsou 15 minutové intervaly měření výkonu dostatečné. Zajímavá by jistě byla i analýza na datech minutových, k těm jsem však neměl přístup v potřebném množství. Na základě mé první analýzy zmíněných dat jsem předpokládal, že zde nevyužívají žádný typ elektrického vytápění, což je patrné z obr.11. Graf vykresluje data z měsíce dubna roku 2021.



Obrázek 11: Ukázka nezávislosti spotřeby na teplotě (data duben 2021)

2.1.2 Neuronová síť spotřeby

Na základě předchozí podkapitoly 3.1.1 jsem rozdělil dostupná data na data pro učení neuronové sítě a data pro analýzu, kde data pro učení jsou jeden kalendářní rok od března roku 2021 do konce února roku 2022. Data pro analýzu jsou za zbylé měsíce roku 2022. Hlavní otázkou u všech neuronových sítí, tuto nevyjímaje, je, jaké vstupní parametry využijeme, abychom u predikce pomocí NN dosáhli co nejvyšší přesnosti. Vzhledem k tomu, že spotřeba tohoto objektu není závislá na teplotě ani jiném parametru počasí, nezahrnul jsem je ani do vstupních parametrů. Z mého pozorování naměřených dat spotřeby vyplynulo, že hlavním parametrem, na kterém závisí spotřeba, je měřítko času. Já jsem pro svou aplikaci zvolil měřítko času dnů v týdnu, tedy čísla od 1 do 7 pro jednotlivé dny a číselnou řadu hodin a minut například ve formátu 1215, 1230, 1245, 1300 pro definování hodin a jednotlivých čtvrt hodin ve dni. Pro vysvětlení hodnota 1235 odkazuje na čas 12:45, 1300 znamená 13:00 v daný den. Dalším prvkem vstupních parametrů byl údaj, který udává, zda se daný den jedná o svátek či nikoliv. To jsem definoval jednoduchým dvoustavovým řádkem prvků. Pokud řádek na dané pozici obsahoval 0 nejednalo se o svátek a naopak 1 byla použita jednalo se o svátek. Jak je opět patrné na obr. 11. druhý a pátý den měsíce je výrazně nižší spotřeba než v jiné pracovní dny měsíce. Nejedná se o náhodu, ale tyto dny právě vycházejí na statní svátek (jednalo se o velikonoční svátky). Pro lepší orientaci v grafu také upozorňuji, že první den v měsíci byl čtvrtek. Pro lepší pochopení je nutné dodat, že počet dat pro učení jednoho roku je 4 krát 35040, to znamená počet vstupních dat krát počet čtvrt hodin v roce.

t (Dny v Týdnu)	5	5	6	6	6	6	6	6	6	6
t (čtvrt hodiny)	2330	2345	0000	0015	0045	0100	0100	0115	0130	
Svátky	1	1	0	0	0	0	0	0	0	0
Spotřeba (kW)	699	727	733	712	696	698	690	685	664	647
641										

Tabulka 1: Tabulka ukazující vstupní data do NN pro predikci spotřeby

2.1.3 Výsledky predikce spotřeby

V této podkapitole se pokusím ukázat výsledky predikce na různých neuronových sítích pro nalezení optimálního řešení pro danou problematiku predikce spotřeby. Budeme aplikovat dva druhy neuronových sítí. První z nich využívá LV a druhá BR. Zároveň budeme používat různý počet skrytých neuronů. Budu zde porovnávat výsledky ze čtyř neuronových sítí hlavním důvodem je určení ideálního přístupu a zároveň ověření chování principu overfitting.

1. Neuronovou síť jsem tedy vytvořil pro šest skrytých neuronů, při stanovení této hodnoty vycházím z výsledků práce (7), kde se doporučuje počet skrytých neuronů rovný maximálně dvojnásobku vstupních hodnot. Zároveň využívám principu LV.

2. NN využívá stejného množství skrytých neuronů, ale principu RB.
3. NN bude tvořena neobvykle velkým počtem skrytých neuronů zvolil jsem tedy 150 s principem LV.
4. NN využívá opět stejné množství jako ve třetí variantě, ale tentokrát s RB.

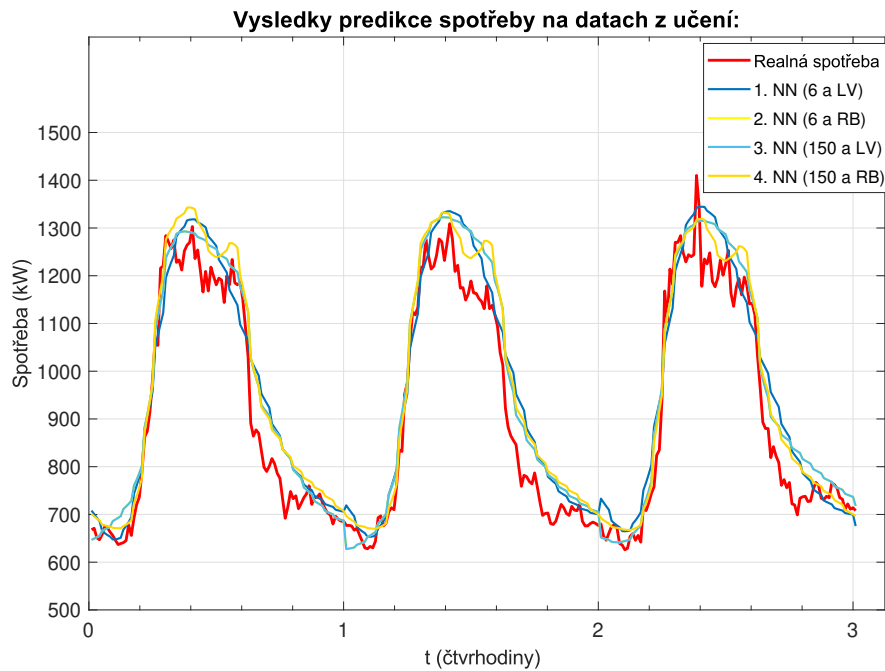
2.1.3.1 Predikce na datech z učení

Pro tuto část využiji data, která jsem zároveň použil pro učení neuronové sítě. Využiji půl roku tedy 17520 vzorků čtvrt hodin od 1.3. 2021 do 30.8. 2021 použil bych do 12:45. Ideální by samozřejmě bylo vyhodnotit data za celý rok. Tato varianta nebyla možná z důvodu omezeného množství změřených dat končících rokem 2022. V tomto případě by nebylo možné adekvátně porovnat výsledky dat z učení a dat tzv. neznámých.

Pro vyhodnocení výsledků měření využiji tři zásadní parametry. Prvním parametrem je průměrná absolutní chyba (AAE) viz. rovnice (3), jedná se o průměr. Jako druhý parametr je v dané problematice nejvýznamnější průměrná relativní chyba (ARE) (4), ale opět vyjádřená v průměru a maximální relativní chyba (MRE). Dalším porovnávacím parametrem je doba učení neuronové sítě (porovnávám jen tento čas, protože doba výpočtu je pro všechny totožná.

1. NN dosáhla výsledku: $AAE = 70,45 \text{ kW}$, $ARE = 7,717 \%$ a $MRE = 42,07 \%$ $t = 1\text{s}$
2. NN dosáhla výsledku: $AAE = 67,859 \text{ kW}$, $ARE = 7,469 \%$ a $MRE = 38,359 \%$ $t = 6\text{s}$
3. NN dosáhla výsledku: $AAE = 67,858 \text{ kW}$, $ARE = 7,469 \%$ a $MRE = 38,359 \%$ $t = 10\text{s}$
4. NN dosáhla výsledku: $AAE = 62,634 \text{ kW}$, $ARE = 6,79 \%$ a $MRE = 34,85 \%$ $t = 8 \text{ min } 51 \text{ s}$

Graf výsledků predikce jednotlivých typů NN (obrázek 12) nám ukazuje, že i přesto, že se výsledky mírně liší v jednotlivých porovnávacích parametrech chyb (AAE,ARE,MRE), všechny NN poměrně slušně sledují trend reálných hodnot. Graf vykresluje tři dny od 19. do 22. dubna 2021. Data jsem zvolil čistě náhodně a podobné výsledky by byly patrné i v jiných dnech.




