



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

ENERGETICKÝ ÚSTAV

ENERGY INSTITUTE

MOŽNOSTI VYUŽITÍ NEURONOVÝCH SÍTÍ PŘI PROVOZU TEPELNÉHO ČERPADLA

APPLICATIONS OF NEURAL NETWORKS IN HEAT PUMP CONTROL

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Radim Kandrata

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jiří Hejčík, Ph.D.

BRNO 2025

Zadání diplomové práce

Ústav: Energetický ústav
Student: **Bc. Radim Kundrata**
Studijní program: Energetické a termofluidní inženýrství
Studijní obor: Technika prostředí
Vedoucí práce: **Ing. Jiří Hejčík, Ph.D.**
Akademický rok: 2024/25

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách a se Studijním a zkušebním řádem VUT v Brně určuje následující téma diplomové práce:

Možnosti využití neuronových sítí při provozu tepelného čerpadla

Stručná charakteristika problematiky úkolu:

Neuronové sítě přinášejí revoluci v řízení tepelných čerpadel. Analýzou dat z senzorů dokáží předvídat poruchy a optimalizovat výkon. To vede k vyšší efektivitě, úsporám energie a delší životnosti zařízení. Díky predikci tepelné zátěže se čerpadlo přizpůsobí potřebám budovy a minimalizuje spotřebu. Neuronové sítě tak otevírají cestu k inteligentním a udržitelným systémům vytápění.

Cíle diplomové práce:

Cílem této práce je identifikovat potenciál neuronových sítí pro zvýšení spolehlivosti a efektivity provozu tepelných čerpadel. Na základě provedené rešerše prakticky posoudit možnosti nasazení vhodných algoritmů pro posouzení provozních stavů (predikci poruch) u tepelného čerpadla vzduch – voda.

Seznam doporučené literatury:

RIOS, Jorge D.; ALANIS, Alma Y.; ARANA-DANIEL, Nancy; LOPEZ-FRANCO, Carlos a SANCHEZ, Edgar N. Neural networks modeling and control: applications for unknown nonlinear delayed systems in discrete time. London: Academic Press, an imprint of Elsevier, 2020. ISBN 9780128170786

DOUNIS, Anastasios. Intelligent Control in Energy Systems. MDPI, 2019. ISBN 9783039214167.
Dostupné z: <https://doi.org/10.3390/books978-3-03921-416-7>.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2024/25

V Brně, dne

L. S.

prof. Ing. Jiří Pospíšil, Ph.D.
ředitel ústavu

doc. Ing. Jiří Hlinka, Ph.D.
děkan fakulty

ABSTRAKT

Tato diplomová práce se zabývá možnostmi využití neuronových sítí pro detekci poruchových stavů tepelného čerpadla vzduch-voda, které bylo instalováno k rodinnému domu. Výzkum zahrnoval sběr dat po dobu tří měsíců, během kterého byly zaznamenávány vybrané provozní parametry jak normálního chodu, tak i při simulovaných poruchách. Na připravených datech byly testovány neuronové sítě – autoenkodéry pro detekci anomálií, RNN a transformer pro identifikace konkrétních poruch. Lepší identifikace poruch byla dosažena transformerem: porucha zakrytí výparníku (99,6 vs. 30,7 %), porucha odpojení ventilátoru (100,0 vs. 93,8 %), porucha změny přehřátí (99,2 vs. 70,0 %). Navzdory tomu však RNN vykazovala nižší procento falešných poplachů (0,59 vs. 1,4 %). Získané výsledky prokázaly potenciál využití neuronových sítí pro identifikaci poruch tepelných čerpadel.

Klíčová slova

tepelné čerpadlo, poruchy tepelného čerpadla, detekce poruch, neuronová síť, sběr dat, autoenkodér, RNN LSTM, transformer

ABSTRACT

This master thesis deals with the possibilities of using neural networks for the detection of fault conditions of an air-to-water heat pump that has been installed to a family house. The research involved data collection over a period of three months, during which selected operating parameters were recorded both during normal operation and during simulated faults. Neural networks - autoencoders for anomaly detection, RNN and transformer for identification of specific faults were tested on the prepared data. Better fault identification was achieved by the transformer: covered evaporator fault (99.6 vs. 30.7 %), fan disconnection fault (100.0 vs. 93.8 %), changed superheat fault (99.2 vs. 70.0 %). However, despite this, RNNs showed a lower percentage of false alarms (0.59 vs. 1.4 %). The results obtained demonstrated the potential of using neural networks to identify heat pump faults.

Key words

heat pump, heat pump faults, fault detection, neural network, data acquisition, autoencoder, RNN LSTM, transformer

BIBLIOGRAFICKÁ CITACE

KUNDRATA, Radim. Možnosti využití neuronových sítí při provozu tepelného čerpadla. Online, diplomová práce. Jiří HEJČÍK (vedoucí práce). Brno: Vysoké učení technické v Brně, Fakulta strojního inženýrství, 2025. Dostupné z: <https://www.vut.cz/studenti/zav-prace/detail/167007>. [cit. 2025-03-26].

PROHLÁŠENÍ

Prohlašuji, že jsem diplomovou práci na téma **Možnosti využití neuronových sítí při provozu tepelného čerpadla** vypracoval samostatně s použitím odborné literatury a pramenů, uvedených v seznamu, který tvoří přílohu této práce.

.....
Datum

Jméno a příjmení

PODĚKOVÁNÍ

Děkuji tímto Ing. Jiřímu Hejčíkovi, Ph.D. za cenné připomínky a rady, které mi poskytl při vypracování závěrečné práce. Děkuji za pomoc mé rodině, partnerce a všem, kteří mé úsilí podpořili.

OBSAH

1	ÚVOD.....	12
1.1	Cíle diplomové práce.....	13
1.2	Postup	13
2	NEURONOVÉ SÍTĚ.....	14
2.1	Možné oblasti využití neuronových sítí	15
2.2	Použité neuronové sítě.....	16
3	DOSAVADNÍ PROVEDENÉ VÝZKUMY	18
4	POUŽITÉ TEPELNÉ ČERPADLO	20
4.1	Typ tepelného čerpadla.....	20
4.2	Úpravy tepelného čerpadla	21
4.3	Parametry otopné soustavy	22
4.4	Režimy tepelného čerpadla.....	23
5	PORUCHY TEPELNÝCH ČERPADEL	27
5.1	Mechanické poruchy.....	27
5.2	Provozní poruchy.....	29
5.3	Chyby při instalaci.....	31
5.4	Elektrické poruchy.....	31
6	MĚŘENÉ PORUCHY.....	34
6.1	Zakrytí výparníku vnější jednotky.....	34
6.2	Porucha ventilátoru.....	35
6.3	Změna přehřátí chladiva na výparníku	36
6.4	Výpadek čidla kontroléru expanzního ventilu.....	37
6.5	Snížení průtoku vody otopným systémem	38
6.6	Expanzní ventil zaseknut v poloze otevřeno	38
7	SBĚR A ÚPRAVA DAT.....	40
7.1	Způsob získávání dat	40
7.2	Problémy se sběrem dat.....	42
7.3	Měřená data	43
7.4	Příprava dat a feature engineering	47
8	HARDWARE A SOFTWARE.....	49
8.1	Hardware	49
8.2	Software.....	49
9	AUTOENKODÉR – HLEDÁNÍ ANOMÁLIÍ.....	51
9.1	Popis metody	51
9.2	Postup	51
9.3	Shrnutí	58
10	RNN – IDENTIFIKACE PORUCHY.....	59
10.1	Popis metody	59
10.2	Vyhodnocení.....	59
11	TRANSFORMER – IDENTIFIKACE PORUCHY.....	64

11.1	Popis metody	64
11.2	Vyhodnocení.....	64
12	DISKUZE	69
13	ZÁVĚR.....	73
14	SEZNAM PŘÍLOH	74
	SEZNAM POUŽITÝCH ZDROJŮ	75
	SEZNAM POUŽITÝCH ZKRATEK	78

1 ÚVOD

Umělá inteligence (AI) je fenoménem dnešní doby, který stále více proniká do různých oblastí nejen techniky a průmyslu. Přestože koncept umělé inteligence není nový, v posledních letech zažívá nebývalý rozmach, a to zejména díky pokroku v oblasti velkých jazykových modelů. Klíčovou roli v tomto vývoji hraje rozvoj architektur neuronových sítí, dostupnost výpočetního výkonu a obrovské množství obsahu na internetu, který je zcela zásadní pro proces trénování. Velké jazykové modely AI posunují hranice benchmarků každých několik týdnů [1].

S příchodem ChatGPT (Generative Pre-trained Transformer) došlo k rychlému rozšíření umělé inteligence mezi běžné uživatele, kteří ji v současnosti využívají nejen ke generování textů, ale i obrázků, 3D modelů, písniček, videí. Dokáže pomoci i ve spoustě dalších oblastí, např. v programování, analýze obrazu, plánování aj.

Práce s informacemi se stala ještě snazší a uživatelsky příjemnější – chatové aplikace fungují, zatím, bez reklam, při jejich používání není uživatel nucen prodlírat se nepřehlednými webovými stránkami s hromadou vyskakujících oken a nabídek. Na rozdíl od „googlování“ se neomezují pouze na klíčová slova, dokážou pracovat s předchozím kontextem a rozsah odpovědi je možné upravit podle přání tazatele. Na druhou stranu ale mohou být zatíženy artefakty a halucinacemi.

Umělá inteligence je velmi široký pojem, který zastřešuje nejen chatboty popsané v předchozím odstavci, ale i další technologie: Počítačové vidění, které dokáže přechytit SPZ na parkovišti nebo vybrat část kamerového záznamu pouze, pokud jsou přítomny osoby. Data mining, který umí z ohromného množství dat extrahovat různé nečekané a skryté korelace, což se uplatňuje například ve zdravotnictví, pojišťovnictví nebo marketingu. Evoluční algoritmy umožňují optimalizovat složité systémy. AI bezpochyby sehráje zásadní roli také v další robotizaci a automatizaci systémů a procesů, jež bude snadnější naprogramovat díky schopnosti porozumění kontextu.

Z pohledu budoucího servisního technika kompresorových zařízení si pokládám otázku, jakým způsobem bych mohl tyto nástroje AI využít při hledání závad, jejich predikci a identifikaci příčin, optimalizaci výkonu a účinnosti [2]. Zajímá mě, zda jsou mi schopné přinést hlubší pochopení systémů a zvýraznit mi význam některých korelací. Zda může síť halucinovat, kolik je zapotřebí trénovacích dat a jaké jsou nároky na jejich kvalitu. Zda a jaký smysl má záznam provozních parametrů, jaký musí být jejich rozsah atp.

Tepelných čerpadel byla v posledních letech nainstalována spousta. Mnohé z nich už disponují pokročilou senzorikou i online diagnostikou a zaznamenávají řadu dat. Použití AI na těchto datech může zlepšit predikci spotřeby energie pro řízení sítě, odhalit vznikající poruchu, a dokonce i posloužit k vývoji dalších generací tepelných čerpadel.

Rozhodl jsem se, že pro odhalení těchto otázek nainstaluji pokusné tepelné čerpadlo na náš rodinný dům, u něhož budu schopen uměle vyvolávat poruchy chodu. Budu u něj moci řídit také důležité parametry, kontrolovat proces měření, sledovat jeho chování, a navíc se veškeré vyrobené teplo využije k vytápění objektu. Sesbíraná data pak využiji k trénování neuronových sítí.

„Functions describe the world.“ Thomas Garrity

„Neural networks are function building machines.“ Emergent Garden

1.1 Cíle diplomové práce

Cílem diplomové práce je vytvoření a natrénování neuronové sítě, která dokáže indikovat poruchy u experimentálního tepelného čerpadla vzduch-voda. Na základě rešerše bude vybráno několik algoritmů, které budou následně prakticky otestovány aplikací na naměřená data. Výsledkem bude zhodnocení, zda jsou dané algoritmy pro požadované možnosti nasazení vhodné či nikoliv a jaká jsou jejich úskalí.

Doufám, že data i dovednosti získané během zpracování této práce mi pomohou zlepšit mou intuici co se týká samotného tepelného čerpadla, ale i při výběru algoritmů využívající neuronové sítě a že se budu lépe orientovat v dané problematice a dostupných přístupech.

1.2 Postup

Diplomová práce byla zpracována kombinovaným přístupem, který zahrnoval rešerši, praktické experimenty na tepelném čerpadle se zaznamenáváním provozních dat a následnou analýzu dat s využitím neuronových sítí.

Na rodinný dům bylo instalováno experimentální tepelné čerpadlo vzduch-voda, které bylo doplněno senzory pro snímání požadovaných provozních parametrů. Toto umožnilo sběr dat z reálného provozu. Sbíraná provozní data zahrnovala jak záznamy z normálního chodu TČ, tak data získaná během cíleně vyvolaných poruchových stavů. Mezi simulované poruchy patřilo například omezení průtoku vzduchu výparníkem jednotky, selhání ventilátoru či chybné nastavení expanzního ventilu. Data byla sbírána během tří měsíců. Tento řízený sběr dat byl klíčový pro vytvoření označených datových sad nezbytných pro trénování a testování modelů.

Teoretická část práce je věnována rešerši zaměřené na dosud provedené aplikace neuronových sítí v oblasti diagnostiky HVAC systémů. Na základě toho pak byly zvoleny typy a architektury neuronových sítí vhodné pro praktickou část.

Sesbíraná data prošla nezbytným předzpracováním – čištěním a feature engineeringem. Připravené datové sady byly poté použity pro trénování vybraných modelů neuronových sítí. Byly vyzkoušeny různé konfigurace a přístupy. Úspěšnost a výkonnost 3 natrénovaných modelů byla následně vyhodnocena na testovacích datech pomocí standardních metrik a vizuální analýzy výsledků v grafech. Cílem bylo porovnat efektivitu jednotlivých přístupů a posoudit celkovou schopnost neuronových sítí detekovat, případně klasifikovat, poruchové stavy tepelného čerpadla.

2 NEURONOVÉ SÍTĚ

Umělá inteligence je velmi široký pojem a nemá přesnou definici. Obecně lze říct, že se jedná o systémy, které projevují inteligentní chování. Za to se může považovat schopnost řešit úkoly se složitým souborem pravidel, ale také schopnost samostatně se učit, přizpůsobovat se, hledat vzory v datech nebo generovat nová, rozhodovat se. Pojem umělá inteligence také označuje vědní obor, který se zabývá vytvářením těchto systémů.

Strojové učení je podmnožinou umělé inteligence a označuje algoritmy a modely, které jsou schopné učit se a zlepšovat se díky vzorům a závislostem z dat. To jim pak umožňuje rozpoznávat objekty, hledat anomálie, rozhodovat se nebo předpovídat budoucí výstupy.

Neuronové sítě jsou podmnožinou strojového učení. Jedná se o systémy, které jsou založeny na architektuře, která připomíná fungování mozku. Neurony, výpočetní jednotky s jednoduchými matematickými závislostmi, jsou mezi vrstvami vzájemně propojeny a vytváří tak síť. Při učení se potom tyto matematické závislosti upravují tak, aby po průchodu dat sítí nejlépe odpovídaly požadovanému výsledku. Na základě neuronových sítí fungují i velké jazykové modely.

Pro lepší orientaci v této práci přikládám slovník základních pojmů, které jsou s AI a umělými neuronovými sítěmi spojeny. [3]

- **Tensor:** Více-dimenzionální pole čísel. Skalár je 0D tenzor, vektor je 1D tenzor, matice je 2D tenzor. Tenzory jsou základní datovou strukturou používanou v knihovnách pro hluboké učení pro reprezentaci dat a vah.
- **Perceptron:** Nejjednodušší typ umělého neuronu, který produkuje binární výstup (typicky 0 a 1 nebo -1 a 1) na základě toho, zda vážený součet jeho vstupů překročí určitou prahovou hodnotu.
- **Neuron:** Základní výpočetní jednotka neuronové sítě. Přijímá jeden nebo více vstupů, provádí na nich výpočet (typicky vážený součet následovaný aktivační funkcí) a produkuje spojitý výstup.
- **Aktivační funkce:** Funkce aplikovaná na výstup neuronu (po váženém součtu vstupů a přičtení biasu), která zavádí nelinearitu do modelu. To umožňuje neuronovým sítím učit se komplexní vzory. Příklady zahrnují sigmoid, ReLU, tanh. Nemusí být nutně "neskoková", ale pro gradientní metody učení je výhodné, pokud je možné udělat její diferenciál.
- **Bias:** Parametr v neuronu (často označovaný jako b nebo mezní hodnota), který je přičten k váženému součtu vstupů neuronu před aplikací aktivační funkce. Umožňuje posunout aktivační funkci doleva nebo doprava, což zvyšuje flexibilitu modelu.
- **Vstupní vrstva:** První vrstva neuronové sítě, která přijímá surová vstupní data.
- **Skrytá vrstva:** Jakákoli vrstva neuronů mezi vstupní a výstupní vrstvou v neuronové síti. Tyto vrstvy provádějí transformace dat a učí se komplexnější rysy z výstupů předchozích vrstev.
- **Výstupní vrstva:** Poslední vrstva neuronů v síti, která produkuje konečný výsledek nebo predikci modelu. Počet neuronů a typ aktivační funkce ve výstupní vrstvě závisí na typu úlohy.
- **Hyperparametry:** Označení parametrů, které umožňují nastavení algoritmů strojového učení, která nejsou učena přímo z trénovacích dat, ale jsou nastavena předem uživatelem nebo pomocí validačního procesu. Ovlivňují chování algoritmu, např. rychlost učení, velikost dávky dat, délka sekvencí, dropout a další.
- **Hloubka:** V kontextu hlubokého učení označuje počet vrstev v neuronové síti, zejména počet skrytých vrstev. Hlubší síť jsou schopny se učit hierarchické reprezentace rysů.

- **Rychlost učení** (learning rate): V optimalizačních algoritmech, který určuje velikost kroku při aktualizaci vah modelu na základě vypočteného gradientu. Příliš vysoká rychlost učení může vést k nestabilitě, příliš nízká k pomalé konvergenci.
- **Epocha**: Jedná se o jeden kompletní průchod celým trénovacím datasetem během procesu trénování neuronové sítě. Trénink obvykle zahrnuje více epoch.
- **Batch**: Podmnožina trénovacích dat použitá k výpočtu gradientu a aktualizaci vah modelu v jedné iteraci tréninkového procesu. Použití dávek namísto celého datasetu zrychluje trénink a může vést k lepší generalizaci.
- **Autotuner**: Proces automatického nebo poloautomatického hledání optimální sady hyperparametrů pro model strojového učení tak, aby se dosáhlo nejlepšího výkonu na validačních datech.
- **CNN** (Convolutional Neural Network): Neuronová síť využívající konvoluční vrstvy k detekci lokálních vzorů ve vstupních datech (obrázky, signály). Filtry procházejí daty a extrahují rysy nezávislé na jejich poloze.
- **RNN** (Recurrent Neural Network): Architektura umělé neuronové sítě navržená pro zpracování sekvenčních dat (časové řady, text apod.). Díky zpětným vazbám mezi vrstvami si síť „pamatuje“ předchozí vstupy a dokáže modelovat závislosti v čase.
- **LSTM** (Long Short-Term Memory): Architektura sítě, která se snaží řešit problém mizejícího gradientu, který mají RNN sítě (informace o minulosti postupným průchodem nových dat ztrácí svůj vliv). Neurony mají svou paměť a brány, které vybírají, které informace budou zachovány.
- **GRU** (Gated Recurrent Unit): Zjednodušená varianta LSTM sítě, která používá pouze dvě „brány“ (aktualizační a resetovací). Díky menšímu počtu parametrů je výpočetně efektivnější, přitom si zachovává schopnost učit se dlouhodobé závislosti.
- **Hybridní model**: Kombinace dvou nebo více typů neuronových sítí (např. RNN + CNN), která využívá výhody každé z nich a zlepšuje se přesnost či robustnost výsledného řešení.
- **Ztráta** (loss): Hodnota, která ukazuje, jak špatně neuronová síť predikuje výsledky na základě trénovacích dat.
- **Přesnost** (accuracy): Hodnota, která ukazuje podíl správně klasifikovaných vzorků z trénovacích dat.
- **Validate**: Část dat je vyhrazena validaci. Je to část dat, která nebyla sítí využita pro trénink (neuronová síť ji neviděla). Používá se k rychlé indikaci toho, jak si síť vede při generalizaci a zda není přeučená (tzn. skvělá přesnost při trénování, ale nízká přesnost při validaci).

"The greatest enemy of knowledge is not ignorance, it is the illusion of knowledge." Daniel J. Boorstin

2.1 Možné oblasti využití neuronových sítí

HVAC (Heating, Ventilation and Air Conditioning) je zkratka pro systémy vytápění, větrání a klimatizace, které zahrnují také tepelná čerpadla. Existují 4 hlavní odvětví neuronových sítí, které lze použít v systémech HVAC [4]:

- **Regrese** (Regression)
Regrese se používá pro predikci spojitých číselných hodnot (např. teploty, energetické spotřeby). Cílem je najít vztah mezi vstupními proměnnými a výstupní proměnnou, často proložením dat modelem, aby bylo možné předpovídat budoucí hodnoty.
Predikce budoucích výstupů je základem pro řízení systémů neuronovými sítěmi.

- **Shlukování** (Clusterization)
Shlukování je technika (bez učitele – tzv. unsupervised learning), která seskupuje podobné datové body dohromady do „shluků“ na základě jejich vlastností, aniž by předem znala kategorie. Cílem je objevit přirozené skupiny nebo struktury v datech. Shlukování může být použito například pro detekci anomálií, kde body, které nezapadají do žádného velkého shluku, mohou být považovány za odchylky.
- **Klasifikace** (Classification)
Klasifikace se používá k přiřazení vstupních dat do jedné z několika předem definovaných kategorií nebo tříd (učení s učitelem – supervised learning). Toho je možné využít pro klasifikaci přesného typu poruchy po předchozí ukázce poruchových stavů.
- **Redukce dimenzionality** (Dimension reduction)
Umožňuje z rozsáhlých dat vybrat ty nejdůležitější, dále umožňuje lepší vizualizaci dat nebo extrakci závislostí, což mohou následně využít i jiná odvětví neuronových sítí. Může být také využita pro komprimaci dat.

2.2 Použité neuronové sítě

Algoritmů neuronových sítí je celá řada. Každý má své výhody a nevýhody, což jej předurčuje ke specifickému využití. Na základě rešerše dostupných možností byly v práci použity následující tři modely:

Autoenkodéry

Autoenkodér je druh neuronové sítě, která se učí napodobit svůj vstup na výstupu – tedy vytvořit co nejvěrnější kopii vstupních dat. Síť se skládá ze dvou částí: první část (enkodér) vstup zkomprimuje a druhá (dekodér) ho z této zjednodušené podoby opět složí zpět.

Pokud by se síť naučila vstup jen bezchybně zkopírovat, nebylo by to moc užitečné. Proto jsou autoenkodéry navrženy tak, aby nebylo dokonalé kopírování možné. Mezi enkodérem a dekodérem je dimenze dat snižena. Díky tomu se síť naučí vystihnout jen podstatné rysy dat, které pak můžeme dále využít – například pro kompresi, odstraňování šumu nebo detekci anomálií[3].

Autoenkodéry pro odstranění šumu pracují tak, že ke vstupním datům bez šumu je šum uměle přidán. Výsledek z autoenkodéru pak ale neporovnáváme s daty se šumem, ale s daty původními – bez šumu. Tím by se měla síť naučit odstraňovat šum.

Autoenkodérů lze využít i pro kompresi dat. Autoenkodér je naučen na původních datech. Data jsou pak uložena jako reprezentace v oblasti snížené dimenze. Obraz původních dat je možné opět vytvořit dekodérem.

Detekce anomálií – síť je naučena na datech, které reprezentují běžný (normální) stav systému. Pokud jsou pak do sítě vložena data, která se od jejich původní podoby výrazně liší, může to indikovat anomálii těchto dat.

Problém může nastat, pokud je síť příliš velká, a proto pak autoenkodér neextrahuje důležité rysy dat. Pokud je příliš malá, nemá dostatek neuronů pro postihnutí všech závislostí. Je třeba experimentálně otestovat vhodně velikou síť.

„All models are wrong, but some are useful.“ George E. P. Box

Rekurentní neuronové sítě (RNN)

Rekurentní neuronové sítě (Recurrent Neural Networks – RNN) jsou třída umělých neuronových sítí navržených pro zpracování sekvenčních dat, jako jsou text, řeč nebo časové řady, kde pořadí prvků určuje kontext.

Na rozdíl od feed-forward sítí, které zpracovávají jednotlivé vstupy nezávisle, RNN využívají zpětné („recurrent“) spojení, kdy výstup neuronů z předchozí časové chvíle ovlivňuje zpracování následujícího vstupu.

Díky této architektuře mají RNN „paměť“ umožňující modelování časových závislostí v datech. Problémem je tzv. mizející/explodující gradient, kdy ze sítě mizí informace, která se nevyskytuje tak často nebo se vyskytuje v dávě části dat. Řešením tohoto problému je LSTM neuronová síť, která má tři brány. Vstupní brána určuje, která informace bude do buňky přijata. Brána zapomínání rozhoduje, které informace budou zapomenuty a výstupní brána určuje, která data budou poslána do dalších neuronů.

Transformery

Transformery byly představeny v poprvé v roce 2017 v práci Attention Is All You Need [5]. Tvoří základ moderních jazykových modelů (jak odkazuje i název chatu GPT – Generative Pre-trained Transformer). Data jsou označena jejich pořadím v sekvenci. Založeny jsou na zkoumání závislostí (self-attention) mezi vstupními daty. Toto vyhodnocení závislostí je pak předáno do vrstev dopředné neuronové sítě. Tato architektura neuronových sítí nemusí všechna data zpracovávat sekvenčně. To umožňuje paralelizaci procesu učení, a to vede k zásadnímu zrychlení tohoto procesu.

3 DOSAVADNÍ PROVEDENÉ VÝZKUMY

Níže jsou uvedeny předchozí výzkumy, které se věnovaly nasazení neuronových sítí na data tepelných čerpadel.

Heat pump digital twin: An accurate neural network model for heat pump behaviour prediction [6]

Cílem autora bylo vytvoření digitálního dvojčete tepelného čerpadla voda-voda, aby bylo možné predikovat spotřebu a výkon tepelného čerpadla pro potřeby řízení sítě s co nejvyšší přesností. K tomu využil přístup neuronových sítí, které byly trénovány na skutečných naměřených datech. Nebylo tedy nutné vytvářet žádný fyzikální model. Porovnával FNN a RNN s LSTM. Data jsou v minutovém kroku. Vstupem jsou průtoky a teploty na vstupu výparníku a kondenzátoru společně s výstupní a nastavenou teplotou kondenzátoru. Výstupem je průtok a výstupní teploty kondenzátoru a výparníku, společně s příkonem a tepelným výkonem tepelného čerpadla.

Z výsledků vyplývá, že pro predikci jednoho kroku dopředu dosahuje lepších výsledků FNN síť. Pro delší predikce je lepší použít RNN LSTM síť, protože dokáže zohlednit předchozí zásahy.

Nejlepší výsledky pro víceukrokovou predikci poskytla LSTM síť využívající 60 minut předchozích provozních dat. Tato síť dokázala predikovat elektrický příkon s chybou ± 10 % po 79,7 % času, průtok kondenzátorem s chybou ± 10 % po 89,8 % času a výstupní teplotu kondenzátoru s chybou ± 1 % po 83,9 % času během testovacího týdne.

Studie také zkoumala přenositelnost modelu: model trénovaný na datech ze systému s podlahovým vytápěním měl výrazně nižší přesnost při aplikaci na systém s radiátory bez přetrénování, což zdůrazňuje potřebu dostatečně bohatých a rozmanitých trénovacích dat.

Physics-Informed Neural Networks for Heat Pump Load Prediction [7]

Autor se zaměřuje na spojení základního fyzikálního modelu s neuronovou sítí pro predikci příkonu tepelného čerpadla PINN (Physics-Informed Neural Networks). Od toho přístupu si autor slibuje výsledky, které jsou více fyzikálně konzistentní a pro natrénování neuronové sítě by nemělo být zapotřebí tak velké množství dat. Hyperparametry sítě byly optimalizovány s pomocí Keras Tuner. Model byl trénován a testován na veřejně dostupných datech z US Heat Pump Database.

Navržený PINN model dosáhl statisticky významně vyšší přesnosti predikce tepelné zátěže ve srovnání s klasickou datově řízenou neuronovou sítí. Došlo ke snížení chybových metrik: RMSE kleslo o $\sim 7,5$ %.

Integrace fyzikálních zákonů zajišťuje, že predikce jsou fyzikálně konzistentní a model lépe generalizuje, i když nemá k dispozici obrovské množství dat.

Model prokázal dobrou výkonnost v různých teplotních podmínkách (testováno na datech z chladnější i teplejší lokality).

Článek ukazuje, že začleněním, i zjednodušených, fyzikálních modelů přímo do procesu učení neuronové sítě lze zlepšit přesnost a robustnost predikcí pro tepelná čerpadla. Tento přístup je méně náročný než tvorba komplexních fyzikálních modelů a zároveň přesnější než čistě datové modely.

Comparative analysis of four classification algorithms for fault detection of heat pumps [8]

Článek se zabývá porovnáním 4 přístupů pro identifikaci poruch tepelného čerpadla. Byť nepoužívá přímo algoritmy hlubokých neuronových sítí, s tématem práce souvisí oblastí

indikace poruch. K vyhodnocení byla využita data z práce Performance of a residential heat pump operating in the cooling mode with single faults imposed [9], která měřila splitové tepelné čerpadlo v režimu chlazení v různých klimatických stavech. Součástí práce bylo měření poruch (netěsnost kompresoru/reverzního ventilu, nedostatečný průtok přes venkovní výměník, nedostatečný průtok přes vnitřní výměník, zvýšení tlakové ztráty na trubce kapaliny, přeplnění systému chladivem, nedostatek chladiva v systému, přítomnost nekondenzovatelných plynů v systému).

Veličiny z původního datasetu byly předzpracovány, normalizovány a s pomocí testu závislosti proměnných byla vybrána polovina těch nejprizmatnějších.

Poté byly porovnány 4 přístupy:

- K-Nearest Neighbors (KNN)
- Naïve Bayes (Gaussian)
- Support Vector Machine (SVC, lineární / RBF jádro)
- Logistic Regression (L1 – penalizovaná)

Pomocí metrik Accuracy, Precision, Recall a F1 score byly přístupy porovnány. Nejlépe dopadl algoritmus KNN, který dosáhl ve všech metrikách výsledků nad 99,8 %. Ostatní přístupy dosahovaly výsledků nad 94 %. Závěrem tedy je, že jsou tyto modely schopné velmi spolehlivě detekovat poruchy. Výzkum také ukázal, že použití pouze poloviny měřených veličin nijak zásadně neovlivnilo přesnost použitých algoritmů.

Pro kompresory a ventilátory tepelných čerpadel větších výkonů je možné využít i vibradiagnostiku, která se již využívá u jiných rotačních strojů. Metoda spočívá v záznamu hluku mikrofonom nebo měření vibrací, jejich zpracování (například využití Fourierovy transformace) a následnou analýzu v čase. Zvyšující se intenzita značí, že dochází k opotřebení částí a tím se může předcházet poruše, která by systém neplánovaně odstavila. [10]

Jako základ práce byla tedy zvolena detekce anomálií s využitím autoenkoderů. Následně pak byly porovnány dvě klasifikační metody se supervised learning (učení s učitelem) – rekurentní neuronové sítě LSTM a transformery.

„The goal of forecasting is not to predict the future but to tell you what you need to know to take meaningful action in the present.“ Paul Saffo

4 POUŽITÉ TEPELNÉ ČERPADLO

Pro lepší pochopení dosažených výsledků je nutné se seznámit s konkrétním tepelným čerpadlem společně s otopnou soustavou, ke které je připojeno.

V posledních letech došlo k velkému nárůstu instalací tepelných čerpadel nejen do rodinných domů [11]. Ale například oproti plynovým kotlům se jedná o komplexnější zařízení, jehož poruchy jsou hůře identifikovatelné. Navíc na trhu přibyla spousta nových výrobců, která s jejich výrobou a řídicími jednotkami nemají velkou zkušenost [12]. Potíže mohou nastat i při samotné instalaci, u které je nutné dodržet spoustu zásad.

Diagnostika tak může hrát do budoucna důležitou roli, a to při úspoře času i financí. Pokud je již předem známo, jaká porucha nejpravděpodobněji nastala, servis může lépe predikovat délku odstávky i náklady opravy, hned při první návštěvě dovést potřebné díly i vybavení. To celý proces opravy urychlí.