Obrázek 12: Výsledky jednotlivých typů NN na tréninkových datech (data 19.-21. duben 2021)

2.1.3.2 Predikce na nových datech

Pro tuto část využiji data nová, která jsem ještě nepoužil. Využiji polovinu roku tedy 17520 vzorků čtvrt hodin od 1.3. 2022 do 30.8 2022 12:45. Ideální by samozřejmě bylo vyhodnotit data za celý rok to však jak jsem již zmiňoval to není možné. Využijeme zde úplně stejné neuronové sítě, které již máme naučené z předchozí podkapitoly. Za poznámku také stojí, že průměrný čtvrt hodinový výkon v roce 2022 byl o 21,604 kW nižší než v roce 2021.

1. NN dosáhla výsledku: AAE = 76,63 kW, 19,93 ARE = 9,06 % a MRE = 45,33 % t = 1s
2. NN dosáhla výsledku: AAE = 75,49 kW, ARE = 8,94 % a MRE = 43,44 % t = 6s
3. NN dosáhla výsledku: AAE = 73,41 kW, ARE = 8,63 % a MRE = 43,36 % t = 10s
4. NN dosáhla výsledku: AAE = 73,30 kW, ARE = 8,62 % a MRE = 45,22 % t = 8 min 51 s

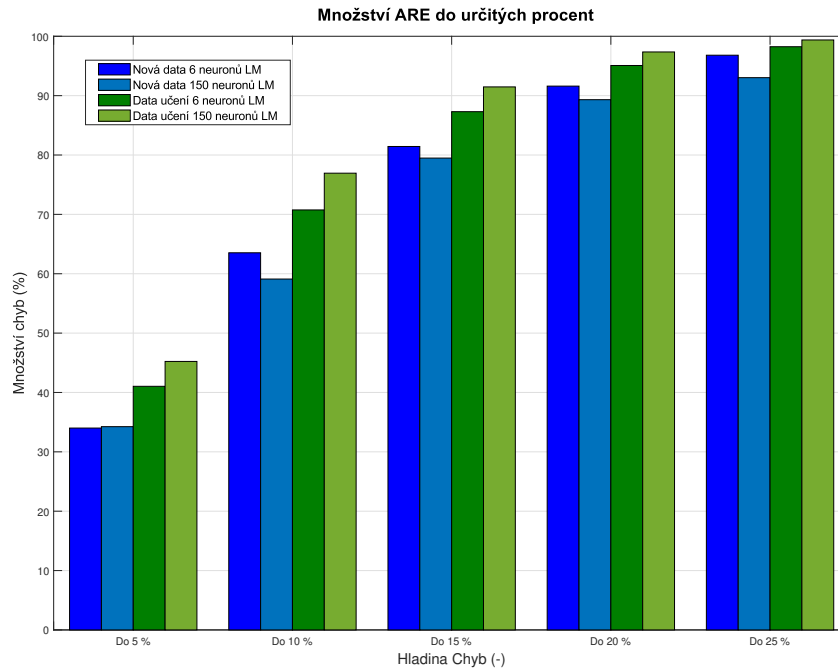
Z obrázku 13. je patrné, že při predikování pomocí NN při využití dat nových neznámých je chyba predikce vyšší, protože to daný trend sleduje. Spotřeba nemá špičky, což predikce nechytíla.



Obrázek 13: Výsledky jednotlivých typů NN na datech u učení (data 20.-22. duben 2022)

2.1.3.3 Zhodnocení overfittingu a vhodné zvolení NN

Z předchozích dvou podkapitol se bohužel úplně nepotvrdil problém overfittingu, kdy se očekávalo, že NN se 150 skrytými neurony budou mít vysokou přesnost a tedy nízkou chybovost na datech z učení. Tento předpoklad se nepotvrdil. Dalším očekáváním u těchto sítí bylo, že dojde k výrazně vyšší chybovosti na datech nových neboli pro NN neznámých. Tento předpoklad také naplněn nebyl. Sice došlo k poklesu přesnosti, ale se stejným trendem jako u sítí se šesti skrytými neurony. Tento jev je viditelný na obrázku 14. Hlavním parametrem při vybírání počtu skrytých neuronů je pro tuto práci tedy přesnost za čas a v tomto ohledu vychází nejlépe síť se šesti skrytými neurony využívající LM. Případně i 150 neuronů a násobný čas může být pro některé aplikace limitující. Pro mou aplikaci to znamenalo 10 krát tolik času za cenu 0,248 % přesnosti. Také je nutné si uvědomit, že tato predikce je poměrně jednoduchá a k tomu se periodicky opakuje, což může nahrávat tomu, že se neprokáže vliv "neznámých" dat tj. overfitting se neprojeví.




Obrázek 14: Vyhodnocení chybovosti jednotlivých sítí pro jednotlivá data

2.1.4 Postupná predikce spotřeby

V této kapitole budeme aplikovat postupné učení sítě. To znamená, že provedeme síť po každé čtvrt hodině. Očekáváním tohoto postupu bylo, že by se měla výrazně zvednout přesnost predikce. Pro tento problém jsem zvolil síť na základě předchozí podkapitoly tedy LM a šest skrytých neuronů. Výpočet této sítě měl podle odhadů vyjít podle vzorce počet hodnot predikce krát čas jednoho vypočtení sítě. To znamená minimálně $17520 \times 1s$, což odpovídá 292 minutám. Reálný čas je však výrazně vyšší, protože to zároveň musíme uvažovat i mezi výpočty. Reálný čas byl přes 6 hodin. Zároveň je nutné upozornit, že čas by byl v praxi mnohem větší, protože jsem měl již všechny hodnoty načteny v mezipaměti.

Z obrázku 15 je patrné, že postupná predikce, tedy postupné zpřesňování pomocí přetrénování po každém kroku, o něco lépe sleduje výsledek, avšak stále nerespektuje nižší výkon. Jedná se o období od 20. do 22. dubna 2022.

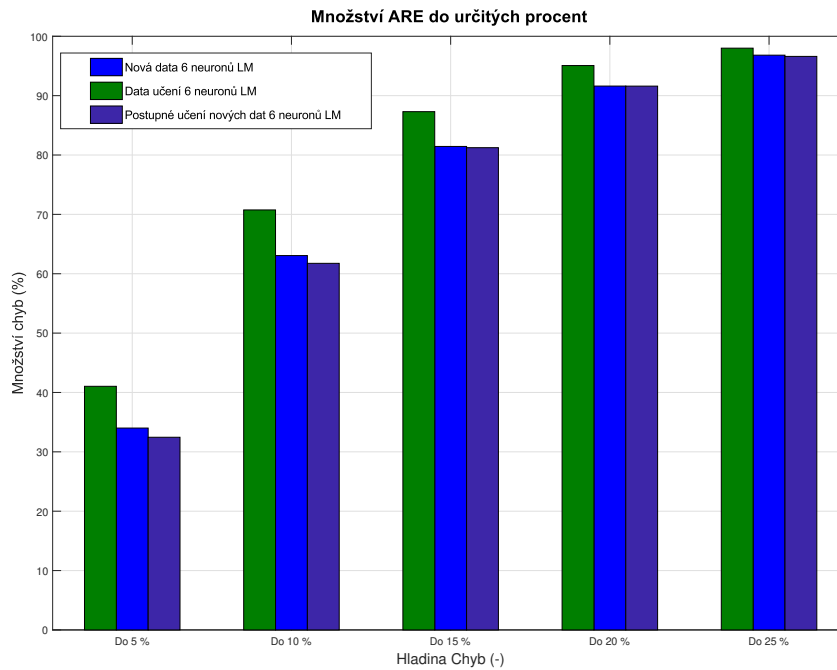


Obrázek 15: Ukázka výsledků jednotlivých sítí pro jednotlivá data za období 20.- 22. dubna 2023