4.1 Typ tepelného čerpadla

Základní typy tepelných čerpadel jsou TČ vzduch-vzduch, země-voda, voda-voda a vzduch-voda. Zvoleno bylo TČ vzduch-voda, protože je pro vytápění celých domů nejběžnější, nebylo nutné investovat do zemních výměníků, má nejširší pracovní rozsah a zajímavé provozní stavy (odmrazování, chlazení), které jsou ovlivňovány venkovními podmínkami.

Jedná se o splitovou jednotku Sinclair, model: ASH-09 AINPT, viz obrázek 4.1.



Obr. 4.1: Ilustrační obrázek splitové jednotky Sinclair [13].

Klimatická třída jednotky je T1 podle normy ISO 5151(tab. č. 4.1) [14]. Její parametry jsou uvedeny v tab. č. 4.2. Hlučnost venkovní jednotky je podle štítku 53 dB(A).

Tab. 4.1: Parametry měření v jednotlivých klimatických třídách podle ISO 5151 [14].

třída	T1	T2	T3
teplota vzduchu vstupujícího do vnitřní jednotky:			
- suchý teploměr	27 °C	21 °C	29 °C
- mokřý teploměr	19 °C	15 °C	19 °C
teplota vzduchu vstupujícího do venkovní jednotky:			
- suchý teploměr	35 °C	27 °C	46 °C
- mokřý teploměr	24 °C	19 °C	24 °C

Tab. 4.2: Výkon a příkon jednotky třídy T1 podle ISO 5151 [14].

chlazení	výkon	2500 W	topení	výkon	2750 W
	příkon	780 W		příkon	760 W
	maximální příkon	1400 W		maximální příkon	1450 W

Jednotka používá chladivo R410A. Jedná se o zeotopní chladivo (byť je teplotní skok pouze kolem 0,08 °C), které je složeno v poměru 1:1 z difluormethanu (CH_2F_2) a pentafluorethanu (CHF_2CF_3). ODP chladiva je 0. Nominální náplň je 0,78 kg, což odpovídá ekvivalentu 1628,6 kg CO_2 (podle GWP-AR4). [15]

Od chladiva se odvíjí i tlaky v chladivovém okruhu. Maximální dovolený tlak je 3,8 MPa. Maximální provozní tlak na výtlačná straně je podle štítku 2,8 MPa a na sací straně 1,2 MPa. Venkovní jednotka má krytí IP24, podle normy ČSN EN 60529, které brání vniknutí prstů (resp. předmětů větších jak 12,5x12,5 mm) a chrání jednotku proti stříkající vodě ze všech úhlů [16]. Je osazena axiálním ventilátorem se třemi plastovými lopatkami, který je poháněn jednofázových asynchronním elektromotorem. Ten zajišťuje proudění vzduchu přes lamelový výměník, který je jednořadý s prostřihávanými lamelami. Chladivový okruh je v něm rozdělen do dvou sekcí.

Kompresor je hermetický rotační, jeho pohon je zajištěn integrovaným elektromotorem s permanentními magnety. Kompresor je uložen na 3 šroubech se silentbloky. Celý je obalen do tepelné a hlukové izolace. Kompresor je vyhříván topným páskem umístěným zhruba ve spodní pětině jeho výšky.

Veškerá elektronika venkovní jednotky je v plechovém boxu. Chladič výkonové elektroniky je v prostoru ventilátoru. Elektrické propojení vnitřní a venkovní jednotky je pomocí komunikačního a napájecího kabelu.

Teplotní čidla, měřící teplotu trubek, jsou s pomocí pružného nerezového plíšku upevněna v krátké měděné trubičce, která je připájena na trubku, jejíž teplota je měřena. Čidlo venkovní teploty je v ochranné plastové hadičce vyvedeno do levého horného rohu jednotky vně výměníku venkovní jednotky, kde je držena plastovým úchytem.

Propojení vnitřní a venkovní jednotky je realizováno pomocí měděné trubky s izolací. Délka propojení je zhruba 2 metry, vnější průměr je 6 a 10 mm.

Lokalita instalace TČ je 250 m n. m., na jihovýchodě Zlínského kraje. Umístěno bylo v závětrí, na dvoře, na severní straně domu. Ustaveno je na polystyrenových blocích, 20 cm nad zemí. Po dobu testů bylo celodenně zastíněno.

4.2 Úpravy tepelného čerpadla

K testování jsem použil levnou, nepotřebnou jednotku, neboť existovala reálná možnost jejího nevratného poškození. Tato jednotka však byla typu vzduch-vzduch, bylo proto nutné ji na typ vzduch-voda konvertovat. Vyměněn byl tedy výměník vnitřní jednotky za nerezový pájený deskový výměník – SWEP B25THx40 [17] v protiproudém zapojení. Systém byl také doplněn o filtrdehydrátor společně s průhledítkem.

Protože byl změněn vnitřní objem, muselo být změněno i množství náplně chladiva. Proto byl systém naplněn podle průhledítka tak, aby se v něm, v žádném z provozních stavů při režimu vytápění, neobjevovaly viditelné bublinky.

Další úpravou byla výměna expanzního zařízení. Původně bylo tepelné čerpadlo osazeno kapilárou, která byla nahrazena elektronickým pulsním ventilem. Osazen byl i další uzavíratelný ventil, aby bylo možné expanzní zařízení vyměnit bez nutnosti vypustit celý okruh

a také, aby bylo možné seřadit jeho tlakovou ztrátu, a pracoval tak v optimálním hodnotě otevření.

Řídicí jednotka pulsního ventilu (AK-CC 550, obr. 4.2) byla nastavena tak, aby udržovala přehřátí 3 K. Pracovala spolehlivě téměř celou dobu testu. Pokud TČ odmrazuje, měřené přehřátí je vysoké a ventil je tak otevřen naplno. I když se nejedná o optimální řešení, odmrazení probíhalo za všech podmínek v pořádku.



Obr. 4.2: Řídicí jednotka pulsního expanzního ventilu AK-CC 550 [18].

4.3 Parametry otopné soustavy

Ekonomika a provoz tepelného čerpadla jsou silně závislé na tom, na jaký systém je připojeno. Otopný systém ovlivňuje dynamiku změn teplot, provozní teplotní spád i proces odmrazení. Soupis otopných těles systému je uveden v tabulce 4.3.


Tab. 4.3: Charakteristika otopné soustavy.

patro	název místnosti	výška [cm]	délka [cm]	typ – hloubka [cm]	v provozu
suterén	sklep	60	120	11 – 6,5	NE
	prádelna	60	120	11 – 6,5	NE
	schodiště	60	100	11 – 6,5	NE
přízemí	zádveří	60	90	11 – 6,5	NE
	schodiště	60	100	11 – 6,5	NE
	chodba	60	80	11 – 6,5	ANO
	koupelna – žebřík	190	60	3,5	ANO
	koupelna – podlahové topení 3 m ²	-	-	-	ANO
	obývací pokoj	50	140	22 – 11	ANO
	obývací pokoj 2	50	140	22 – 11	ANO
	pokoj	50	100	21 – 8,5	ANO
patro	pokoj 1	60	100	21 – 8,5	ANO
	pokoj 2	60	110	11 – 6,5	NE
	ložnice	60	100	21 – 8,5	ANO
	obývací pokoj	60	90	22 – 11	NE
	obývací pokoj	60	140	22 – 11	NE

Oběhové čerpadlo je elektronicky řízené. V průběhu celého testu bylo nastaveno na konstantní výkon. V celé soustavě byly termostatické radiátorové hlavice nastaveny buď zcela otevřené nebo zcela zavřené. Průtok tedy byl víceméně konstantní. Oběhové čerpadlo

není nijak řízeno – běží, i pokud není tepelné čerpadlo v chodu. Pokud je tepelné čerpadlo odpojeno od elektrické sítě, neběží ani oběhové čerpadlo.

Tepelné čerpadlo je do otopné soustavy připojeno paralelně (viz obr. 4.3), přičemž byl v době testů kohout kotle uzavřen. Ve schématu nejsou zaneseny ochranné, expanzní ani řídicí prvky systému.




Obr. 4.3: Blokové schéma zapojení otopného systému.

4.4 Režimy tepelného čerpadla

Pro lepší přiblížení fungování použitého tepelného čerpadla se následující kapitola zabývá běžnými režimy fungování. Zachycuje chování řídicí jednotky a ovlivnění měřených veličin. To je nutné k pochopení některých fenoménů v evaluaci dat neuronovými sítěmi.

- **Zapnutí**


Při spuštění vytápění kompresor začne skokově zvyšovat své otáčky, roste i jeho teplota. Zároveň s kompresorem je spuštěn i ventilátor. V grafu 4.1 je zřetelný teplotní spád otopné soustavy i zpoždění, než se ochlazená voda dostane zpět do výměníku. Zvlnění měřených veličin je způsobeno otevíráním expanzního ventilu.



Graf 4.1: Chování tepelného čerpadla při zapnutí.

• Odmrazování


Moment, kdy je nutné spustit odmrazování, vyhodnocuje řídicí elektronika. Odmrazovací sekvence je následující: Nejdříve je vypnut kompresor. Ventilátor poté několik sekund dobíhá, což napomáhá k rychlejšímu ohřevu výměníku na teplotu okolí. Následuje pauza, ve které dojde k přepnutí reverzního ventilu do stavu chlazení (červená oblast grafu – graf 4.2). Po pauze kompresor zase postupně přidává na výkonu a teplota výparníku se zvyšuje. Zřetelné je taky odebírané teplo z otopného systému (teplota vody zpátečky je vyšší jak teplota vody na výstupu do otopného systému). Po konci odmrazování je ventil přepnut do režimu topení a po další pauze začne tepelné čerpadlo opět standardně nabíhat v režimu topení.



Graf 4.2: Průběh teplot a příkonu při odmrazovací sekvenci.

• Vypnutí


Po vypnutí kompresoru jsou vyrovnány teploty výstupu a zpátečky (graf 4.3). Ventilátor pak dobíhá ještě několik sekund. Teplota v otopné soustavě postupně klesá. Peak teploty sání je v důsledku proudění chladiva z vysokotlaké části (kondenzátoru) skrz kompresor (ten nemá zpětný ventil nebo je poškozený). Je vidět, že klidová spotřeba tepelného čerpadla je zhruba 50 W.



Graf 4.3: Chování čerpadla bezprostředně po vypnutí.

• Vypnuto


Oběhové čerpadlo běží i v případě, že TČ nevytápí. Teploty výstupu a zpátečky jsou vyrovnány (liší se pouze chybou měření použitých senzorů). Jak lze ale vidět na grafu 4.4, teploty sání i kompresoru jsou vyšší než okolní teplota. Tento rozdíl je způsobem ztrátovým teplem cívky expanzního a reverzního ventilu a vyhříváním kompresoru.



Graf 4.4: Průběh teplot při dlouhodobém vypnutí tepelného čerpadla.

• Odpojení od napájení

Pokud je tepelné čerpadlo zcela odpojeno od napájení, teploty už nejsou ovlivněny ztrátovým teplem elektromagnetického expanzního ventilu, elektromagnetem čtyřcestného ventilu ani vyhříváním kompresoru. Oběhové čerpadlo neběží, je vidět značný rozdíl mezi teplotou zpátečky, která je vedena u podlahy, a výstupem, který je zhruba 50 cm nad podlahou kotelny (viz graf 4.5).



Graf 4.5: Chování tepelného čerpadla v případě, že je odpojeno od napájení.

5 PORUCHY TEPELNÝCH ČERPADEL

V následující kapitole jsou nastíněny běžné poruchy tepelných čerpadel. Tento obecný přehled je důležité mít na mysli pro správné pochopení jejich příčin, důsledků a následnou interpretaci získávaných dat. Může být nápomocný pro výběr měřených parametrů. Klíčovými zdroji informací pro tuto kapitolu byly zdroje [19], [20] a [21].

5.1 Mechanické poruchy

Mechanické poruchy představují významnou kategorii závad tepelných čerpadel. Postihují především pohyblivé části a komponenty vystavené mechanickému namáhání, vibracím a opotřebením.

Poruchy kompresoru

Kompresor je základem každého chladivového okruhu TČ. Existuje několik konstrukčních typů (např. pístový, scroll, rotační, swing), ale přestože se liší principem činnosti, mohou je postihnout podobné typy mechanických poruch:

- **Problémy se startem:** Některé kompresory mají omezený startovací moment a nejsou schopny se rozběhnout proti vysokému protitlaku (např. pokud v systému ještě nedošlo k vyrovnání tlaků). Proto se často používají časová relé nebo jiné řídicí prvky, které zpožďují opětovné spuštění kompresoru o určitou dobu, aby se tlaky stihly vyrovnat. [22]
- **Zadření kompresoru:** K této vážné poruše dochází při nedostatečném mazání pohyblivých částí (např. v důsledku nízké hladiny oleje, degradace oleje nebo ucpání mazacích kanálků) nebo při jejich nedostatečném chlazení. Třecí plochy se přehřejí, dojde k jejich poškození (svaření) a následnému mechanickému zablokování kompresoru.
- **Zatuhnutí kompresoru:** Může nastat po delší odstávce, zejména v důsledku koroze vnitřních částí, z toho důvodu, že do systému pronikla vlhkost.
- **Vnitřní netěsnosti:** Způsobené jsou opotřebením funkčních ploch v důsledku přítomnosti pevných částic. Zdrojem těchto částic mohou být zbytky z obrábění, otřepy z úprav konců trubek nebo oxidy (např. oxidy mědi vznikající při pájení bez ochranné atmosféry dusíku).
- **Poruchy ventilů** (u pístových kompresorů): Sací a výtlačné ventily pístových musí být zkonstruovány tak, aby se minimalizoval škodlivý prostor kompresoru. Jsou vystaveny extrémnímu tepelnému a cyklickému mechanickému namáhání. V důsledku toho může dojít k jejich prasknutí, netěsnosti nebo zaseknutí.
- **Porucha nástřiku chladiva pro chlazení kompresoru:** Některé kompresory, zejména ty pracující s vysokými kompresními poměry, vyžadují aktivní chlazení, například nástřikem malého množství kapalného chladiva do sací nebo kompresní komory [23]. Selhání tohoto systému vede k přehřívání kompresoru.
- **Netěsnost zpětného ventilu:** Rotační a scroll kompresory jsou často vybaveny zpětným ventilem, který po vypnutí brání zpětnému proudění stlačených par z kondenzátoru do kompresoru. Pokud tento ventil netěsní, může tlakem par dojít k roztočení kompresoru na opačnou stranu, což maří energii.
- **Chladivové rázy:** Náhlé změny tlaku a teploty, v důsledku nasání kapalného chladiva kompresorem, způsobují cyklické namáhání, čímž může dojít k ulomení částí ventilů, pístů, ojnic atd.

Poruchy ventilátoru venkovní jednotky

Ventilátor zajišťuje nucené proudění vzduchu přes výparník (v režimu topení) nebo kondenzátor (v režimu chlazení). Mezi jeho mechanické poruchy patří:

- **Opotřebením nebo koroze ložisek:** Projevuje se zvýšenou hlučností, vibracemi, případně až zadřením motoru ventilátoru.
- **Zaseknutí vrtule:** Může být způsobeno tvorbou a pádem ledu z výparníku do prostoru vrtule nebo vniknutím cizích předmětů.
- **Mechanické poškození vrtule/lopatek:** Nevyváženost, praskliny nebo ulomení lopatek vedou k vibracím a sníženému průtoku vzduchu.

Poruchy reverzního (čtyřcestného) ventilu

Reverzní ventil umožňuje změnu směru proudění chladiva, a tím přepínání mezi režimem topení a chlazení. Typicky se jedná o mosazný válec s vnitřním posuvným jezdcem, jehož poloha určuje propojení vstupních a výstupních portů. Přesun jezdce je řízen rozdílem tlaků na jeho čelních plochách, který je vytvářen malým elektromagnetickým ventilem. Tento ventil přepíná tlak z portu výtlačné strany kompresoru na jeden z konců jezdce.

- **Vada elektromagnetického ventilu:** U ventilu může selhat elektromagnetická cívka nebo může dojít k jeho ucpání či zaseknutí, což znemožní správné řízení hlavního jezdce.
- **Netěsnost reverzního ventilu:** Vnitřní netěsnosti jezdce vedou k netěsnosti mezi vysokotlakou a nízkotlakou stranou, což snižuje výkon a účinnost v obou režimech. Příčinou může být opotřebením těsnění nebo poškození dosedacích ploch.
- **Zaseknutí jezdce:** Jezdec se může zaseknout v některé z krajních poloh nebo i v mezipoloze v důsledku nečistot, opotřebením nebo deformace. TČ pak nelze přepnout do požadovaného režimu a pracuje nesprávně.

Poruchy oběhového čerpadla otopné soustavy

Oběhové čerpadlo zajišťuje cirkulaci teplotnosné látky (obvykle vody) v otopné soustavě (v sekundárním okruhu). Starší systémy často využívají čerpadla s jednofázovým asynchronním elektromotorem s možností skokové změny otáček (např. pomocí Dahlanderova vinutí). Novější systémy jsou osazovány elektronicky řízenými čerpadly s plynulou regulací otáček a vyšší účinností, často s motory s permanentními magnety.

- **Zatuhnutí:** Především u čerpadel s motory s permanentními magnety může docházet po delší době k zanášení rotoru. Magnetické pole totiž přitahuje feromagnetické částice (např. magnetit z koroze systému), které se usazují v mezeře mezi rotorem a statorem a brání jeho otáčení.
- **Zavření ventilů v okruhu:** Uzavírací armatury v otopném systému mohou být omylem uzavřeny, což znemožní cirkulaci.
- **Zavzdušnění okruhu:** Přítomností vzduchu v otopném tělese se snižuje průtok vody. Může vést ke zvýšené hlučnosti nebo úplnému zastavení cirkulace v některých částech systému.

Poruchy expanzního zařízení

Expanzní zařízení (termostatický expanzní ventil – TEV, elektronický expanzní ventil – EEV nebo kapilára) reguluje množství vstřikovaného chladiva do výparníku. Jeho správná funkce je zásadní pro ekonomický a spolehlivý provoz.

- **Špatně nastavené přehřátí** (u TEV a EEV): Přehřátí je rozdíl mezi teplotou par chladiva na výstupu z výparníku a teplotou nasycených par chladiva za daného tlaku.

- **Nízké přehřátí:** Při nízkém přehřátí chladiva na vstupu do kompresoru hrozí jeho nasátí v kapalném stavu. Prudká expanze v pracovním prostoru kompresoru způsobuje rázy, které vedou k jeho rychlému opotřebení.
- **Vysoké přehřátí:** Kapacita výparníku není zcela využita (část jeho plochy slouží pouze k ohřevu par), snižuje se jeho výkon, a tím i celkový výkon a účinnost tepelného čerpadla. Vyšší přehřátí par na sání kompresoru vede k taky k vyšší teplotě na výtlaku kompresoru.
- **Špatně umístěný senzor** (tykavka u TEV, teplotní čidlo u EEV): Pro správnou regulaci přehřátí je nezbytné, aby senzor co nejpřesněji snímal teplotu na výstupu z výparníku. Musí být řádně připevněn k sacímu potrubí a tepelně izolován od okolního prostředí.
- **Špatně umístěný tlakový odběr:** V blízkosti teplotního senzoru musí být správně nainstalován odběr tlaku (kolmo na potrubí). Chybná instalace vede k nesprávnému měření tlaku, a tím pádem k regulaci přehřátí.
- **Nečistoty a ucpání:** Tryska expanzního ventilu/kapilára se může ucpat nečistotami (kovové špony, produkty koroze, zbytky pájecí pasty) nebo ledem (pokud do systému pronikla vlhkost a teplota na expanzním zařízení klesla pod bod mrazu). Větší ventily bývají opatřeny sítkem. Ucpání vede k nedostatečnému průtoku chladiva do výparníku. Před expanzní zařízení bývají instalovány taky filtrdehydrátory, které jsou schopné zachytit mechanické nečistoty, vlhkost a neutralizovat kyseliny v chladivovém okruhu.

Úniky chladiva

Ačkoliv jsou chladivové okruhy tepelných čerpadel navrženy jako hermeticky uzavřené systémy, přesto může dojít k únikům chladiva. Většina běžně používaných chladiv pracuje při provozních teplotách s tlaky vyššími, než je atmosférický tlak. Výjimkou může být např. přírodní chladivo R600a, které je však pro svou hořlavost využíváno spíše v menších okruzích (ledničky, mrazáky, výčepní zařízení atp.).

U některých systémů je udáván normovaný únik chladiva (např. skrze hřídelové ucpávky kompresoru). Chladivo tedy uniká, i když je systém v naprostém pořádku, a je tedy nutné jej periodicky doplňovat.

- **Únik způsobený nedbalostí:** Vzniká nedostatečným dotažením servisních portů (čepiček ventilů) nebo spojů při instalaci či servisu.
- **Výrobní vada:** Úniky vznikají na komponentech nebo potrubí v důsledku chybného svaru nebo pájeného spoje.
- **Vnější mechanické poškození:** například proražení trubky, poškození výměníku
- **Prodření vlivem vibrací:** Kapilára nebo tenkostěnné trubky mohou vibrovat a prodřít se o jiné části zařízení.
- **Únavové poškození spojů:** vlivem vibrací a teplotních dilatací mohou časem prasknout. Použití vhodných konstrukčních prvků (pružné připojení, smyčky a ohyby propojovacích trubek, jejich fixace k rámu) může toto riziko snížit.
- **Koroze potrubí:** Především ocelové nebo hliníkové části chladivového okruhu mohou korodovat, zejména pokud jsou vystaveny agresivnímu prostředí nebo galvanické korozi.
- K mechanickému poškození může dojít v důsledku tvorby ledu u výparníků (především deskových).

5.2 Provozní poruchy

Kromě mechanických závad mohou tepelná čerpadla během svého provozu vykazovat řadu poruch, které přímo souvisí s jejich provozními podmínkami, údržbou a interakcí s okolním prostředím. Tyto poruchy mohou vést ke snížení účinnosti, zvýšení spotřeby energie, zkrácení

životnosti zařízení nebo dokonce k jeho úplnému selhání. Níže jsou popsány běžné provozní poruchy:

Zpoždění nebo nedostatečné odmrazení

U tepelných čerpadel typu vzduch-voda dochází při nízkých venkovních teplotách k tvorbě námrazy na výparníku. Pokud řídicí systém nezahájí odmrazovací cyklus včas nebo pokud je tento cyklus neefektivní (např. příliš krátký), dochází k hromadění námrazy. Námraza se může hromadit například i na ochranné mříži výměníku. To vede k výraznému snížení průtoku vzduchu přes výparník, zhoršení přestupu tepla a poklesu výkonu i účinnosti tepelného čerpadla. V krajních případech může dojít až k úplnému zablokování výparníku krustou ledu, která nedoléhá k výparníku a systém se jí tak není schopný odmrazením zbavit.

Zanesení výparníku

Výparník venkovní jednotky je náchylný k zanášení nečistotami z okolního prostředí (např. prach, listí, pyl). Tyto nečistoty ulpívají na lamelách výparníku, čímž snižují přestup tepla a omezují průtok vzduchu. Výparníky, navržené s cílem maximalizovat součinitel přestupu tepla, často využívají hustěji uspořádané a složitěji tvarované lamely. Tato konstrukční řešení v čistém stavu sice zvyšují účinnost, ale zároveň se tím urychluje zanášení a znesnadňuje se čištění.

Zanesení systému odvodu kondenzátu

Za příhodných podmínek dochází při provozu tepelného čerpadla na výparníku venkovní jednotky ke kondenzaci vzdušné vlhkosti. Vlivem přítomnosti prachu, pylu a jiných nečistot, a také v důsledku růstu mikroorganismů (např. bakterií tvořících biofilm, někdy označovaný jako „zooglea“ [24]) v kondenzátu, může dojít k zanesení odtokových cest. Nedostatečný odvod kondenzátu může vést k jeho hromadění ve spodní vaně, přetékání, korozi komponent a v zimním období k jeho zamrznutí.

Zanesení filtru na straně otopné soustavy

Každá otopná soustava, do které je tepelné čerpadlo integrováno, by měla být vybavena filtrem pro zachycování mechanických nečistot. Tyto nečistoty mohou zahrnovat produkty koroze, zbytky těsnících materiálů nebo nečistoty vnesené do systému při instalaci či údržbě. Postupné zanášení filtru vede ke zvýšení jeho tlakové ztráty, snížení průtoku teplotnosné látky přes kondenzátor tepelného čerpadla, zvýšení teplotního spádu, a tedy ke snížení účinnosti TČ. Velký problém způsobuje snížený průtok při odmrazování/chlazení, kdy může dojít k lokálnímu vzniku ledu a postupné deformaci výměníku, což může vést k jeho destrukci. Může dojít k porušení svaru mezi stranou vody a chladiva a vysoký tlak chladiva, který není schopný přetlakový ventil dostatečně rychle odpustit může poškodit i ostatní části otopného systému.

Cyklování tepelného čerpadla (short-cycling)

Tato porucha označuje příliš časté spínání kompresoru. To může být způsobeno například předimenzováním tepelného čerpadla, kdy je jeho výkon natolik vysoký, že otopná soustava nedokáže teplo odebrat (buď nedokáže předávat dostatečné množství tepla do vytápěného prostoru nebo je nedostatečný průtok teplotnosné látky). Problém lze částečně eliminovat přidáním akumulární (taktovací) nádoby, která zvýší objem, a tedy i tepelnou kapacitu systému. Částečně to může souviset i s nesprávným nastavením systému (nastavení hystereze) nebo nevhodným umístěním čidel. Short cycling může být i projevem jiných poruch, kdy je TČ vypínáno některou z jeho ochran. Cyklování vede ke snížení účinnosti systému, zvýšení opotřebení, a tedy ke zkrácení životnosti komponent.

5.3 Chyby při instalaci

Problémy s tepelnými čerpadly může přinést již samotná instalace nebo jejich dimenzování. Tyto problémy z velké části vyřešil příchod tepelných čerpadel s proměnnými otáčkami kompresoru, které jsou díky tomu schopny regulovat i výkon a pokrýt tak širokou škálu výkonu za různých venkovních teplot.

Chybné umístění nebo instalace venkovní jednotky

Nedostatečná vzdálenost venkovní jednotky od okolních stěn a jiných objektů může snížit průtok vzduchu. V potaz je zapotřebí brát taky ostatní jednotky, protože může dojít k vzájemnému ovlivnění nebo zkratu proudění vzduchu. Chybou je taky instalace jednotky do uzavřených prostor (zasklené balkony).

Důležité je nejen proudění vzduchu, ale taky přístup pro čištění nebo servis a taky odvod kondenzátu. V mrazivých obdobích se může zmrzlý kondenzát hromadit a tím neúměrně zatížit konstrukci, na které je TČ nainstalované, nebo vytvořit kluzké plochy, nebezpečné pro pohyb osob. Pokud je v okolí jednotky vegetace, je vhodné ji pravidelně udržovat. Jednotka musí být usazena vodorovně (jiný sklon by ovlivnil odvod kondenzátu, hladinu oleje v kompresoru a jeho mazání, distribuci chladiva).

Chyby v propojení chladivového okruhu

Pokud je tepelné čerpadlo typu split, tzn. že venkovní a vnitřní jednotka je propojena chladivovým potrubím, je nutné dodržet maximální přípustnou délku potrubí, jeho průměry i obecné zásady pro chladivová vedení (spád, sifony, metody spojení). Pokud je délka potrubí vyšší, než jakou výrobce udává jako přednaplněnou chladivem, je nutné podle pokynů výrobce doplnit chladivo, případně i olej. Neodbornou instalací může dojít k deformaci trubek v jejich ohybech nebo k netěsným spojům v důsledku špatného provedení procesu pájení nebo kalíškového spoje (nesprávné dotažení, poškozené dosedací plochy spoje nebo nesouosost).

Chyby při plnění systému

U chladivových okruhů je před jejich naplněním chladivem nutné provést tlakové zkoušky a pak systém pečlivě vyvacuovat. Tím se odstraní většina nezkondenzovatelných plynů a vlhkost, která by jinak mohla vést k reakcím s olejem, následné tvorbě kyselin a korozi, až k poškození izolačního stavu kompresoru.

Chyby u elektrického propojení jednotek

Nedostatečné utažení svorkovnic, nevhodné zvolení průřezu vodičů (obzvláště, pokud je veden izolací) nebo typu kabelu a jeho nedostatečná ochrana proti vnějším vlivům a UV záření. Je nutné systém osadit jističem se správnou hodnotou jmenovitého proudu a charakteristikou jističe podle výrobce. Nesprávné rozfázování zátěže domu může vést k vzniku přepětí nebo podpětí. U trojfázových tepelných čerpadel je nutné dodržet správný sled fází.

Chyba může nastat i v připojení do stávajícího otopného systému. To je nutné vhodně hydraulicky vyřešit a vyvážit. Pokud otopný systém obsahuje další zdroje tepla, je nutné tyto zdroje sladit a účelně řídit.

5.4 Elektrické poruchy

Moderní tepelná čerpadla obsahují stále sofistikovanější elektronické komponenty a řídicí systémy. Jednoduché elektromechanické stykače jsou často nahrazovány frekvenčními měniči pro plynulou regulaci otáček kompresorů a ventilátorů a komplexními řídicími deskami

s mikroprocesory s internetovou konektivitou. Tato pokročilá elektronika sice přináší vyšší účinnost a lepší možnosti regulace, ale zároveň představuje další potenciální zdroj poruch.

Spálený motor ventilátoru/kompresoru

Příčinou může být opotřebení nebo zadření ložisek, které vede k přetížení motoru. Dále může dojít k poškození vinutí vlivem přehřátí, zkratu nebo korozi. Motory bývají vybaveny teplotními pojistkami, které ale nejsou konstruovány na opakované odpínání.

Selhání kondenzátorů

Kondenzátory jsou klíčovou součástí pro provoz a rozběh jednofázových elektromotorů. Běhové kondenzátory, připojené k motoru po celou dobu, tvoří fázový posun pomocného vinutí, a tím vytváří rotující magnetické pole. Rozběhové kondenzátory zvětšují záběrný moment a jsou připojeny pouze při rozběhu. Snížená kapacita kondenzátorů vede k nižší účinnosti pohonu, sníženému rozběhovému momentu nebo neschopnosti se rozpohybovat (případně se mohou rozpohybovat v opačném směru). Kondenzátory jsou také součástí spínaných zdrojů a frekvenčních měničů, kde vyhlazují usměrněné napětí a jejich poškození vede k propadům napětí a nesprávné funkci těchto zařízení.

Poruchy topných těles

Kompresory, vany pro odvod kondenzátu i některé výparníky (běžné spíše u mrazíren) jsou vybaveny topnými tělesy. Při porušení izolace může dojít od snížení izolačního odporu (výpadek proudového chrániče) až po zkrat mezi kostrou nebo jinou fází. Vibracemi nebo opakovanými dilatacemi může dojít k mechanickému poškození drátů topných elementů, což přeruší elektrický obvod. Veškeré vodiče by měly být ochráněny proti vibracím (průchody skrze plechové části opatřeny průchodkami, chráničky, fixace, zajištění konektorů silikonem).

Ostatní elektrické poruchy

Vlivem vibrací, tepelných dilatací nebo přímo ve výrobě mohou vzniknout studené spoje vznikající na deskách plošných spojů (pájky jsou křehké). Vodiče, jejich izolace a spoje mohou vlivem povětrnostních vlivů degradovat a korodovat. Tepelná čerpadla je nutné správně jistit a blokovat jejich chod mimo dobu povolenou tarifem dodavatele elektřiny. Komunikační linky, kterými spolu komunikují řídicí desky, musí být stíněné a odolné vůči elektromagnetickému rušení. K poruše může dojít u teplotních, tlakových, proudových, průtokových a dalších čidel, která pak mohou nesprávným měřením ovlivnit chování systému a řídicí jednotka musí celý systém odstavit.

Následující tabulka 5.1 ukazuje seznam poruch, které jsou deklarovány na řídicí jednotce tepelného čerpadla. Díky ní je možné určit, jaké poruchy dokáže identifikovat.