2.1.5 Vyhodnocení predikce spotřeby

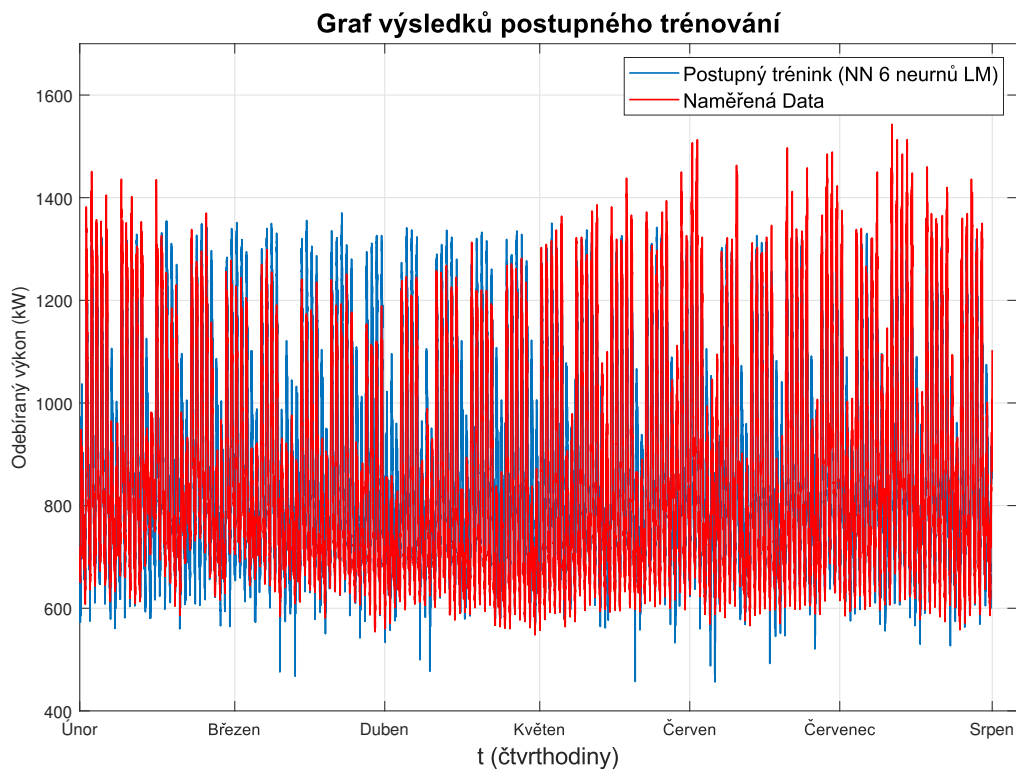
Na nových datech pro predikci celého půlroku se výsledky zadávají poměrně špatné. Obecně je vidět, že data v roce 2022 jsou nižší a síť na to není připravená. Pravděpodobně se jedná o nějakou změnu podmínek, jako například odstavení části nemocnice z ekonomických důvodů nebo výrazně nižšího využití nemocnice. Na tento krok by pak měla reagovat postupná predikce spotřeby.

Z grafu na obrázku 16. je vidět porovnání chyb obou přístupů. Je patrné, že výsledky nejsou výrazně lepší. To potvrzuje i $ARE = 9,276 \%$, $MRE 65,782 \%$ a průměrný rozdíl AAE je $78,868$ kW. Tyto výsledky jsou dokonce horší než výsledky, kdy jsme nepřepočítávali a použili jen naučená data. To rozhodně neodpovídá mým předpokladům, protože množství bodů k učení se zvětšovalo a s tím bych očekával přesnější predikci.



Obrázek 16: Vyhodnocení chybovosti přístupu bez přepočítávání neuronové sítě a s přístupem postupného trénování

Obrázek 17. pak ukazuje vykreslený celý půlrok. Není snadné na něm ukázat výsledky, je zde jen pro představu.



Obrázek 17: Graf výsledků postupného trénování pro celý půlrok


2.2 Predikce výroby fotovoltaické elektrárny (FV)

Fotovoltaické panely jsou v dnešní době (při zvyšující se ceně silové elektřiny) ve velké oblibě. Obecně čím dál tím víc vlastníků objektů přemýšlí nad jejich realizací na vlastní střechy a plochy. Predikce výroby FV je však velice záluďná. Obecně jde hlavně o kvalitu vstupních dat. Hlavním parametrem pro predikci FV je určité co nejpřesnější osvit. Není to však jediný parametr ovlivňující celkový výkon. Dalším důležitým parametrem poměrně výrazně ovlivňujícím výkon je teplota prostředí, která má přímý vliv na chlazení samotného panelu a tedy samotnou teplotu panelu. Teplota panelu pak přímo ovlivňuje výkon FV. Pokud bychom chtěli predikovat FV přesně, museli bychom mít přesné předpovědi počasí. To ovšem není reálné. Proto je nutné předpokládat, že při predikci FV se projevuje nejen nepřesnost NN, ale také přesnost předpovědi počasí. Obecně také není dobré podceňovat časové měřítko pro realizaci takové predikce.

2.2.1 Popis objektu FV

Naměřená data, která jsem měl k dispozici, byla měřena nedaleko Plzně. Opět nejsem oprávněn sdělit bližší informace. Data byla podobně jako u predikce spotřeby měřena za roky 2021 a 2022 po čtvrt hodinách. Bohužel se nám nepodařilo získat historická data předpovědi počasí, což má neblahý vliv na predikci FV. Úspěšní jsme byli při získání naměřených dat počasí z 5 km vzdálené stanice. Jednalo se o naměřená data teploty a globálního záření, obě hodnoty měřeny v desetiminutových intervalech. Problémem těchto dat není ani tak to, že jsou po 10 minutách, i když i to jistě má vliv na celkovou přesnost, ale hlavně to, že se nejednalo přímo o osvit. Bohužel se nám i přes veškerou snahu nepodařilo získat relevantnější data. Pro práci budeme obdobně jako u spotřeby používat data od března roku 2021 do února 2022 pro učení. Pro analýzu si vyčleníme data od března 2022 do 30.8.2022 tedy přesně půl roku (17520 hodnot). Hlavním důvodem toho rozřazení je využití dat ve společné části a tady je potřeba aplikovat data za stejné období. Při prvním pohledu na naměřená data se však ukázalo, že měření vykazovalo chyby v některých časech viz. obrázek XX. Je zde patrné, že měření zcela vypadlo či došlo k výraznému zkreslení dat. Proto tato data vyřadíme pro učení neuronové sítě. Pokud bychom tato data nevyřadili, výrazně by to ovlivnilo přesnost sítě. Také stojí za zmínku, že data počasí, která nám byla poskytnuta, bylo nutno vhodně rozdělit do čtvrt hodin. V tomto případě jsem postupoval tak, že jsem data poměrově rozdělil podle vzorce (5), kde X je dopočtená čtvrt hodina a Y jsou desetiminutová data.

$$X_{licha} = \frac{2Y_1 + Y_2}{3} \dots a \dots X_{suda} = \frac{Y_2 + 2Y_3}{3} \quad (5)$$



Obrázek 18: Ukázka z naměřených dat za rok 2021 s hlavním důrazem na ukázkou chyb měření

2.2.2 Neuronová Síť výroby FV

Jak již bylo zmíněno v předchozích podkapitolách, hlavními prvky vstupní matice budou (viz tabulka 2.):

- Měřená teplota
- Globální záření
- Časové vektory dat, které jsou rozděleny ve tvaru měsíc, den, hodina, čtvrthodina

Z toho vyplývá, že celková matice má 6 vstupních parametrů. Nejsou však po 35040 hodnotách, ale jsou zkrácena o chybná data. Jedná se tedy o matici 6x 31306 hodnot. Na základě výsledků z predikce spotřeby zde využijeme závěry této kapitoly a rozhodl jsme se využít jen jeden typ NN a to s 12 skrytými neurony (tedy dvojnásobek vstupních vektorů v matici) a využívající LM.


t (měsíce)	1	1	1	1	1	1	1	1	1
t (Dny v měsíci)	11	11	11	11	11	11	11	11	11
t (hodiny)	15	15	15	15	16	16	16	16	17
t (čtvrthodiny)	0	15	30	45	0	15	30	45	0
globální světelný výkon (kW)	12,73	6,53	2,43	0,7	0	0	0	0	0
Teplota (°C)	1,3	1,5	1,2	1,1	1,2	0,5	0,2	-0,7	-2
Výkon FV (-)	0,321	0,244	0,116	0	0	0	0	0	0

Tabulka 2: Tabulka ukazující vstupní data do NN pro predikci výroby FV

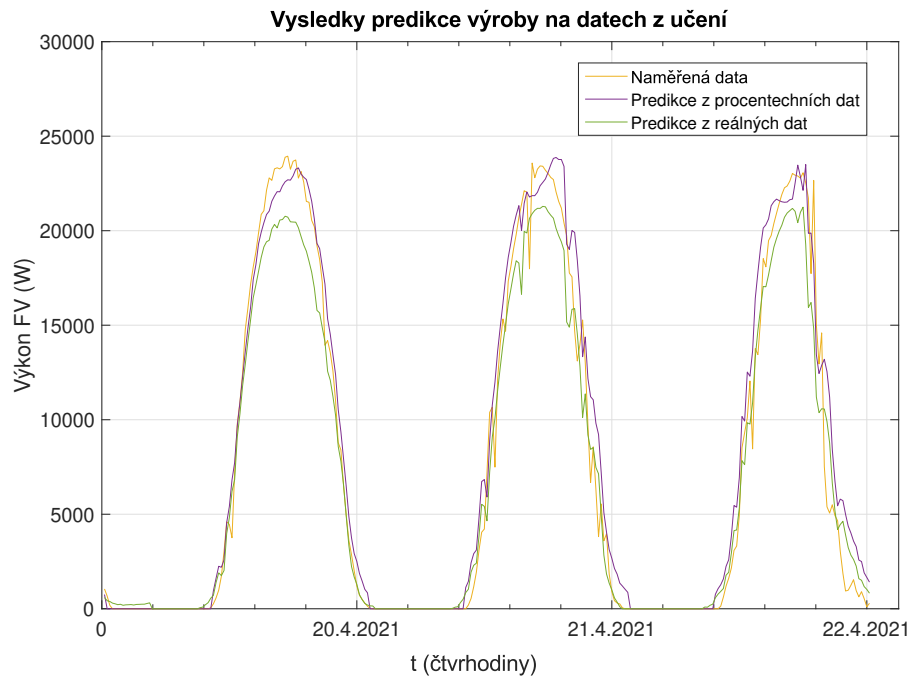
2.2.3 Výsledky predikce výroby FV

Jak jsem popsal v předchozí část, využil jsem jen jednu NN pro analýzu, ale rozhodl jsem se porovnat dva přístupy. Jako první to byl rozdíl mezi učením na skutečnou hodnotu výkonu FV a druhý přístup poměrný výkon vztažený k výkonu jmenovitému. Nazval jsem ho procentní metodou. Setkal jsem se s tímto poměrným přístupem během analýzy článků zabývajících se právě predikcí FV a zajímal mě jeho dopad na výsledek.

Jak je patrné z obrázku 19. FV má poměrně vysokou nepřesnost a to i na učicích datech. S největší pravděpodobností je to způsobeno nepřesnými daty vstupů, tedy hlavně tím, že nemáme osvit a data osvitu a ani data nejsou z přesného místa. Dále je také nutné podotknout, že bereme v potaz jen nenulová data. Zároveň neuronová síť predikuje v místech, kde mají být evidentně nulové hodnoty hodnoty záporné. To jsem však ošetřil jednoduchou if funkcí. Je patrné, že procentuální přístup má mírně lepší výsledky. To může být automatickým zaokrouhlením dat vždy jen na určitý počet hodnot za desetinou čárkou, tedy zaokrouhlením a zjednodušením těchto dat. Je důležité se podívat na obrázku 20. Zde je vidět, že výsledky nejsou tak špatné, jak se na první pohled zdálo. Myslím, že hlavním důvodem je způsob vyhodnocení v oblasti nástupu výroby, kdy je například predikovaná hodnota stále nulová, ale reálná hodnota již nabyla hodnoty, i když minimální. Proto tedy výsledek $ARE = 199,14 \%$ není relevantní jako u spotřeby. Na základě tohoto zjištění jsem zkoušel vypočítat jen přesnost během náhodně zvoleného dne a jen v místě, kdy nedochází k blízkosti s nulou ani u predikce, ani měřených dat. V této oblasti bylo $ARE = 9,15 \%$ (jednalo se o den v půlce května). Zároveň graf mírně naznačuje, že pro tyto konkrétní body se lépe chová predikce v procentech, což jen jen potvrzuje výsledky z grafu na obrázku 19. Zároveň to potvrzuje i výsledek ARE, který byl o 109 procent horší než u procentuálního přístupu.



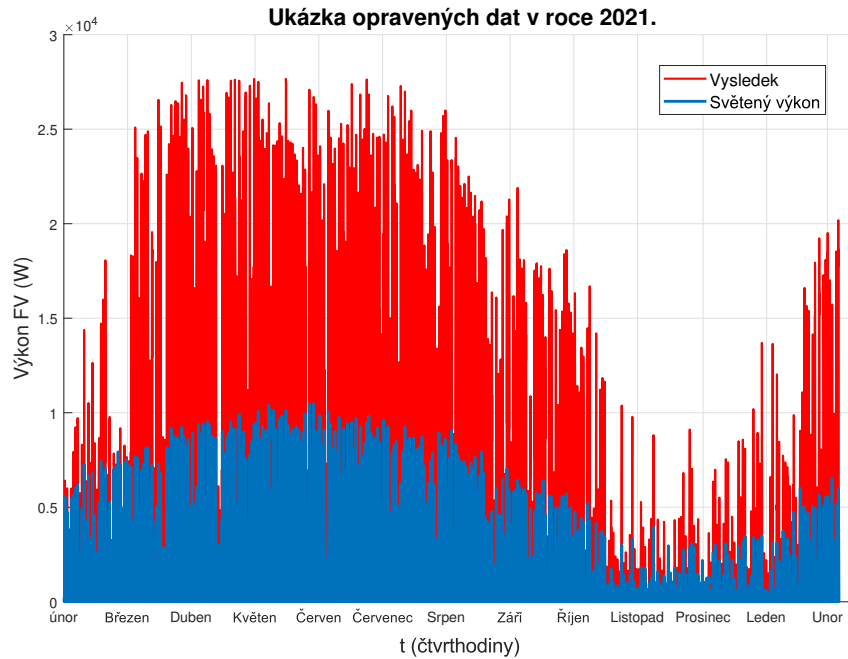
Obrázek 19: Ukázka z výsledků predikce za 20. až 22. dubna roku 2021



Obrázek 20: Ukázka z naměřených dat za rok 2021 s důrazem na ukázkou chyb měření.

2.2.4 Dopočet Chybných dat FV

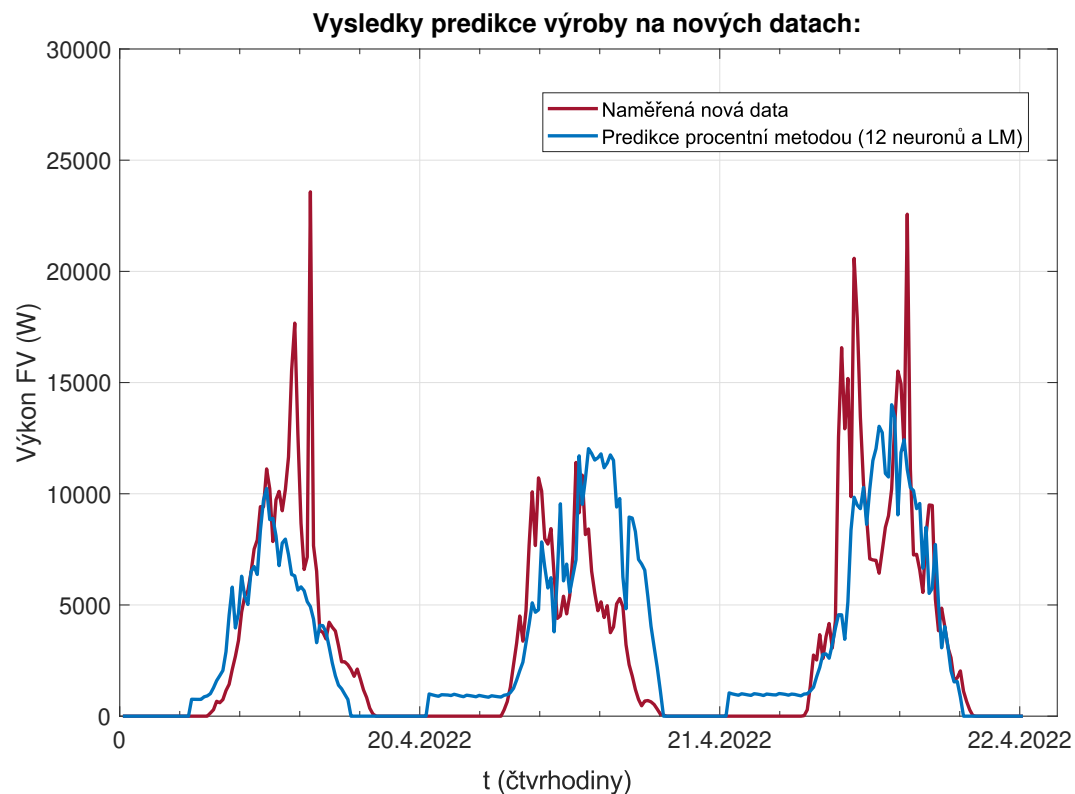
V této podkapitole bych rád ukázal zajímavou možnost využití neuronové sítě. Předpokládejme, že potřebujeme daná data pro nějakou analýzu, případně nějaký dopočet. Celý rok jsme měřili data pro následné vyhodnocení, například zda celkový dodaný výkon opravdu odpovídá tomu, co ukazují hodiny (jedná se jen o příklad, ale skutečných důvodů může být libovolný počet). Při zjištění, že část dat je naprosto chybná, nemůže dojít k výpočtu. Pokud však využijeme neuronovou síť, dají se daná data dopočítat s určitou přesností. Přesně to jsem se rozhodl udělat se svými daty i já, viz obrázek 21. Je patrné, že data nyní sedí daleko více a splňují očekávání.