Tab. 5.1: Seznam poruch dle štítku tepelného čerpadla.

name of malfunction	error code	reasons
Stop for anti-freezing protection of indoor-unit	E2	refrigerant leakage; indoor unit air flow blocked up; filter duty
Stop for exhaust protection	E4	less refrigerant; capillary blocked up; ambient temperature is abominable
Stop for over current protection	E5	outdoor unit over current; ambient temperature is abominable
Stop for communication malfunction	E6	communication line failure; main PCB failure; interfere source; connect line wrong
Stop for compressor overload protection	H3	compressor shell over heat; less refrigerant; capillary blocked up
Overload protection	H4	ambient temperature is abominable; heat exchanger blocked up
Stop for IPM module protection	H5	IPM module over heat; over current
Indoor ambient temperature sensor malfunction	F1	terminal connect not reliable; temperature sensor malfunction
Indoor tube temperature sensor malfunction	F2	terminal connect not reliable; temperature sensor malfunction
Outdoor ambient temperature sensor malfunction	F3	terminal connect not reliable; temperature sensor malfunction
Outdoor tube temperature sensor malfunction	F4	terminal connect not reliable; temperature sensor malfunction
Outdoor exhaust temperature sensor malfunction	F5	terminal connect not reliable; temperature sensor malfunction
Automatic defrosting	H1	H1 isn't error code; it's normal operation (heat-pump only)
Stop for low voltage protection	PL	DC voltage is too low
Stop for high voltage protection	PH	DC voltage is too high
Jumper cap malfunction protection	C5	The jumper misfit the main board
No feedback of indoor fan motor	H6	indoor fan is abnormal
Stop for ID and OD doesn't match	LP	The indoor unit and outdoor unit doesn't match
Disconnection of the exhaust temperature sensor	U8	terminal connect not reliable; temperature sensor malfunction

6 MĚŘENÉ PORUCHY

Následující kapitola popisuje mnou měřené poruchy tepelného čerpadla. Okamžiky vzniku a zániku poruch byly časově zaznamenány (viz tabulka 6.1) a následně byly do tréninkových dat připsány při zpracování dat. U vybraných poruch je popsán způsob jejich simulace a je popsán jejich vliv na chování systému a zaznamenané parametry. Je nutné mít na paměti, že velká část poruch se projevuje pouze, pokud je tepelné čerpadlo v provozu, a není je tudíž možné z měřených dat odhalit, pokud je tepelné čerpadlo v klidu. Simulována byla vždy jen jedna porucha. Pozornost byla zaměřena na poruchy venkovní jednotky, které souvisí s výkonem výparníku. Konkrétně na zakrytí výparníku, odpojení napájení ventilátoru a změnu nastaveného přehřátí chladiva, které byly naměřeny vždy minimálně 2x, aby pak mohla být jedna instance použita pro trénování a druhá pro evaluaci modelu neuronové sítě.

Dalšími simulovanými poruchami bylo snížení průtoku otopným systémem a úplné otevření expanzního ventilu.

Po experimentech bylo do datasetu zaznačeny taky období, kdy došlo k zapnutí plynového kotle, režimu chlazení z důvodu vysoké vnitřní teploty, neplánovanému výpadku záznamu wattmetru, výpadku čidla kontroléru expanzního ventilu a výpadku záznamu hodnot.

Tab. 6.1: Seznam simulovaných poruch.

ID	začátek	konec	typ	popis
0	20.2.2025 23:37:00	21.2.2025 1:38:00	10	vytápění plynovým kotlem
1	3.3.2025 10:22:15	3.3.2025 11:25:00	1	zakrytí výparníku
2	3.3.2025 13:22:42	3.3.2025 14:15:20	1	zakrytí výparníku
3	7.3.2025 17:58:57	7.3.2025 23:48:00	2	odpojení napájení ventilátoru
4	8.3.2025 20:20:52	9.3.2025 10:00:00	1	zakrytí výparníku
5	15.3.2025 16:40:30	17.3.2025 15:33:00	3	změna nastavení přehřátí na 6 K
6	23.3.2025 20:10:14	24.3.2025 12:23:10	3	změna nastavení přehřátí na 6 K
7	4.4.2025 17:04:16	4.4.2025 17:06:35	4	chlazení
8	14.4.2025 12:02:00	14.4.2025 13:58:00	5	výpadek wattmetru celkového příkonu
9	17.4.2025 15:47:10	17.4.2025 15:51:16	4	chlazení
10	18.4.2025 22:39:54	24.4.2025 20:43:20	3	změna nastavení přehřátí na 6 K
11	27.4.2025 1:28:10	27.4.2025 1:42:30	6	výpadek záznamu
12	27.4.2025 1:43:00	28.4.2025 1:53:55	7	výpadek čidla kontroléru expanzního ventilu
13	5.5.2025 13:55:13	5.5.2025 16:24:05	2	odpojení napájení ventilátoru
14	7.5.2025 20:59:01	7.5.2025 23:33:19	1	zakrytí výparníku
15	9.5.2025 19:33:53	9.5.2025 21:38:45	8	snížení průtoku otopným systémem
16	12.5.2025 22:45:20	13.5.2025 0:31:27	3	změna nastavení přehřátí na 8 K
17	13.5.2025 18:34:34	13.5.2025 20:44:48	9	expanzní ventil zcela otevřen
18	16.5.2025 0:02:22	16.5.2025 13:00:55	3	změna přehřátí na 6 K
19	18.5.2025 0:37:10	18.5.2025 1:22:06	1	zakrytí výparníku

6.1 Zakrytí výparníku vnější jednotky

První simulovanou poruchou bylo zanesení výměníku vnější jednotky. Rychlost zanášení zásadně závisí na umístění jednotky a jejím okolí, dále také na konstrukci výměníku, průtoku vzduchu, povrchové úpravě. K zanesení může docházet postupně, ale také skokově, pokud se na výměník přisaje větší předmět.


Porucha byla simulována obložením výměníku jednotky igelitem. Výměník byl zakryt již před startem jednotky. Venkovní teplota se během testu pohybovala kolem 5 °C. Po prvním startu jednotka běžně po krocích zvyšovala otáčky kompresoru, a rostl tak celkový příkon.

Zajímavá byla teplota kompresoru, která byla neobvykle nízká. Teploměr byl nejspíš významně chlazen okolním prouděním, které mohlo být umocněno tím, že byl zakrytý výměník, a vzduch si tak hledal jinou cestu. Přehřátí chladiva na výparníku bylo podle teplot nízké a do kompresoru se nejspíš nasávalo nevypařené chladivo.

Po necelé půlhodině běhu došlo k prvnímu odmrazení. Bylo zvláštní tím, že po vypnutí kompresoru teplota výparníku nedosáhla nuly, jako u běžných odmrazení, ale ještě před startem kompresoru dosáhla 3 °C. To indikuje, že výparník nebyl ve skutečnosti pokryt námrazou. Po opětovném zapnutí byl výtlak kompresoru zase dlouho na nízké teplotě a přehřátí bylo nulové. Měřitelné přehřátí se objevilo až po 20 minutách běhu a poté začala teplota na výtlaku z kompresoru růst až k 80 °C. Následně došlo k odstavení kompresoru.

Můžeme si všimnout, že podobné vypnutí vidíme v grafu 6.1 i podruhé a teplota kompresoru je v tomto okamžiku podobná. I délka opětovného zapnutí je stejná. Lze tedy předpokládat, že se jednalo o tepelnou ochranu kompresoru. Lze také vidět, že má řídicí systém nějakou ochranu, protože potom, co kompresor najel na vyšší frekvenci a následně pokračoval v chodu na nižší frekvenci (příkon zhruba 550 W). V čase od 21:30 do 22:15 běžela jednotka na snížený výkon a byla operačně stabilní. Rozdíl teploty venkovní a sací byl větší než obvykle, přesto byl ventilátor netěsnostmi a rozháněním vzduchu uvnitř jednotky schopen předávat dostatek tepla.

Poté začala jednotka zvyšovat výkon, což vedlo k významnému poklesu teploty výparníku. Změna byla postupná a vstřikovací ventil neměl problém udržet stabilní přehřátí. Poté nastal další defrost. Po 25 minutách následného běhu na plný výkon opět došlo k přehřátí kompresoru.



Graf 6.1: Ukázka poruchy zanesení výměníku vnější jednotky.

6.2 Porucha ventilátoru

Porucha byla nasimulována odpojením ventilátoru. Zde je nutné připomenout, že je jednotka umístěna v závětrří, tzn. že vítr hraje minimální roli.


Na začátku byl čtyřcestný ventil v poloze pro chlazení (výchozí stav po připojení k napájení). A to z toho důvodu, že před odpojením ventilátoru bylo nutné vypnout napájení, aby bylo bezpečné ventilátor odpojit. Venkovní teplota v průběhu zobrazeného záznamu (graf 6.2), klesla z 12 °C na 5 °C. Po spuštění kompresor postupně zvyšoval otáčky. Kontrolér na začátku udržoval přehřátí. Teplota výparníku rychle klesla až k -25 °C. Poté začala teplota

na výtlaku z kompresoru prudce růst a po dosažení 95 °C byl kompresor odstaven kvůli přehřátí. Odstavení kompresoru způsobilo rychlé ochlazení, protože se přes výtlakovou trubici vracelo ochlazené chladivo. Příčinou mohlo být to, že kompresor nemá zpětný ventil anebo je tento ventil nefunkční.

Po krátké pauze kompresor opět naběhl na vyšší frekvenci a pak běžel na nižší frekvenci. Po 40 minutách provozu na nízký výkon se teplota výparníku ustálila na -15 °C a následovalo odmrazení.

Po odmrazení naběhl kompresor na vysoký výkon a po 30 minutách provozu byl opět odstaven kvůli přehřátí (teplota na výtlaku nad 90 °C). Pokus o start kompresoru následně 4× selhal kvůli přehřátí modulu elektroniky frekvenčního měniče. Chladicí žebra jsou umístěna v blízkosti ventilátoru, díky němuž jsou i chlazená. Pokud ventilátor nefunguje, chlazení je nedostatečné.

Poté opět jednotka běžela v režimu sníženého výkonu. Po necelých 50 minutách následovalo odmrazení a následně kompresor dosáhl plného výkonu. K dalšímu přehřátí kompresoru již nedošlo, protože byla simulace poruchy ukončena.




Graf 6.2: Ukázka chování při odpojení ventilátoru.

6.3 Změna přehřátí chladiva na výparníku

Další možnou poruchou je změna přehřátí chladiva ve výparníku. Kontrolér expanzního ventilu byl přenastaven na 6 K přehřátí.


Na grafu 6.3 je zřetelná změna nastavení přehřátí (zhruba v čase 22:45). Po změně začne stoupat teplota na výtlaku kompresoru, kvůli které jsou pak postupně snižovány otáčky kompresoru. Po více jak hodině běhu od změny přehřátí dojde k odstavení kompresoru kvůli jeho přehřátí.



Graf 6.3: Chování tepelného čerpadla po změně přehřátí.

6.4 Výpadek čidla kontroléru expanzního ventilu


Tato porucha nebyla vyvolána záměrně a identifikována byla až z naměřených dat. Chování systému bylo velmi zvláštní (viz graf 6.4). Pulzní expanzní ventil, který je kontrolérem ovládan, nebyl spínán v pravidelných šesti sekundových intervalech, jako je běžné za normálního provozu. Ventil byl několik minut zcela uzavřen, což vedlo k vystoupaní teploty na sání vysoko nad teplotu venkovního vzduchu (teplo ve skříni tepelného čerpadla). Stav, při kterém by byl expanzní ventil zcela uzavřen dlouhou dobu, by mohl vést k zadření kompresoru, nejdříve by však nejspíš byla aktivována tepelná ochrana kompresoru. Otevření ventilu taky trvalo mnohem déle a lze vidět nulové přehřátí.



Graf 6.4: Chování tepelného čerpadla při výpadku čidla kontroléru expanzního ventilu.

6.5 Snížení průtoku vody otopným systémem

Porucha byla vyvolána snížením výkonu oběhového čerpadla a uzavřením některých otopných těles. Po 20 minutách provozu s omezeným průtokem (graf 6.5) začal kompresor snižovat své otáčky z důvodu vysoké teploty. Po více jak hodině provozu došlo k přehřátí kompresoru.




Graf 6.5: Chování tepelného čerpadla při snížení průtoku vody otopným systémem.

6.6 Expanzní ventil zaseknut v poloze otevřeno

Další poruchou bylo otevření expanzního ventilu naplno. Toho bylo dosaženo překlenutím spínacího členu kontroléru. Teploty na vstupu a výstupu výparníku se rychle téměř vyrovnaly. Velice rychle se propadla i teplota kompresoru, což značí přítomnost kapaliny na jeho sání. Z grafu 6.6 je také očividný pokles výkonu i příkonu. Zajímavé je i to, jak se změnil průběh příkonu, který fluktuuje mnohem méně, než je obvyklé.

Propad výkonu však není zásadní. Expanzní ventil má i v otevřeném stavu značnou tlakovou ztrátu, která je zvýšená o tlakovou ztrátu ventilu, který je na venkovní jednotce instalovaný proto, aby v ní bylo možné chladivo uzavřít (a mohla tak být naplněna chladivem přímo od výrobce). Při instalaci a ladění byl ventil otevřen tak, aby expanzní ventil pracoval v optimálním procentu otevření (téměř 100 % při nejvyšších otáčkách, vysoké venkovní teplotě a nízké teplotě na kondenzátoru).



Graf 6.6: Chování tepelného čerpadla v případě, kdy se expanzní ventil zaseknul v poloze otevřeno.

„The only source of knowledge is experience.“ Albert Einstein

7 SBĚR A ÚPRAVA DAT

Základním kamenem pro vývoj neuronových sítí jsou kvalitní a reprezentativní data. Kapitola popisuje sběr a následnou úpravu získaných dat, které poté sloužily k trénování a evaluaci modelů neuronových sítí.

Nezbytnost kvalitních dat pro aplikaci neuronové sítě či jiného algoritmu strojového učení je vystižena principem GIGO (Garbage In, Garbage Out). Tento princip říká, že ani ten nejsložitější model neuronové sítě nemůže poskytovat smysluplné výsledky, pokud pracuje s daty chybnými, nerepresentativními, nekompletními nebo s daty zatíženými nadměrným šumem.

„The goal is to transform data into information, and information into insight“ Carly Fiorina

7.1 Způsob získávání dat

Volba metody ovlivňuje kvalitu, kvantitu a relevanci získaných informací pro následnou analýzu a trénování neuronových sítí. Existuje několik základních přístupů sběru dat:

a) Simulace

Tato metoda spočívá ve vytvoření matematického modelu tepelného čerpadla a jeho provozních stavů. Hlavní výhodou simulace je možnost rychlého generování velkého objemu dat, včetně scénářů, které by v reálném provozu byly obtížně dosažitelné, nebo by bylo nutné využít klimatické komory. Lze tak snadno pokrýt širokou škálu provozních podmínek. Nevýhodou je ale značná náročnost na vytvoření dostatečně přesného modelu, který by věrně odrážel komplexní chování reálného zařízení a zohlednil všechny relevantní proměnné a jejich interakce.

b) Přímé měření na reálném zařízení

Sběr dat přímo z tepelného čerpadla představuje nejvěrnější způsob získání relevantních informací. Tento přístup lze realizovat dvěma hlavními způsoby: využitím interních senzorů TČ nebo instalací externích senzorů a dataloggerů.

- **Využití interních senzorů tepelného čerpadla**

Moderní tepelná čerpadla mohou již být vybavena řadou senzorů, jejichž data lze, pokud to výrobce a řídicí systém umožňují, přímo vyčítat. Výhodou je, že senzory jsou již integrovány a není tedy nutné dělat do jednotky žádné zásahy.

- **Instalace externích senzorů a dataloggerů**

Pokud interní senzory nejsou dostupné nebo nepokrývají všechny potřebné veličiny, je možné systém doplnit o vlastní měřicí techniku. Dataloggery jsou specializovaná zařízení určená pro záznam dat z různých typů senzorů. Umožňují sběr dat z více kanálů současně, přičemž dle konfigurace mohou zaznamenávat napěťové signály, pulzní vstupy či komunikovat s digitálními senzory [25]. Tento přístup poskytuje větší flexibilitu ve výběru měřených veličin a přesnosti měření, avšak je náročnější na implementaci.

c) Sběr dat z online platform

Někteří výrobci tepelných čerpadel [26] nebo provozovatelé energetických systémů umožňují online přístup k provozním datům. Tento přístup, někdy označovaný jako „data scraping“ (pokud data nejsou poskytována strukturovaně přes API), umožňuje získat data z celé flotily

zařízení. Výhodou je potenciálně velký objem dat z reálného provozu za různých podmínek. Nevýhodou může být variabilita v kvalitě a formátu dat, nutnost jejich dodatečného čištění a harmonizace a také závislost na dostupnosti a podmínkách poskytovatele dat.

d) Využití databází dat

Alternativním či doplňkovým přístupem ke sběru dat je využití již existujících, veřejně dostupných databází. Příkladem je např. databáze spravovaná U. S. Department of Energy [27]. Výhodou je především okamžitý přístup k často rozsáhlým souborům reálných provozních dat, což snižuje časovou i finanční náročnost vlastního sběru dat. Takové databáze mohou obsahovat data z různých typů tepelných čerpadel provozovaných v odlišných klimatických podmínkách a po delší časové období, což potenciálně umožňuje větší generalizaci výsledků.