Obrázek 21: Ukázka dopočtených dat chybějících v měření.

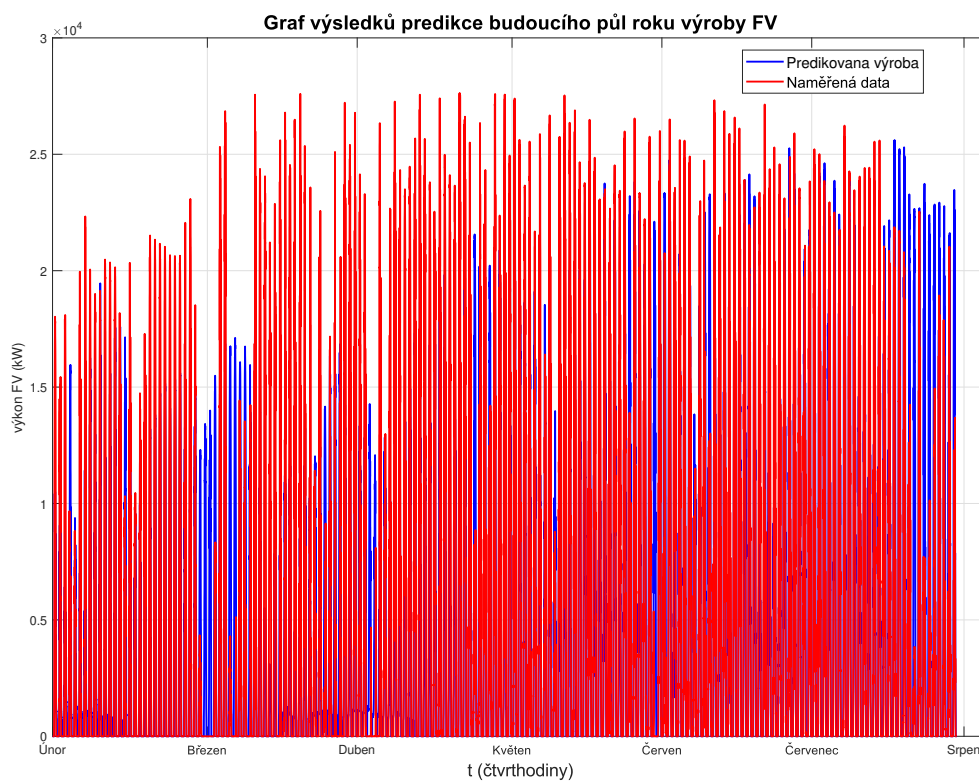
2.2.5 Zhodnocení predikce výroby FV

Z výsledků, které prezentuji v předchozích kapitolách dá vyvodit, že predikce není příliš přesná, a největší problém vzniká v oblasti blízké 0. Tam dochází k velkým relativním odchylkám. Při zanedbání všech hodnot pod 1 kW zjistíme, že ARE je již 40,46 %, což stále není dobré, ale určitě už se s takovým výsledkem dá pracovat. Ke zvýšení přesnosti by jistě pomohla lepší vstupní data a to hlavně data týkající se osvitů přesně v daném místě.



Obrázek 22: Porovnání predikce na "neznámých" datech od 20. do 22. dubna 2022.

Obrázek 23. je výsledek predikce celého budoucího půlroku. Pro celý tento půlrok vychází data velice špatně, evidentně se chyba ještě zvětšila. Však pozitivním zůstává, že to alespoň z části kopíruje trend reálných dat.



Obrázek 23: Celý půlrok roku 2022 od března do srpna predikovaných dopředu.

2.3 Využití NN pro regulaci

2.3.1 Záměr

Důvodů pro využití neuronové sítě pro predikci je více. Hlavním je ověření schopnosti NN regulovat s rozumnou přesností a hlavně za krátký čas. I když námi zvolený příklad regulace zvládne bez problému relativně jednoduchá funkce for a v ní vnořená vícestupňová funkce if, tak existují typy regulace, které jsou podstatně složitější a někdy využívající až PID regulátory v závislosti na funkci. Tomu většinou odpovídá i čas jejich výpočtu. Jedná se o zajímavou problematiku, které se zde ovšem jen dotknu. Zajímat nás tedy pro náš příklad bude regulace výkonů pro nepřesážení čtvrt hodinového maxima s využitím baterie.

2.3.2 Popis objektu FV

V této části budeme využívat výsledky i vstupy z předchozích dvou kapitol praktické části, tedy spotřebu objektu a výrobu FV. Sestavíme si zde čtyři postupy výpočtu, které mezi sebou budeme navzájem porovnávat (KGJ nevyužijeme z důvodů neschopnosti ji predikovat). Uvažujeme tedy, že se jedná o jeden energetický objekt využívající baterii pro regulaci čtvrt hodinových výkonu a tím nepřesáhnutí čtvrt hodinového maxima. Výrazně však zanedbáváme přesné chování baterie. Zajímá nás jen dobíjený a vybíjený výkon (tedy aktuální stavy kapacity baterie). Je nutno zmínit, že hodnoty výkonů z FV budeme násobit 10, tedy maximální výkon je 280 kW, abychom zvýšili její vliv na systém. Ten však nikdy nedojde do stavu, kdy by výroba byla větší než spotřeba. Zmiňované čtyři postupy k porovnání:

1. Změřená data a rozhodovací funkce if
2. Predikovaná data rozhodovací funkce if
3. Změřená data a rozhodovací neuronová síť (naučená z výsledků fce if)
4. Predikovaná data a rozhodovací neuronová síť (naučená z výsledků fce if)

2.3.3 Neuronová Síť pro regulaci

Tato neuronová síť bude tak trochu speciální. Využívá totiž pro vstupní data jen dva řádky vstupní matice. První nám udává výkonovou bilanci, tedy rozdíl mezi výrobou FV a spotřebou z předchozích kapitol. Druhý řádek je pak směrnice z aktuálního početního bodu do bodu +6 tedy o hodinu a půl později. Pro tento krok jsem využil metodu nejmenší čtverců, abych definoval přímku, z níž pak využiji jen směrnici. Hlavním důvodem je, že v předchozích kapitolách se ukázalo, že není problém predikovat nějaký čas dopředu se slušnou přesností bez přeučení sítě. A směrnice mám dokáže v kombinaci s výpočtem středního výkonu určit budoucí špičku. Neobvykle

tedy bude více výstupních hodnot a to čtyři. První z nich je třístavová veličina určující, zda se blíží špička bilance výkonů. Stavů jsou "1" pro stav před špičkou, "0" po špičce a "-1" pro "mimo špičkové pásmo tedy pod střední hodnotou výkonu a špička se neblíží. Druhým parametrem je spínání baterie. Opět máme třístavovou veličinu, kde "1" znamená, že baterie je využita jako stav, kdy baterie dodává výkon. "-1" označuje dobíjení baterie a "0" je standby. Třetí parametr pak udává aktuální nabití baterie v %. Poslední výstupní parametr je signalizace krize, který je binární. Nabývá hodnot "0" pro označení, že není problém a označení "1" signalizuje pozor nedostatek výkonu pro pokrytí špičky. Dál bych rád vysvětlil, že neuronová síť nedává výsledky rovnou ve stavech, ale má tendence se k dané hodnotě výrazně blížit. Z toho důvodu je nutné výsledky mírně zaokrouhlit, aby výsledek byl jasný.

2.3.4 Rozhodovací funkce If

Tato funkce vznikla pro naučení a porovnání neuronové sítě. Nejedná se o složitou funkci, je tvořena dvěma if funkcemi a její přesný zápis následuje na obrázku 25. Kde "rovnice 1" je již zmíněná směrnice pro následujících 6, "Celkem" označuje bilance výkonů, "P stred" je vypočtený střední výkon tedy 861 kW, "Stav Bat" aktuální nabití baterie, "Spinani Bat" stav provozu baterie. "Signalizace krize" je dvoustavová signalizace krize. Považuji za nutné opět zmínit, že se určitě nejedná o reálně fungující systém. Tento návrh je výrazně zjednodušující a tedy v praxi by byl nedostatečný. Záměrem této práce ani není vytvořit samotné řízení baterie.

```

if rovnice_1(k) > 2 && Celkem(k+4) > P_stred
    Sit_stav = [Sit_stav, 1];
elseif Celkem(k) < P_stred && Celkem(k+4) < P_stred && rovnice_1(k) < 5
    Sit_stav = [Sit_stav, -1];
else
    Sit_stav = [Sit_stav, 0];
end

if Sit_stav(k) == 1 && Celkem(k) > 1150 && Stav_Bat(k) > 10
    Spinani_Bat = [Spinani_Bat, 1];
    Stav_Bat = [Stav_Bat, (Stav_Bat(k) - (Celkem(k) - 1150) / Celkova_kapacita * 100 / 4)];
    Signalizace_krize = [Signalizace_krize, 0];

elseif Sit_stav(k) == -1 && Celkem(k) < P_stred && Stav_Bat(k) < 85
    Spinani_Bat = [Spinani_Bat, -1];
    Stav_Bat = [Stav_Bat, (Stav_Bat(k) + (P_stred - Celkem(k)) / Celkova_kapacita * 100 / 4)];
    Signalizace_krize = [Signalizace_krize, 0];

elseif Stav_Bat(k) < 10 && Sit_stav(k) == 1
    Spinani_Bat = [Spinani_Bat, 0];
    Stav_Bat = [Stav_Bat, Stav_Bat(k)];
    Signalizace_krize = [Signalizace_krize, 1];


else
    Spinani_Bat = [Spinani_Bat, 0];
    Stav_Bat = [Stav_Bat, Stav_Bat(k-1)];
    Signalizace_krize = [Signalizace_krize, 0];
end

```

Obrázek 24: Rozhodovací funkce if.


2.3.5 Zhodnocení predikce regulace

Jak je patrné z obrázku 25. neuronová síť byla schopná se celkem slušně přiblížit výsledkům predikce stavu sítě a zachytit největší špičky. Docházelo sice k chybovosti, ale predikce byla poměrně přesná. Chyba byla v 17 % bodů, což není málo, ale stále je to využitelné. Z obrázku se zdá, že je neuronová síť opatrná a změny stavu predikuje se zpožděním. Je pravděpodobné, že před zaokrouhlením hodnot by bylo na hodnotách patrný drobný trend avšak nedostatečný pro detekci při rozhodování.



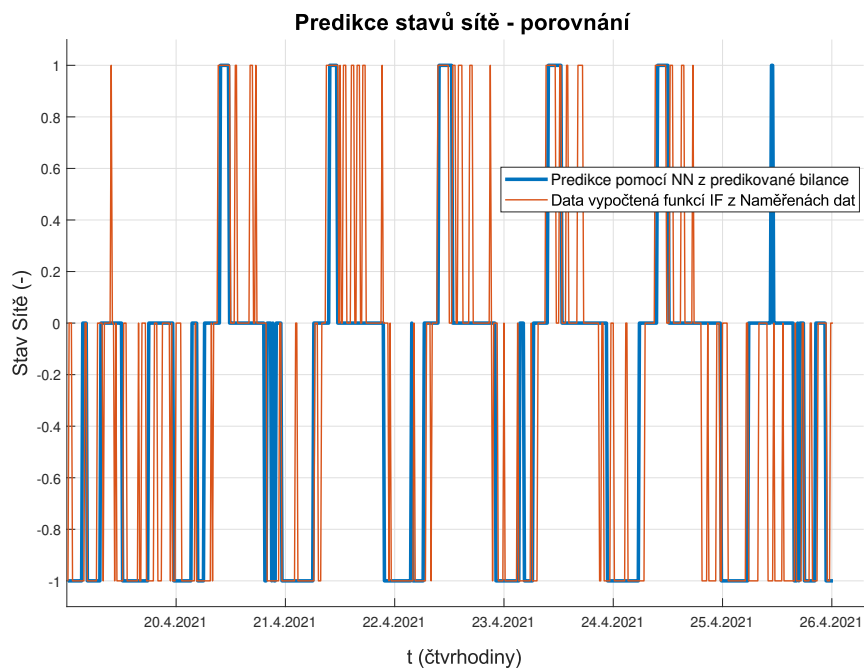
Obrázek 25: Predikce stavu sítě z predikované bilance.

Na obrázku 26. jsou znázorněny výsledky z měřené bilance a tedy porovnání mezi daty dopočtené přes if a opět predikcí neuronové sítě. Chyba je v tento moment ještě vyšší a to jak vypočtená 28,5%, tak vizuální. Mé očekávání bylo, že se výsledky nezmění vzhledem k tomu, že pro každý přístup jsem stanovil jinou neuronovou síť. Tento jev si sám nedokážu plně odůvodnit. Proč došlo k tak výraznému poklesu přesnosti? Jediný princip, který, by mohl mít tento vliv zvlnění bilance výkonů. Predikovaný průběh je poměrně vyhlazený v porovnání s reálnými daty. Pokud tedy na reálných datech počítáme směrnici následujících šest bodů, pak může vyjít blíže k rozhodovací hladině tedy budou nabývat v absolutní hodnotě nižších hodnot a tedy jejich predikce v těchto místech bude horší. Jedná se ale jen o možné vysvětlení.



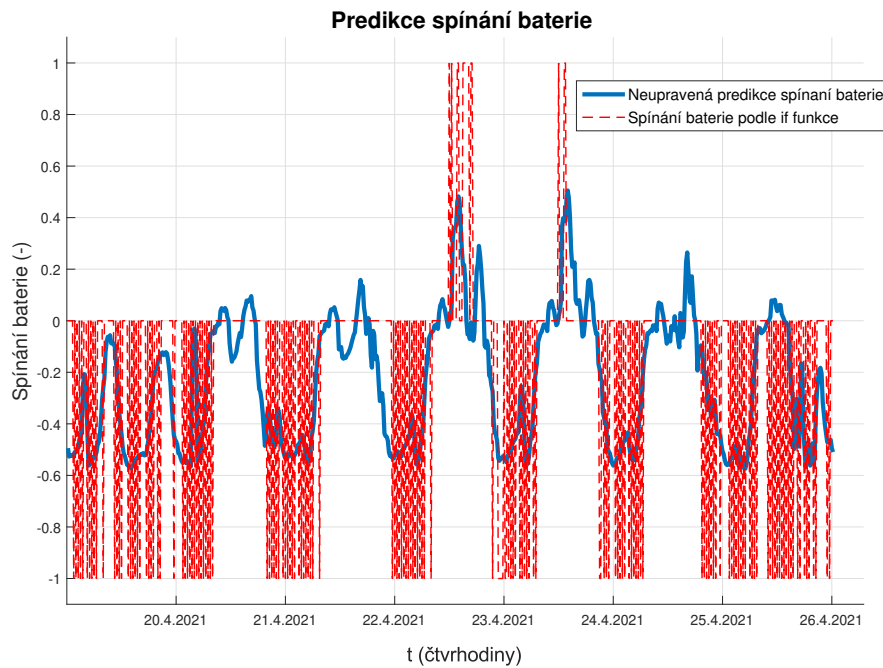
Obrázek 26: Predikce stavů sítě z reálné bilance.

Na dalším obrázku 27. se jedná o problematiku při nastavení if funkce pro reálná data, ale predikce na datech bilance predikovaných. Je zde patrné, že chyba je mnohem větší než v předchozích případech, tedy 61,85 % Tento jev bych nazval násobením chyb řazených neuronových sítí. Projevují se nám kombinace chyby neuronových sítí pro predikce spotřeby, výroby FV i predikci stavů.



Obrázek 27: Ukázka problému násobící chyby pro stav sítě.

Jedním z problémů, na který jsem narazil je, že neuronová síť celkem uspokojivě predikuje stavy sítě a tedy zvládla naučení první části funkce if viz obrázek 24., ale nezvládá už napočítat další části této funkce, tedy druhou podmínku if. Predikce spínání baterie, stavu baterie a signalizace krize nefungují dobře pro mnou zvolené parametry sítě. Z obrázku 28. je patrné, že to má mírnou tendenci rozpoznat daný bod sepnutí avšak nedostatečnou "silou". Na tento výsledek se těžko nastavují záchytné hodnoty a tvrdit zde, že všechno nad 0,4 je 1 a obdobně může větší pravděpodobnost chyby v daném bodě zkreslit víc než přesný výsledek.