Pro tuto práci byla zvolena metoda přímého měření s využitím externích senzorů. Sensory byly připojeny na mikrokontrolér Arduino Mega, který byl naprogramován tak, aby vyčítal hodnoty ze senzorů. Získaná data byla následně přenášena sériovou linkou do sběrného počítače, ve kterém se ukládala do souboru. Tento počítač byl spravován prostřednictvím vzdálené plochy. Data se ukládala v desetiminutových intervalech, zálohována byla na cloudovém úložišti Google drive, které sloužilo také k přenosu dat na počítač, ve kterém byla data zpracovávána.


Mezi instalované externí senzory patří: teploměry, wattmetry, napěťový transformátor a optický oddělovač (viz obrázek 7.1).

- **Teploměry DS18B20:** Bylo použito 6 teploměrů, které zaznamenávaly venkovní teplotu, teplotu zpátečky z otopného systému, teplotu na výstupu do otopného systému, teplotu na výtlaku kompresoru, teplotu na vstupu výparníku a teplotu na výstupu z výparníku. K trubkám, ze kterých odečítaly hodnoty, byly připevněny stahovacími páskami a následně byly obaleny izolací. Měřicí rozsah byl $-55\text{ }^{\circ}\text{C}$ až $125\text{ }^{\circ}\text{C}$, přesnost měření je $\pm 0.5\text{ }^{\circ}\text{C}$ v rozsahu $-10\text{ }^{\circ}\text{C}$ až $85\text{ }^{\circ}\text{C}$. [28] Komunikaci s mikrokontrolérem zajišťuje sběrnice OneWire. Měření bylo spolehlivé, pokud ale přeci jen došlo k problému s přenosem dat, bylo to vyřešeno zopakováním pokusu o vyčtení, což pokaždé problém vyřešilo.
- **Teploměr NTC:** Řídicí systém TČ používá NTC termistory. Pro měření teploty v obytné místnosti, která je poměrně vzdálená od kotelny, nebylo možné využít další kontrolní čidlo (nebylo možné k němu dovést kabel). Proto bylo nutné využít přímo NTC teploměr TČ. Země Arduina a řídicí desky byly spojeny. NTC teploměr byl připojen paralelně a jeho napětí bylo odečítáno přes analogový vstup Arduina, jehož rozlišení je 10 bitů. Hodnota napětí byla v každém časovém kroku změřena několikrát a následně byla vybrána nejčastější hodnota (hodnota periodicky kolísala nejspíš kvůli interním procesům logiky řídicí jednotky). Naměřenou hodnotu napětí pak bylo nutné přepočítat na teplotu, k čemuž byly použity hodnoty teploty na displeji řídicí jednotky TČ).
- **Wattmetry PZEM004T v30:** Wattmetry byly použity pro měření příkonu celého tepelného čerpadla a příkonu ventilátoru [29].
- **Optický oddělovač:** Byl využit k detekci přítomnosti napájení síťovým napětím elektromagnetického ventilu čtyřcestného ventilu.
- **Napěťový transformátor s filtrem:** Nejsložitější bylo měření frekvence kompresoru. Použití optického oddělovače nefungovalo. A to ani po jeho úpravách, které spočívaly v odstranění vyhlazovacího kondenzátoru a následné výměně můstkového usměrňovače za jednoduchou diodu. Dalším pokusem bylo použití proudového transformátoru, který by neinvazivně měřil proud jedné fáze kompresoru, ale indukované napětí bylo pro měření příliš nízké. Výsledným řešením je použití oddělovacího transformátoru, který byl vyroben z nabíjecího adaptéru. Jeho primární strana byla připojena paralelně ke dvěma fázím

napájejících vinutí kompresoru. Sekundární vinutí mělo pouze nízký počet závitů, aby bylo napětí nízké. Protože měří Arduino na svých analogových vstupech pouze hodnoty 0 až 5 V, bylo nutné připojit sekundární vinutí transformátoru na 3,3 V, které je na desce k dispozici a druhé na pin, který umožňuje analogový vstup.

Výstup byl ještě opatřen low pass filtrem, který byl vytvořen z rezistoru a filmového kondenzátoru, aby odfiltroval spínací frekvenci měniče (zhruba 12 kHz).

Algoritmus pro měření frekvence zaznamenal několik stovek milisekund, pak spočítal počet průběhů a z toho byla následně vypočtena frekvence.



Obr. 7.1: Blokové schéma zapojení.

7.2 Problémy se sběrem dat

Během procesu sběru dat se vyskytlo několik problémů, které ovlivnily kontinuitu, v některých případech i validitu, zaznamenávaných dat.

V průběhu měření několikrát došlo k „zamrznutí“ programu, který zaznamenával data z Arduino. Přesná příčina nebyla objevena. Řešením byl manuální restart programu. Předcházet by se tomu dalo přidáním watchdogu, který by dohlížel na to, aby zaznamenávací program běžel.

Další komplikací byly automatické aktualizace Windows update na sběrném počítači. I přes snahu tyto aktualizace pozastavit, se systém několikrát restartoval, čímž vznikly mezery v kontinuitě měření. Je proto nutné, aby měl program, který zaznamenává naměřené hodnoty z Arduino, zapnuté automatické spuštění.

K přerušení měření dat došlo i v důsledku výpadku dodávky elektřiny. To zapříčinilo vypnutí počítače, který se pak automaticky nespustil, a tudíž nefungovalo ani Arduino, které je

z počítače napájeno. Protože je NTC teploměr připojen paralelně k Arduino, došlo k ovlivnění hodnot napětí – měřená teplota byla vyšší než ve skutečnosti a tepelné čerpadlo začalo klimatizovat. Proto je vhodné mít aktivní automatické spouštění počítače.

Naměřené hodnoty veličin mohou být zkresleny i působením vnějších vlivů. Příkladem může být ovlivnění hodnoty teploty sání teplem z cívek elektromagnetů a kompresoru.

„You can't manage what you can't measure.“ Peter Drucker

7.3 Měřená data


Během provozu TČ byly měřeny následující parametry:

- venkovní teplota (graf 7.1),
- teplota vnitřního čidla,
- teplota zpátečky otopného systému,
- teplota výstupu do otopného systému (graf 7.2),
- teplota na vstupu do výparníku,
- teplota na výstupu z výparníku (obr. 7.3),
- teplota výtlaku kompresoru,
- celkový příkon,
- příkon ventilátoru,
- frekvence kompresoru,
- poloha reverzního ventilu.


Data byla sbírána s časovým krokem 6 sekund po dobu více než 90 dní. Nakonec bylo sesbíráno 1 239 713 záznamů. Až na pár výjimek, kdy došlo k výpadku programu, elektřiny nebo bylo nutné jednotku odstavit kvůli nějaké úpravě, jsou data nepřetržitá. Teplota vnitřního čidla v mnoha případech neodpovídala skutečné teplotě v místnosti, ale byla uměle snížena. To je nutné z toho důvodu, aby bylo možné řídit výkon tepelného čerpadla (prostředek pro ovládání cílové teploty řídicí jednotky nebyl k dispozici). Poloha reverzního ventilu 0 označuje režim topení. V následující tabulce (tab. 7.1) jsou uvedeny vybrané parametry naměřených dat. Dataset je k dispozici v příloze práce (příloha 1).

Tab. 7.1: Charakteristika zaznamenaných dat.


název	hodnota
počet dat	1 239 713 záznamů
časový krok	~6 sekund
celková délka záznamu	~92 dnů
doba vypnutí	48 dnů
doba běhu kompresoru	44 dnů
počet zapnutí kompresoru	400
počet zapnutí kompresoru za den	4,4
celková spotřeba elektřiny	1,1MWh
počet odmrazení	143
průměrná doba odmrazení	3,8 min



Graf 7.1: Histogram četnosti záznamů podle venkovní teploty.




Graf 7.2: Histogram teplotního spádu topné vody za běhu tepelného čerpadla.



Graf 7.3: Histogram rozdílu teploty na vstupu a výstupu z výparníku (přibližně přehřátí chladiva).


Graf 7.4 zobrazuje, kolik času strávilo tepelné čerpadlo v jednotlivých režimech. Do času odmrazení je započítána i pauza před a po odmrazení. Významný je taky sloupec, kdy bylo tepelné čerpadlo odpojeno. V datasetu jsou řádky příslušných stavů označeny následovně:

- 0: neběží,
- 1: běží,
- 2: pauza před odmrazením,
- 3: odmrazení,
- 4: pauza po odmrazení,
- 5: bez proudu.




Graf 7.4: Časové rozdělení stavů tepelného čerpadla.

Následující graf 7.5 ukazuje, při jaké napájecí frekvenci kompresor nejčastěji běžel. Lze vidět, že regulace není v celém rozsahu spojitá, ale v rozsahu 100 až 200 Hz je vybráno několik frekvencí, při kterých je kompresor provozován. Vysvětleno to může být tím, že jsou vybrány takové frekvence, při kterých nedochází k rezonanci s ostatními komponenty jednotky.




Graf 7.5: Histogram počtu záznamů rozdělený podle frekvence napájení kompresoru.

Graf 7.6 zobrazuje, jak dlouhé byly jednotlivé běhy kompresoru. V datech lze jednoznačně vidět zapínání kompresoru pro potřeby odmazování (0–5 minut).



Graf 7.6: Četnost sekvencí běhu kompresoru různých délek.

V grafu 7.7 jde vidět závislost procenta času, kdy běží kompresor. V grafu se jednoznačně promítají víkendy, kdy tepelné zisky z provozu domácnosti významně snížily potřebu vytápění a taky teplý začátek května.



Graf 7.7: Procentuální doba běhu kompresoru během jednotlivých dnů záznamu.

7.4 Příprava dat a feature engineering

Před aplikací do neuronové sítě bylo nutné data připravit. Tato příprava spočívala v následujících krocích:

- **Doplnění:** Chybějící hodnoty byly nahrazeny průměrem předchozí a následující hodnoty.
- **Úprava odchylek:** Tato úprava se týkala hodnot naměřených wattmetru při rozběhu ventilátoru, jehož rozběhový proud překročil měřicí rozsah wattmetru – velmi vysoké hodnoty byly nahrazeny následující hodnotou příkonu.
- **Přepočet z napětí na teplotu:** Naměřené napětí NTC teploměru bylo nutné přepočítat na teplotu.
- **Označení poruch:** Při poruchovém stavu TČ byl zaznamenán časový rozsah poruchy, a proto musely být jednotlivé záznamy (řádky datasetu) označeny číslem poruchy.
- **(Oversampling):** Další možnou úpravou je oversampling, který spočívá v zopakování datových úseků, které se v datasetu nevyskytují oproti ostatním dostatečně často. Vzhledem k povaze mých dat nebylo nutné tuto úpravu použít.
- **Feature engineering:** viz níže.
- **Normalizace dat:** Normalizace spočívá v transformaci hodnot jednotlivých proměnných tak, aby se nacházely ve srovnatelném (obvykle menším) číselném rozsahu, protože dataset může obsahovat různé veličiny (watty, stupně celsia, binární stavy), jejichž rozsahy hodnot se mohou i řádově lišit. Tím je zajištěn přibližně stejný vliv všech vstupních parametrů při počátku trénování sítě, než si sama síť určí jejich důležitost. Tato funkce je již automatizovaná v rámci knihoven neuronových sítí.
- **Rozdělení dat:** Pro některé neuronové sítě je zapotřebí data rozdělit na trénovací a kontrolní. Toto rozdělení však zpracuje sama knihovna strojového učení. Uživatel však musí nastavit, jaký podíl dat má být využit pro validaci.

Feature engineering (dopočítávaná data)

Pro trénování neuronových sítí je nutné některá data dopočítat, protože pro vybrané veličiny je zásadnější jejich rozdíl nebo podíl než jejich absolutní hodnota. Neuronovým sítím to také umožňuje vytrénovat se na menším počtu dat, díky tomu, že jsou si metriky v průběhu topné sezóny více podobné. Tyto hodnoty nejsou z důvodu omezení maximální velikosti přílohy zaneseny do datasetu v příloze práce, je však možné je jednoduše reprodukovat.

Konkrétní dopočítávaná data jsou následující:

- Diference teploty přes kondenzátor – vypočítává se jako teplota na výstupu mínus teplota na vstupu v daný časový okamžik. Protože je v průběhu měření průtok víceméně konstantní, jedná se také o měřítko tepelného výkonu systému.
- Diference teploty přes výparník – vypočítává se jako teplota na výstupu mínus teplota na vstupu do výparníku. Ukazuje schopnost výměníku venkovní jednotky předávat teplo chladivu. Je závislá na průtoku chladiva, vlhkosti vzduchu a průtoku vzduchu přes výměník.
- Diference teploty výparníku a venkovní teploty – vypočítá se jako rozdíl teploty výparníku na výstupu a venkovní teploty. Může sloužit jako indikátor množství vytvořené námrazy na výparníku.
- Podíl příkonu a difference teploty přes kondenzátor – hodnota ukazuje, jak účinná je tepelné čerpadlo v dodávce tepla do otopného systému
- Diference teploty na výstupu z tepelného čerpadla a teploty na výstupu z výparníku
- Moment kompresoru – odpovídá podílu příkonu kompresoru a frekvenci (otáčkám) kompresoru. Hodnota není zcela přesná, protože další neznámou proměnnou je účinnost kompresoru, která je závislá na jeho otáčkách i zatížení.
- Změny veličin oproti předchozímu kroku/krokům, například změna teploty kompresoru nebo teploty vody na výstupu
- Čas od uplynutí od změny frekvence – hodnota, která udává počet záznamů od poslední změny frekvence kompresoru.
- Plovoucí průměr frekvence kompresoru – frekvence kompresoru se mění skokově, ale projevy této změny jsou zpožděné a vyhlazené tepelnými setrvačnostmi. Díky tomu by tento parametr měl lépe korelovat s ostatními.
- Diference teploty na výstupu z výparníku k venkovní teplotě normalizovaná otáčkami kompresoru

„If you torture the data long enough, it will confess to anything.“ Ronald Coase

8 HARDWARE A SOFTWARE

8.1 Hardware

Pro veškeré výpočty byl využit notebook střední třídy. Jeho základní parametry jsou: procesor AMD Ryzen 7 4800H, grafická karta NVIDIA GeForce GTX 1660 Ti a operační paměť 16 GB na taktu 3200 MHz.

Výpočetní čas potřebný k natrénování neuronové sítě se v mém případě pohyboval od pár minut po několik hodin. Pokud je ale cílem optimalizovat architekturu sítě společně s jejími parametry, počet kombinací se velmi navýší a časová náročnost výpočtu vzroste tak, že se může stát neúnosnou. Největším rizikem při výpočtech je, že pokud je vyčerpána paměť RAM, počítač začne využívat paměť harddisku. To výpočty nejen extrémně zpomalí, ale pokud úložiště využívá SSD, může v krátké době dojít k jeho opotřebení. Je vhodné tuto funkci omezit.

8.2 Software

Tato podkapitola popisuje programové vybavení, které bylo využito pro zpracování dat, vývoj modelů neuronových sítí, jejich trénování a následné vyhodnocení. Veškerý použitý software je volně dostupný ke stažení i používání.

Python

Python je vysokoúrovňový, interpretovaný a univerzální programovací jazyk. V současnosti je dominantním jazykem pro datovou vědu, strojové učení a vývoj neuronových sítí, a to díky rozsáhlé standardní knihovně, čitelné syntaxi a velkému množství specializovaných balíčků. [30] V této práci byla použita verze Pythonu 3.11 jako základní programovací jazyk pro implementaci všech algoritmů a datových manipulací i vykreslení grafů.