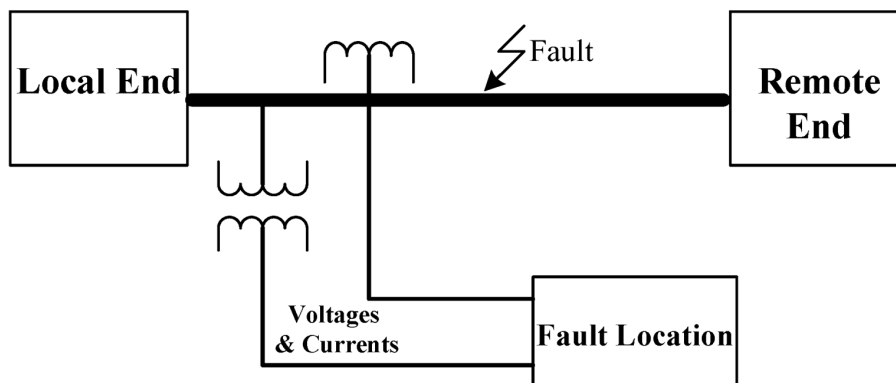
Obrázek 28: Ukázka problému se spínáním baterie

3 Zmapování využití NN v energetice

V této kapitole se pokusím ukázat 2 zajímavé práce na, které jsem narazil, které se zabývají predikcí v oblasti energetiky. Pokusím se zachytit hlavní myšlenku práce a navnadit čtenáře k jejich přečtení. Není mým záměrem takhle složitou problematiku vysvětlit.

3.1 Význam umělých neuronových sítí pro lokalizaci poruch přenosových soustav: Průzkum

Tento článek představuje průzkum výskytu poruch na vzduchových vedeních přenosových linek pomocí umělých NN. Poptávka po elektřině každým dnem roste a s ní souvisí i nárůst populace, což vyžaduje větší výrobu elektřiny, aby se uspokojila poptávka. V elektrických energetických systémech dochází k nejvyššímu počtu poruch právě ve vzduchových vedeních přenosových linek. Tento průzkum ukazuje důležitost umělých NN pro určování místa poruch, protože mají mnoho výhod ve srovnání s jinými softwarovými technikami, jako je například vlnková analýza, metoda podpůrných vektorů atd. (23)



Obrázek 29: (23)

3.2 Praktická metoda založená na strukturálních neuronových sítích pro optimalizaci provozu energetické soustavy

Tato práce navrhuje novou metodu optimalizace provozu přenosového systému elektrické energie založenou na strukturované neuronové síti. Díky tomu, že je strukturovaná neuronová síť předem připojena, je doba potřebná k vytvoření sítě velmi krátká. Byly provedeny simulace snižování pře-

nosových ztrát. Ukázalo se, že optimalizační výkon navrhované metody je v praxi uspokojivý. (24)

4 Závěr

4.1 Zhodnocení výsledků predikce spotřeby

Jak je patrné z výsledků na obrázku 14. a 16. do $ARE < 15\%$ vychází přes 80 % pracovních bodů. Nejedná se stále o ideální nastavení a v praxi bych navrhl hledání optimalizace, která docílí lepších výsledků. Zároveň je nutné si uvědomit, že predikují jen na základě historických dat a časového měřítka. Problém s přesností nastává hlavně pro moment, kdy se data snažíme využít pro regulaci čtvrt hodinového maxima, kde stále relativně velká chyba 10 %, kterou má mezi 30 až 40 % vzorků (v závislosti na typu dat a typu NN). To může způsobit rozdíl mezi překročením a nepřekročením i s rozumnou rezervou k tomuto limitu.

Této problematice by se podle mého názoru dalo vyhnout rozdělením predikce na dostatečné množství vzorku i s jejich měřeními (tedy měřit s daným časovým vzorkem aktuální spotřebu). I přes stejnou chybovost u těchto vzorků by podle mého názoru došlo k vyšší přesnosti pro daných patnáct minut, protože by se chyba jednotlivých vzorků v jedné patnáctiminutovce pokrátila směrem k průměrné odchylce. Bohužel jsem k daným datům neměl přístup a tedy tuto teorii jsem nemohl ověřit. Také si myslím, že pokud by spotřeba byla výrazně závislá na teplotě (což v mém případě tak nebylo, jak jsem se pokusil dokázat na obrázku 11.), mohli bychom díky tomu dosáhnout lepších výsledků. To je ale jen moje teorie a nemohu to opřít o žádné výsledky.

Díky jednoduchosti této problematiky můžeme docílit velice rychlých výpočtů po jednotlivých bodech i na průměrně výkonných zařízeních. V tomto případě po predikci jednoho bodu nastane přepočítání neuronové sítě i se znalostí bodu předchozího. Na mém zařízení tento výpočet probíhal řádově od 1 s do 5 s. Pokud budeme uvažovat i určitý čas na načtení vektorů dat do mezipaměti a nějakou úpravu dat, můžeme uvažovat čas s jistotou do 30 sekund. Tento čas má tedy velkou rezervu a je naprosto vhodný pro real-time predikci. Osobně bych ale přistoupil spíše k řešení, kdy bude přepočítání provedeno po určitém časovém úseku. Například každý den v noci a během dne budou probíhat jen výpočty predikovaných bodů.

4.2 Zhodnocení výsledků predikce výroby FV

Jak je patrné z obrázku 19., tak FV nedosahovala zdaleka tak dobrých výsledků bych doufal. Jak jsem již zmiňoval v části zabývající se výsledky FV, data jsou mírně ovlivněna blízkostí nuly a nejsou tak špatná, jak se může zdát. I přesto se nejedná o dobré výsledky a osobně bych tato data nedoporučil k využití pro regulaci čtvrt hodinových maxim přímo. Možností nepřímého využití by mohlo být například využití jen části predikovaného výkonu z predikce, tedy uvažování mnohem horšího stavu než predikují například jen 60 % z výkonu, a tím omezit velikost chyb. Tento přístup je dost neefektivní a jistě nastane spousta času, kdy zbytečně aktivujeme baterii i přesto, že nehrozí blízkost přesažení maxima. Dále je také nutné zmínit, že vstupní data, jenž

jsem využíval nebyla rozhodně ideální a to hlavně z těchto důvodů:

- **Časové měřítko** po 10 minutách není vhodné, protože při rozdělení dochází k nepřesnostem.
- **Typ dat**, kdy jsem neměl přístup k datům osvitů, což by jistě ovlivnilo výsledky.
- **Místo měření** počasí nebylo v místě FV, ale přibližně 5 km vzdálené. I takto malá vzdálenost hraje jistý nezanedbatelný vliv.

Za zajímavou část výsledků FV považuji rozdíl mezi predikcí s reálnými daty a jak jsem já nazval procentním či poměrným přístupem. I přestože výsledky nejsou strhující, došel jsem k vyšší přesnosti. Otázkou však zůstává, zda je to způsobeno lepší predikcí pro procentní hodnoty a nebo tím, že neuronová síť v programu matlab uvažuje vždy stejné množství hodnot za desetinou čárkou a tedy při využití procentního přístupu dojde k oříznutí těchto dat. Přestože na výsledcích predikce bych chtěl ještě zapracovat, tak její výpočet pro 12 skrytých neuronů a využití LM trval přibližně 4 až 12 sekund. Pokud opět uvažujeme načtení většího množství dat, můžeme s jistotou tvrdit, že predikce proběhne do 45 sekund, což je čas, při kterém lze real-time predikce na čtvrt hodiny provádět bez problémů. Vzhledem k výsledkům a úvahám v předchozí kapitole bych však opět zvolil raději vyšší vzorkování a přeučení neuronové sítě například jen jedno za 24 hodin v noci.