„Python is the most powerful language you can still read.“ Paul Dubois

Knihovna PyTorch

PyTorch je open-source knihovna pro strojové učení založená na knihovně Torch. Vyvinutá je primárně společností Meta AI. Využívá se zejména pro aplikace počítačového vidění a výzkum i nasazení hlubokých neuronových sítí. Velmi oblíbená je pro svou flexibilitu, pythonovské rozhraní a silnou podporu pro výpočty GPU. [31]

Knihovna TensorFlow

TensorFlow je komplexní open-source platforma pro strojové učení. Vznikla v roce 2015 ve vývojářském týmu Google Brain. Využívá se často pro trénování hlubokých neuronových sítí a podporuje vývoj modelů prostřednictvím vysokoúrovňového API Keras. [32]

Scikit-learn

Scikit-learn je open-source knihovna pro strojové učení v Pythonu, postavená na dalších pythonovských knihovnách, jako např. NumPy, SciPy a Matplotlib. Umožňuje pokročilou prediktivní analýzu dat skrze širokou škálu algoritmů pro klasifikaci, regresi, shlukování, redukci dimenzionality, výběr modelu a předzpracování dat. V této práci byla klíčová pro přípravu dat a evaluaci modelů. [33]

Visual Studio 2022

Pro vývoj a správu kódu bylo využito integrované vývojové prostředí (IDE) Visual Studio 2022 od společnosti Microsoft. Visual Studio poskytuje pokročilý editor kódu s nástroji pro ladění, správu projektů a integraci se systémy pro správu verzí (např. Git), což zefektivňuje proces vývoje softwaru, včetně skriptů v jazyce Python. [34]

CUDA (Compute Unified Device Architecture)

CUDA je platforma pro paralelní výpočty a programovací model vytvořený společností NVIDIA pro její grafické procesory (GPU). Její implementace vyžaduje kompatibilní GPU od NVIDIA a instalaci CUDA Toolkit, který poskytuje potřebné knihovny, kompilátor a vývojové nástroje. Umožňuje využívat masivní paralelní výpočetní výkon GPU pro obecné výpočetní úlohy (tzv. GPGPU), což umožňuje např. výrazně urychlit výpočty při trénování hlubokých neuronových sítí. [35]

MLFlow

MLflow je open-source platforma pro správu životního cyklu strojového učení (Machine Learning Lifecycle Management – MLOps). Vytváří databázi výsledků, umožňuje spravovat modely nebo trénovací data, porovnávat jednotlivé experimenty a přenášet je do různých prostředí. Zvyšuje organizovanost výsledků dosažených různými architekturami neuronových sítí. [36]

Při tvorbě programů bylo nejnáročnější, aby si odpovídaly tenzory vstupních dat a vstupů neuronové sítě. V některých případech došlo k tomu, že učicí ztráta (loss) byla tak vysoká, že přetekla. Pak bylo nutné upravit hyperparametry sítě nebo upravit rozsah trénovacích dat.

Během trénování sítí nebyl zaznamenán žádný zásadní problém se stabilitou běhu programů. Je však vhodné, aby programy umožňovaly průběžné ukládání modelu, především pokud je špatně odhadnuta časová náročnost. Knihovny taky umožňují dynamickou změnu learning rate, výběr epochy s nejlepším výsledkem, early stopping (zastavení učicího procesu, pokud se již natrénovaná síť výrazně nezlepší). Pro vyhledávání optimálních hyperparametrů jsou součástí grid searche (mřížkový vyhledávač), který vyzkouší všechny jejich kombinace, nebo zkouší náhodné kombinace.

„Prediction is very difficult, especially if it's about the future!“ Niels Bohr

9 AUTOENKODÉR – HLEDÁNÍ ANOMÁLIÍ

9.1 Popis metody

Princip metody hledání anomálie v provozních datech je následující: Využívá se přístupu autoencoderů s LSTM neurony. Síť je rozdělena na enkodér a dekodér. Do enkodéru jsou vkládány sekvence trénovacích dat, které jsou zpravidla smrštěny do menší dimenze na jejím konci. Tento výsledek je následně vkládán do dekodéru, který se z těchto dat opět snaží co nejvěrněji vytvořit data, která byla na vstupu do sítě. Neuronová síť je učena na datech, která reprezentují běžný provoz tepelného čerpadla. Anomálie je hodnota odchylky vstupních dat od vygenerovaných výstupních dat. Pokud je odchylka vysoká, znamená to, že data neodpovídají běžnému provozu, a tím lze indikovat možnou poruchu. Tento přístup není schopen identifikovat konkrétní poruchu. Za poruchu může také vyhodnotit stav, který je zcela běžný, ale je od trénovacích dat vzdálen svými provozními parametry.

9.2 Postup


Podkapitola přibližuje postupné zkoušení a pozorování odezev modelů neuronových sítí po aplikaci různých dat. Zvolené hyperparametry jsou výsledkem předchozího experimentování se sítí a jsou shodné napříč všemi zkoušenými kombinacemi dat (s výjimkou nejlepšího výsledku).

Celý dataset, základní features

Nejprve byl do neuronové sítě nahrán celý dataset se základními features (viz tabulka 9.1). Na grafu 9.1 jsou oblasti s reálnými poruchami označeny červeně. Je viditelné, že oblasti s poruchami nevykazovaly vyšší hodnoty anomálie ve všech případech. Tento výsledek proto není použitelný.

Tab. 9.1: Hyperparametry využitě pro trénování autoenkodéru.


data	celý dataset
délka sekvence	30
batch	256
learning rate	0,008
počet epoch	20
architektura	64x4
LSTM dropout	0,1
délka tréningu	27 minut
features	teplota na vstupu do výparníku, teplota výtlaku kompresoru, teplota na výstupu z výparníku, venkovní teplota, teplota zpátečky otopného systému, teplota výstupu do otopného systému, celkový příkon, příkon ventilátoru, provozní stav, teplota vnitřního čidla, frekvence kompresoru, poloha reverzního ventilu.



Graf 9.1: Hodnoty anomálie neuronové sítě, která byla trénována na celém datsetu.

Celý dataset, feature engineering


V tomto případě byla do sítě opět vložena všechna data. Nahrány byly features, z nichž některé byly uměle vytvořeny feature engineeringem. Na grafu 9.2 lze vidět, že hodnoty anomálií jsou v oblastech poruch ve většině případů vyšší. Z grafu je také patrné, že byť je porucha přítomná dlouho, její hodnota je vyšší jen, pokud tepelné čerpadlo běží. Použité features: difference teploty přes kondenzátor, difference teploty výparníku a venkovní teploty, difference teploty přes výparník, Podíl příkonu a difference teploty přes kondenzátor, celkový příkon, provozní stav, čas od uplynutí od změny frekvence, frekvence kompresoru, difference teploty na výstupu z tepelného čerpadla a teploty na výstupu z výparníku.



Graf 9.2: Hodnoty anomálie neuronové sítě, která byla trénována na celém datasetu s použitím feature engineeringu.

Obzvlášť vysoká hodnota anomálie se však v grafu 9.2 objevuje i mimo vyznačenou oblast poruchy. Po prozkoumání dat bylo zjištěno, že se jedná o dobu, kdy bylo nutné kvůli nízkým venkovním teplotám zapnout záložní zdroj tepla. Jednalo se o plynový stacionární kotel s litinovým výměníkem a v grafu 9.3 je vidět jeho opakované zapínání a taky teplotní zpoždění, které je způsobeno nízkým průtokem a tepelnou setrvačností deskového výměníku. Tento příklad demonstruje, že poruchovým stavem je síť označen jakýkoliv výjimečný stav

v datasetu. Aby nebylo nutné opětovně pátrat po příčině, byl tento režim označen jako porucha do trénovacích dat.




Graf 9.3: Záznam teplot, pokud je spuštěn plynový kotel otopné soustavy.

Všechna data, trénování pouze za běhu

Prvním provedeným omezením bylo, že v potaz budou brány pouze stavy, kdy tepelné čerpadlo běží. Navíc dojde k ořezu těchto sekvencí běhu několik minut na začátku a několik desítek sekund na konci. Tím se taky sníží počet dat, nároky na výpočet a urychlí se trénování neuronové sítě.


Z grafu 9.4 je patrné, že peaky, způsobené náběhy a doběhy, jsou mnohem nižší. Úseky, kdy nebylo tepelné čerpadlo v provozu, nebyly vyhodnoceny. Vysokých falešně vyhodnocených odchylek je značně méně než v předchozích pokusech. Nejvyšší hodnota anomálie na grafu má hodnotu 1000 (graf je ořezán, použití logaritmického měřítka nepřineslo kýžené zvýšení přehlednosti) a jedná se o správně detekovanou poruchu – výpadek čidla kontroléru expanzního ventilu. Z features byl odebrán parametr provozního stavu, protože je ve všech případech stejný.



Graf 9.4: Hodnoty anomálie neuronové sítě, která byla trénována na všech datech pouze za běhu. Osa y pro lepší názornost nezobrazuje maximální hodnotu anomálie.

Sít' obsahuje naprosto vše


Také bylo vyzkoušeno, jak si sít' poradí s tím, že jí budou dány všechna naměřená data i všechny features vytvořené feature engineeringem. Hodnota maximální odchylky (porucha čidla expanzního ventilu) klesla z hodnoty 1000 na zhruba 300.



Graf 9.5: Hodnoty anomálie neuronové sítě, která byla natrénovaná na celém datasetu a se všemi features (osa y pro lepší názornost nezobrazuje maximální hodnotu anomálie).

Bylo zjištěno, že peak anomálie, která dosahuje hodnoty 19 (viz graf 9.5) byla způsobena přerušением záznamu dat (ve vykreslení jsou lineárně spojeny koncové a počáteční body přerušení – graf 9.6). Podobné chování by bylo způsobeno i jinou skokovou změnou, například výpadkem senzoru nebo jeho poruchou. Vysoká hodnota anomálie u této chyby byla způsobena (v porovnání s předchozím grafem č. 11, kde vysokou hodnotu nemá) tím, že v použitých features byly použity rozdíly mezi současným a předchozím krokem (teplota kompresoru, výparníku a jiné).

Tato anomálie byla do dat zaznamenána jako chyba výpadku měření, aby nebylo nutné opětovně hledat příčinu její vysoké hodnoty anomálie.




Graf 9.6: Výpadek záznamu způsobený zaseknutím programu.

Ořez na oblast bez simulovaných poruch (prvních 270k dat)

Následující varianta je učena pouze na prvních 270 000 dat při běhu TČ, které neobsahují žádnou simulovanou poruchu – tím by si síť měla natrénovat bezchybný provoz.


Použito byly tyto features: venkovní teplota, difference teploty přes kondenzátor, příkon ventilátoru, difference teploty přes výparník, plovoucí průměr difference teploty přes výparník, difference teploty výparníku a venkovní teploty, podíl příkonu a difference teploty přes kondenzátor, moment kompresoru, podíl frekvence a teploty kompresoru, změna teploty kompresoru za poslední 3 kroky, plovoucí průměr difference teploty výparníku a teploty na výstupu kondenzátoru.

Vysoká venkovní teplota (v období kolem 15. 4. 2025) zapříčinila, že byla zvýšena minimální hodnota anomálie (graf 9.7). Důvodem je nejspíše to, že v souboru 270k trénovacích dat byla venkovní teplota výrazně nižší.




Graf 9.7: Hodnoty anomálie neuronové sítě, která byla natrénovaná na prvních 270k záznamech (osa y pro lepší názornost nezobrazuje maximální hodnotu anomálie).

Zajímavý je i vrchol 2. 4. 2025 (anomálie na výřezu grafu 9.8), který se zobrazoval i v jiných grafech, ale nikdy nebyl tak výrazný. Podle grafu 9.9 došlo ke snížení frekvence kompresoru. Zvláštní je zvýšení příkonu kolem času 1:30. Jiná nesrovnalost nalezena nebyla. Je tedy otázkou, co bylo příčinou nezvyklého chování TČ a vysoké hodnoty anomálie.



Graf 9.8: Výřez grafu anomálie z data 2. 4. 2025.




Graf 9.9: Záznam parametrů tepelného čerpadla během anomálie 2. 4. 2025.

„You don't train a neural network. You let it struggle, fail, adapt and repeat – until its failures look like intelligence.“ Emmimal P. Alexander

Přístup s minimem dat

Dalším pokusem bylo vyzkoušet detekovat poruchy pouze na základě měřených teplot. Použita byla změna teploty přes výparník, změna teploty kondenzátoru, rozdíl teploty mezi výparníkem a venkovní teplotou, klouzavý průměr teploty kompresoru (posledních 20 kroků), změna teploty kompresoru ob tři kroky.


Tato varianta vykazuje poměrně dobrou přesnost identifikace poruch (viz graf 9.10).



Graf 9.10: Hodnoty anomálie neuronové sítě, která byla natrénována pouze s minimem vstupních features a prvních 270k záznamech

Pouze teploty bez diferencí, na 270k datech

V následujícím případě byla pro natrénování sítě použita taktéž pouze data teplot, ale bez jejich vzájemných rozdílů. Výsledek grafu 9.11 ale dokazuje důležitost použití rozdílů hodnot – minimální hodnota anomálie je vysoká (jedná se o důsledek velmi rozdílné hodnoty venkovní teploty v trénovacích datech a venkovní teploty v celém datasetu, stejně jako v grafu 9.7).




Graf 9.11: Hodnoty anomálie neuronové sítě, která byla natrénována pouze s minimem vstupních features

Pokus o co nejlepší výsledek

Následně bylo experimentováno s použitím různých features a nastavením hyperparametrů. Jednoho z nejlepších výsledků (graf 9.12) dosaženého na 270k datech za běhu TČ bylo dosaženo s těmito 5 features: rozdíl teplot vody v kondenzátoru, rozdíl teplot přes výparník, rozdíl teplot výstupu výparníku a venkovní teploty, podíl příkonu a rozdílu teplot vody v kondenzátoru, podíl frekvence kompresoru a příkonu.

Oříznutí jednotlivých sekvencí běhu bylo nastaveno na 130 sekvencí na začátku a 10 na konci. Nejvyšší hodnota anomálie dosáhla 40 000.




Graf 9.12: Hodnoty anomálie neuronové sítě, která dosahovala nejlepších výsledků indikaci poruch

9.3 Shrnutí

Metoda autoenkodérů s LSTM modelem je ze všech vyzkoušených přístupů nejjednodušší. Jediný problém nastal, pokud byla délka sekvencí zvolena moc vysoká. Pak ztráta (loss) přetekla a síť přestala konvergovat. Poruchy není nutné mít v použitém datasetu označené. Pokud se nevyskytují velmi často, je možné nahrát dataset i s poruchou. Je však vhodné rozdělit záznam podle provozních stavů. Tyto sekvence je nutné, pro dosažení dobrých výsledků, oříznout (oříznout je, v případě konkrétního TČ, nutné i konec, protože roztočení kompresoru protitlakem bývá zaznamenáváno frekvencí). Problémem je, že za poruchu je označen i stav, který se vyskytuje výjimečně, byť je zcela v pořádku. Výsledkem je jediná hodnota v závislosti na času.

Vyhodnocení výsledků je na druhou stranu velice obtížné. Je otázkou, jak vysoká má být hranice nebo délka úseku, označující anomální stav. Vytvoření takových algoritmů a porovnání jejich přesnosti by mohla být dalším posunem při aplikaci autoenkodérů pro detekci anomálií.

V rámci experimentování byly porovnány různé architektury neuronové sítě pro autoenkodér. Byly vyzkoušeny různé počty vrstev (1, 2, 3) a počet neuronů ve vrstvě 16, 32, 64, 128 (graf 9.13 vlevo). V grafu 9.13 vpravo je závislost doby trénování modelu na batch size.



Graf 9.13: Train loss v závislosti na počtu skrytých vrstev pro šířku 16,32,64,128 (vlevo). Závislost doby trénování na batch size (vpravo).

10 RNN – IDENTIFIKACE PORUCHY

10.1 Popis metody


Cílem je, aby neuronová síť odhalila konkrétní typ poruchy. Neuronová síť je naučena na příkladech poruch, které jsou uměle vyvolány. Je tedy nutné mít poruchy zaneseny již v trénovacím datasetu. Síť je učena na všech provozních stavech. Evaluace probíhá na všech datech.

Vybrané features jsou normalizovány min/max. Je nadefinována LSTM neuronová síť. V její výstupní vrstvě jsou 4 výstupy pro bezporuchový stav a tři zvolené poruchy (zakrytí výparníku, odpojení ventilátoru, změna přehřátí). V trénovacím datasetu se každá z poruch vyskytuje minimálně jednou. Data nejsou jinak upravována ani omezoována, jsou použita všechna (i stav kdy tepelné čerpadlo neběží). Bylo to použito, právě proto, aby se nemuselo s daty jakkoli manipulovat.

Použité features: difference teplot na kondenzátoru, difference teplot na výparníku, difference teploty výparníku a venkovní teploty, podíl frekvence kompresoru a příkonu, čas od změny frekvence, provozní stav tepelného čerpadla, příkon ventilátoru, celkový příkon

10.2 Vyhodnocení


Grafy v horní části zobrazují jednotlivé pravděpodobnosti poruch v daném časovém okamžiku. Dolní část grafů ukazuje provozní stav TČ. Pokud je porucha skutečně přítomna, je vykreslena vodorovnou čarou (např. graf 10.1).