4.3 Zhodnocení využití NN pro regulaci

Pro tuto problematiku se obtížně hledají motivy realizace. Mým cílem v této práci nebylo nastavení ideálního funkčního systému, který by reprezentoval ideální regulaci baterie pro omezení čtvrt hodinového maxima. Funkce, kterou jsem vymyslel není příliš složitá, ale využívá postupného navazování prvků. S tímto řešením regulace jsem se při procházení zdrojů zabývajících se NN vůbec nesetkal. Byl to tedy hlavní důvod, proč jsem se odvážil to vyzkoušet. Bohužel jsem nedosáhl takového výsledku, který by odpovídal dobré regulaci pro tento problém, ale i přesto nepovažuji tento výsledek za neúspěch. Dokázal jsem, že je tento problém přes neuronovou síť alespoň částečně řešitelný viz obrázek 25., který ukazuje, že jsem NN dokázal naučit funkci IF. i přesto že jednoduchou a plodit rozumné výsledky. Dále obrázek 28., který naopak ukazuje snahu NN predikovat i stavy baterie. Zde ovšem se zdá, že pro dokončení této predikce nemá NN dostatek "síly" a predikuje hodnoty příliš blízké 0. Věřím, že při lépe zvolených vstupních i výstupních parametrech by toho někdo po mě mohl docílit i pro výrazně složitější problémy, kde by neuronová síť mohla ukázat svoji sílu v rychlosti. Dále si dovolím zmínit obrázek 27., který považuji za zajímavý, ukazuje totiž jasný předpoklad, že při navazování neuronových sítí dochází k šíření chyby. Což pode mě samozřejmě automaticky neznamená, že výsledek chyby za poslední neuronové sítě je násobkem chyb všech sítí předchozích. Mnou zvolený typ neuronové sítě měl poměrně krátký čas trénování tedy mezi 3 až 10 s. I s načtením dat se dá říci, že 30 sekund s jistotou. Pokud je tato síť navázána na síť předchozí, je nutné uvažovat i jejich časy tréninku s výpočtem. Dohromady tedy něco do 2 minut i s výraznou rezervou pro jistotu. Celý tento systém

by tedy byl funkční pro predikci 15 minut bez problémů. Pro výpočet po minutových datech by k přetrénování sítí muselo docházet jen v menším časovém měřítku. Výsledky však napovídají, že přetrénování po každém bodě nezvyšuje přesnost zásadním způsobem.

4.4 Souhrn závěru

Jak se zdá, neuronové sítě jsou v poslední době denní součástí člověka. Osobně věřím, že jejich vliv v energetice výrazně poroste a budou využity nejen jako predikce diagramů zatížení atd. Jejich nespornou výhodou je uvažování na objekt jako na blackbox a tedy zbavení se nutnosti popisovat problematiku velkým množstvím fyzikálních rovnic popisujících interakce v objektu. To jim umožňuje rychlejší doby výpočtů bodů i přesto, že čas učení nemusí být krátký. Nevýhodou je pak to, že neuronová síť nikdy nemůže predikovat něco, co ještě neviděla. Přesto je to však nadmíru užitečný nástroj.

Zdroje:

- (1) PIVOŇKOVÁ, Alena. Optimalizační algoritmy řídicích systémů. Praha, 2005. Diplomová práce. České Vysoké učení technické v Praze Fakulta elektrotechnická.
- (2) ČERNÝ, Vlastimil. Kombinovaná výroba elektřiny a tepla v ČR. Praha, 2016. Diplomová práce. České Vysoké učení technické v Praze Fakulta elektrotechnická.
- (3) BÁRTA, Michael. Modelování provozu elektroenergetického zdroje v ostrovním provozu. Plzeň, 2020. Bakalářská práce. Západočeská Univerzita v Plzni Fakulta elektrotechnická.
- (4) ŽAITLÍK, David. Optimální řízení akumulátorového úložiště v budově. Praha, 2016. Bakalářská práce. České Vysoké učení technické v Praze Fakulta elektrotechnická.
- (5) NEJEDLÝ, Libor. STUDIUM VLIVU PŘÍMESOVÝCH LÁTEK NA VLASTNOSTI ELEKTRODOVÝCH MATERIÁLU LITHNO-IONTOVÝCH BATERIÍ. Brno, 2009. Bakalářská práce. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ Fakulta elektrotechnicky.
- (6) KRATOCHVÍLA, Lukáš. SYSTÉM PRO SPRÁVU LI-ION BATERIE. Brno, 2017. Bakalářská práce. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ Fakulta elektrotechnicky.
- (7) MULLER, Vojtěch. Parametrické modelování spotřeby elektrické energie pomocí prediktivních metod. Plzeň, 2021. Diplomová práce. Západočeská Univerzita v Plzni Fakulta elektrotechnická.
- (8) KRYCH, Jiří. Využití neuronových sítí pro predikci zatížení distribučního transformátoru. Plzeň, 2019. Bakalářská práce. Západočeská Univerzita v Plzni Fakulta elektrotechnická.
- (9) KALINA, Zbyněk. Analýza projektu FVE na rodinném domě v současných legislativních podmínkách. Praha, 2017. Diplomová práce. České Vysoké učení technické v Praze Fakulta elektrotechnická.
- (10) MA, Shiqing a Yingqi LIU. MODE: automated neural network model debugging via state differential analysis and input selection [online]. 2018, November 4–9, 2018, 1-12 [cit. 2023-05-23].
- (11) ODENA, Augustuas a Catherine OLSSON. TensorFuzz: Debugging Neural Networks with Coverage-Guided Fuzzing. Proceedings of the 36 th International Conference on Machine Learning [online]. Long Beach, California, 2019, November 4–9, 2018, 1-12 [cit. 2023-05-23].
- (12) KIM, Edward a Divya GOPINATH. A Programmatic and Semantic Approach to Explaining and Debugging Neural Network Based Object Detectors. University of California, Berkeley [online]. NASA Ames Research Center, 2020, 1-12 [cit. 2023-05-23].
- (13) PŘIBYL, Michal. Augmentace medicínských dat pomocí hlubokých generativních modelů [online]. Praha Katedra aplikované matematiky, 2020 [cit. 2023-05-23]. Diplomová práce. Katedra aplikované matematiky.
- (14) VÁCHA, Marek. Využití aktuálních technologií pro rychlé vyrovnávání výkonových bilancí v podmínkách ČR [online]. Plzeň, 2022 [cit. 2023-05-23]. Bakalářská práce. Západočeská univerzita v Plzni. Vedoucí práce Ing. Václav Mužík, Ph.D.
- (15) B. M. Sutardi, A. B. Zakaria, I. Akbar, K. M. Banjar-Nahor and N. Hariyanto, "A Comparative Study of Battery Energy Storage Systems in Isolated Grids: Novel Approach to Shave Peaks Optimize Energy Costs,"2022 5th International Conference on Power Engineering and Renewable Energy (ICPERE), Bandung, Indonesia, 2022, pp. 1-6, doi: 10.1109/ICPERE56870.2022.10037476.
- (16) Y. Chen, X. Wang, J. Wang, T. Qian and Q. Peng, "Power Control Strategy of Battery Energy Storage System Participating in Power System Peak Load Shifting,"2020 5th Asia Con-

ference on Power and Electrical Engineering (ACPEE), Chengdu, China, 2020, pp. 710-715, doi: 10.1109/ACPEE48638.2020.9136346.

(17) DIETTERICH, TOM. Overfitting and Undercomputing in Machine Learning. Department of Computer Science, Oregon State Unllerslty. Coruallm O [online]. 1995, -, 1-2 [cit. 2023-05-23].

(18) C. Xu et al., "Multi-loss Regularized Deep Neural Network," in IEEE Transactions on Circuits and Systems for Video Technology, vol. 26, no. 12, pp. 2273-2283, Dec. 2016, doi: 10.1109/TCSVT.2015.2477937.

(19) ULDRICH, Miloš a Tomáš JURCZYK. Neuronové sítě a jejich využití. IT Systems [online]. 2014, 3/2014, 1-2 [cit. 2023-05-23].

(20) NOVÁK, Jiří. Základy teorie chyb a zpracování fyzikálních měření [online]. Praha, - [cit. 2023-05-24]. Přednáška. ČVUT Praha.

(21) SHI, Weijia a Andy SHIH. On Tractable Representations of Binary Neural Networks. Computer Science Department, University of California, Los Angeles, California, USA [online]. 2020, 1-11 [cit. 2023-05-25].

(22) MARAKHIMOV, Avazjon R. a Jabbarbergen K. KUDAYBERGENOV. A MULTIVARIATE BINARY DECISION TREE CLASSIFIER BASED ON SHALLOW NEURAL NETWORK. Termez State University Uzbekistan [online]. 2022, 1-9 [cit. 2023-05-25].

(23) A. Prasad and J. B. Edward, "Importance of artificial neural networks for location of faults in transmission systems: A survey," 2017 11th International Conference on Intelligent Systems and Control (ISCO), Coimbatore, India, 2017, pp. 357-362, doi: 10.1109/ISCO.2017.7856016.

(24) K. Sakurai, K. Nishimura and H. Hayashi, "A practical method based on structural neural networks to optimize power system operation," Proceedings of 1993 International Conference on Neural Networks (IJCNN-93-Nagoya, Japan), Nagoya, Japan, 1993, pp. 451-454 vol.1, doi: 10.1109/IJCNN.1993.713952.