Graf 10.1: Celkový přehled vyhodnocení RNN na celém datasetu.

Porucha odpojení napájení ventilátoru


Náběh indikace poruchy odpojení napájení ventilátoru je strmá (graf 10.2). Zdá se, že je vyhodnocení o délku sekvence opožděné. Oproti výsledku, který poskytl transformer, je indikace poruchy přerušena každou pauzou, kdy tepelné čerpadlo neběží (pokud není oblast zaznačena jako odmrazování, znamená to, že došlo k odstavení kompresoru z důvodu přehřátí). Po opětovném připojení ventilátoru dochází k indikaci zakrytí výparníku (výparník má nízkou teplotu a zároveň už běží ventilátor) a pak ke změně přehřátí.



Graf 10.2: Vyhodnocení oblasti poruchy odpojení ventilátoru RNN


Porucha změna přehřátí

Porucha byla v oblasti skutečné poruchy dobře indikována (graf 10.3). V oblasti, kde tepelné čerpadlo neběží, je indikována změna přehřátí.



Graf 10.3: Vyhodnocení oblasti poruchy změny přehřátí


Vyhodnoceno dalšího záznamu poruchy dopadla mnohem hůře (graf 10.4). Viditelné jsou velké oblasti, kdy je indikováno zakrytí výparníku a dokonce oblast kolem času 10:00, která je vyhodnocena jako bezporuchový stav.



Graf 10.4: Vyhodnocení poruchy změny přehřátí


Porucha zakrytí výparníku

Špatného výsledku bylo dosaženo při indikaci poruchy zakrytí výparníku (graf 10.5). Nástup byl pozvolný a nedosáhl 100 %. Po necelých 40 minutách od začátku simulace poruchy bylo neuronovou sítí vyhodnoceno, že je tepelné čerpadlo bez poruchy. Podobný obrazec indikace jde vidět i v části po odmrazovacím cyklu. Na konci indikace poruchy pak hodnota osciluje.



Graf 10.5: Vyhodnocení poruchy zakrytí výparníku 7.5.2025

V dalším grafu stejné poruchy (graf 10.6) lze vidět ještě horší výsledek. Nástup poruchy byl velmi opožděný a až po půl hodině byla indikována porucha změny přehřátí, která byla vystřídána správnou indikací – poruchy zakrytého výparníku.



Graf 10.6: Vyhodnocení poruchy zakrytí výparníku 18.5.2025

Kvantitativní vyhodnocení:

Vyhodnocena byla pouze část, kterou model při trénování neviděl – od záznamu 700k a pouze na datech běhu tepelného čerpadla. Výsledky zobrazuje tabulka 10.1.


Tab. 10.1: Matice záměn vyhodnocení RNN.

skutečný stav	vyhodnocení (data nepoužitá pro trénování) pouze při běhu				celkem
bez poruchy	139560	111	34	690	140395
zakrytí výparníku	1189	567	0	91	1847
odpojení ventilátoru	78	2	1225	0	1305
změna přehřátí	4147	241	0	10262	14650
indikovaný stav	bez poruchy	zakrytí výparníku	odpojení ventilátoru	změna přehřátí	158197


Porucha zakrytí výparníku byla správně indikována v 567 z 1847 záznamů (30,7 %).
Porucha odpojení ventilátoru byla správně indikována v 1225 z 1305 záznamů (93,8 %).
Porucha změny přehřátí byla správně indikována v 10262 z 14650 záznamů (70,0 %).

Počet falešných poplachů (chyba je určena, i když je TČ bez poruchy) za běhu bylo 835 z 140 395 záznamů (0,59 %).

V grafech níže (grid search pro optimální architekturu) je ukázka dosažených přesností při trénování (graf 10.7) a finální validaci (graf 10.8).



Graf 10.7: Ukázka finální přesnosti tréninku pro různé hloubky sítě a pro šířku 16, 32, 64, 128 a 256.



Graf 10.8: Ukázka finální přesnosti validace pro různé hloubky sítě a pro šířku 16, 32, 64, 128 a 256.


11 TRANSFORMER – IDENTIFIKACE PORUCHY

11.1 Popis metody

Klíčovým mechanismem metody Transformer je self-attention. Ten umožňuje modelu při analýze každého časového bodu v sekvenci zvážit relevanci všech ostatních bodů v téže sekvenci. Díky tomu dokáže efektivně identifikovat dlouhodobé závislosti a komplexní vztahy mezi různými měřenými veličinami v čase. Na rozdíl od rekurentních sítí může zpracovávat všechny prvky sekvence paralelně, což vede k urychlení tréninku (pokud je dostupný dostatečný výpočetní výkon). Díky pozičnímu kódování jsou zachovány informace o pořadí dat. Výsledky jsou poté zpracovány FFN sítí na finální klasifikaci.

Cílem metody bylo přesně identifikovat typ poruchy (zakrytí výparníku/odpojení ventilátoru/změna přehřátí – ostatní poruchy byly ignorovány).

Hlavními hyperparametry byla délka sekvencí 32, batch size 64, vnitřní architektura FFN 2x64, počet hlav 2. Počet provedených epoch byl 30. Transformer byl trénován na 700 000 záznamech z datasetu na všech provozních stavech (graf 11.1). V tomto úseku se bylo třikrát simulováno zakrytí výparníku třikrát změna přehřátí a jednou byl odpojen ventilátor. Použité features byly: venkovní teplota, čas od změny frekvence kompresoru, frekvence kompresoru, provozní stav, poloha reverzního ventilu, difference teplot na kondenzátoru, difference teplot na výparníku, difference venkovní teploty a teploty výparníku, moment kompresoru, celkový příkon, příkon ventilátoru, podíl frekvence kompresoru a teploty kompresoru, podíl příkonu a difference teploty přes kondenzátor. Model je velmi náročný na paměť (běh programu si v maximu vyžádal 12 GB RAM).




Graf 11.1: Ukázka indikovaných poruch na celém datasetu.

11.2 Vyhodnocení

Porucha odpojení ventilátoru


Porucha odpojení ventilátoru je ohraničena velmi ostře. Je snadno detekovatelná, protože byl jako feature použit příkon ventilátoru, který je nulový, pokud je ventilátor odpojen. Po jeho připojení následuje indikace zakrytí výparníku, protože ten je stále podchlazen, i když už ventilátor běží. Následuje indikace poruchy – změna přehřátí, než se regulátor ustálí po rychlé změně výkonu výparníku (graf 11.2).



Graf 11.2: Vyhodnocení oblasti poruchy odpojení ventilátoru transformérem.


Změna přehřátí

Porucha změna přehřátí je indikována i ve stavu, kdy tepelné čerpadlo neběží (Graf 11.3). To ale může být správně, protože měřené teploty na vstupu a výstupu výparníku mohou být různé (viz kapitola 4.4 – vypnuto). Kdyby trénovací data obsahovala více okamžiků, kdy TC neběží, nejspíš by se model naučil, že je rozdílnost teplot běžná. Případně je vhodné, aby poruchy, které se nemohou projevit mimo provoz TC, nebyly indikovány.



Graf 11.3: Vyhodnocení oblasti poruchy změny přehřátí transformérem.

Další záznam poruchy (Graf 11.4) změny přehřátí je zajímavý tím, že odmrazovací cykly jsou z části indikovány jako bez poruchy, protože změna přehřátí má jen částečný vliv (změna tvorby námrazy na výparníku) na fungování expanzního ventilu.




Graf 11.4: Vyhodnocení oblasti poruchy změny přehřátí transformérem.


Porucha zakrytí výparníku

Porucha zakrytí výparníku byla opět indikována velmi dobře. Nástup indikace je ostrý a s minimálním zpožděním.

Mmj. na začátku běhu TČ je vidět i porucha změny přehřátí (fialová barva na grafu 11.5). První úsek poruchy změny přehřátí má 5 peaků, což odpovídá počtu změn frekvence kompresoru (viz graf 11.6).




Graf 11.5: Vyhodnocení oblasti poruchy zakrytí výparníku.




Graf 11.6: Úsek záznamu chování TČ odpovídající úseku na grafu 11.5.

Na grafu níže (graf 11.7) lze vidět další průběh poruchy zakrytí výparníku. Detekce poruchy má opět velmi ostrý náběh. Konec poruchy je vystřídán poruchou změny přehřátí, což je logické, protože kontrolér expanzního ventilu nedokázal na změnu tak rychle reagovat.



Graf 11.7: Vyhodnocení oblasti poruchy změny přehřátí transformérem.

Na grafech níže jde je zobrazen průběh učení na konci každé epochy. Jde vidět, že její ztráta i přesnost se stále zlepšovaly a lepších výsledků by bylo možné dosáhnout, pokud by se s tréninkem pokračovalo (graf 11.8).



Graf 11.8: Průběh dosažené ztráty (loss – vlevo) a přesnosti (accuracy – vpravo) při trénování použitého transformeru

Kvantitativní vyhodnocení

Vyhodnocena byla pouze část, kterou model při trénování neviděl – od záznamu 700k a pouze na datech běhu tepelného čerpadla. Výsledky zobrazuje tabulka 11.1.

Tab. 11.1: Matice záměn pro výsledky transformeru.

Skutečný stav	Vyhodnocení (data nepoužitá pro trénování) pouze při běhu				Celkem
	Bez poruchy	Zakrytí výparníku	Odpojení ventilátoru	Změna přehřátí	
Bez poruchy	138454	254	49	1638	140395
Zakrytí výparníku	7	1840	0	0	1847
Odpojení ventilátoru	0	0	1305	0	1305
Změna přehřátí	75	35	4	14536	14650
Indikovaný stav	Bez poruchy	Zakrytí výparníku	Odpojení ventilátoru	Změna přehřátí	158197

Porucha zakrytí výparníku byla správně indikována v 1840 z 1847 záznamů (99,6 %).

Porucha odpojení ventilátoru byla správně indikována v 1305 z 1305 záznamů (100 %).

Porucha změny přehřátí byla správně indikována v 14536 z 14650 záznamů (99,2 %).

Počet falešných poplachů, za běhu TČ, bylo 1941 z 140 395 záznamů (1,4 %).

Porucha zakrytí výparníku tvořila 254 falešných poplachů, porucha odpojení ventilátoru 49, změna přehřátí 1638.

Detailnější analýzy by mohly zobrazit, jak dlouhé jsou sekvence indikace těchto poruch a na tomto základě vyřadit například krátkodobé odchylky od normálního provozu. Byť byly ostatní poruchy z trénování RNN a transformerů vyřazeny, jejich vlivy se mohly vnést i do trénovacích nebo evaluačních dat.

12 DISKUZE

Oblast umělé inteligence a neuronových sítí je velmi široký obor, v současnosti se velmi dynamicky rozvíjející. Předložená práce se pokusila nastínit možnosti využití této technologie pro indikaci poruch tepelného čerpadla. V průběhu zpracování práce se projevila řada nedokonalostí, které jsou níže okomentovány.

Co se týká samotné volby TČ, pro názornost a interpretaci výsledků, by bylo lepší zvolit TČ bez invertoru, tedy s kompresorem, jehož otáčky nelze měnit. Neuronová síť by s tak mohla naučit rychleji, protože by data neobsahovala tolik přechodných dějů a mohla by také lépe odhalit řídicí algoritmy. Kdyby bylo zvoleno výkonnější TČ, data by mohla být sbírána i při nízkých venkovních teplotách, kdy použité TČ nedosahovalo potřebného tepelného výkonu a muselo být nahrazeno náhradním zdrojem tepla (toto období není v datasetu zaznamenáno). Specifikem použitého modelu čerpadla bylo, že otáčky kompresoru se plynule modulovaly pouze při nižším výkonu. Při vyšším výkonu byla řídicí jednotka omezena jen na určité otáčky.

Řízení výkonu tepelného čerpadla bylo nahodilé a záviselo na teplotě v kontrolní místnosti. Upřednostněn byl běh přes den, čímž bylo TČ účinnější, a nerušilo svým hlukem obyvatele domu.

Sesbíraná data byla pro účely práce dostatečná. Obecně by však bylo vhodné mít dat co nejvíce – zejména rozšířit dataset o celou topnou sezónu (či spíše několik sezón).

Většího počtu dat je možné docílit i zvýšením frekvence měření. Frekvence měření byla omezena možnostmi mikrokontroléru pro zaznamenávání dat – jeho program by však mohl být optimalizován, což by frekvenci záznamů zvýšilo.

Přínos by mělo vyšší množství dat zejména pro odmrazovací cykly, protože tyto děje jsou krátké a dynamické.

Měřená data by bylo vhodné také obohatit o další parametry:

- vlhkost vzduchu: Vlhkost vzduchu přímo ovlivňuje tvorbu námrazy i výkon samotného výparníku, který tím může být zvýšen o skupenské teplo. Rychlost vzniku námrazy hraje klíčovou roli při spouštění odmrazovacích cyklů. Tato informace by umožnila neuronové síti modelovat tvorbu námrazy a odmrazovací cykly. Byl pokus o náhradu dat daty z nejbližší meteorologické stanice, ty však nebyly dostupné v dostatečně dlouhém časovém úseku.
- stupeň otevření expanzního ventilu: Tento parametr by byl vhodným indikátorem poruch expanzního ventilu. V moderních čerpadlech s nativními elektronickými expanzními ventily je tato hodnota řízena řídicí jednotkou, takže není s jejím záznamem problém.
- sluneční svit (tepelné záření): Pokusné TČ bylo umístěno ve stínu, proto nebyl tento parametr relevantní. Pokud by však zastínění nemělo, mohlo by to zaznamenávané teploty nejen čidla venkovní teploty zásadně ovlivnit. Neuronová síť pak není schopná najít žádnou vhodnou korelaci. Částečně se může nahradit binární hodnotou, zda je slunce nad obzorem, což lze dopočítat z času.
- teplota chladiva před expanzním zařízením (hodnota podobná podchlazení chladiva).
- teplota v místnosti: Teplota ve zvolené místnosti byla ovlivněna solárními zisky i vnitřními zisky od osob a jejich činností (teplo z vaření apod.). Měření teploty v místnosti, která by nebyla výše zmíněným zatížena, by umožnila měřit závislost tepelné setrvačnosti budovy, ztráty do okolí a závislost výkonu otopných těles na jejich teplotě.
- napětí: Napětí ovlivňuje proud, a tedy i příkon měřený wattmetrem. Hodnotu příkonu by bylo vhodné normalizovat napětím, aby se eliminoval vliv kolísání napětí v elektrické síti.
- průtok vody v otopném systému: Tento parametr byl při sběru dat přibližně konstantní. Mohl se však mírně lišit v případech zavzdušnění otopných těles nebo postupným pomalým zanášením filtrů.
- tlak na sání a výtlačku kompresoru

K zamyšlení je proces měření simulovaných poruch. Je otázkou, zda mělo mít měření pevná pravidla, když jsou poruchy ze své podstaty nahodilé. Snaha byla o to, aby byly poruchy simulovány přímo za ustáleného běhu, což umožnilo sledovat rychlost indikace poruchy neuronovou sítí. Vzhledem k tomu, že nebyly poruchy měřeny stejně dlouho a že byl poměr, kdy tepelné čerpadlo za dané poruchy běží nebo ne, rozdílný, není možné z procentuálního zachycení jednotlivých poruch vyvozovat silné závěry.

Získaný dataset tedy není dokonalý. Příležitostně obsahuje i výpadky záznamu (především na konci datasetu). Ty pak mohou indikovat nepřítomné poruchy. Logika přiřazení provozního stavu může být v některých místech chybná, protože porucha může ovlivnit veličinu, podle které je stav přiřazován. Přestože proběhla kontrola těchto dat, nemusí být správnost 100%. Na druhou stranu odráží realitu a nejedná se o syntetický záznam z laboratorních, precizně hlídaných podmínek.

Při učení sítí byl limitujícím faktorem dostupný výpočetní výkon (zejména paměť RAM). Trénování sítí trvalo únosně dlouho, ale pro nalezení ideální velikosti a parametrů sítě, bylo zapotřebí natrénovat a porovnat stovky sítí. Spousta různých algoritmů a experimentů není v práci zaznamenána, spousta pokusů skončila neúspěšně bez prokazatelných výsledků. Vyzkoušena byla i spousta dalších algoritmů, jako je XGBoost, K-means, predikce spotřeby, predikce provozního stavu, redukce dimenze a snaha o identifikaci poruch v tomto prostoru, vykreslení vzájemných korelací.

Trénováním sítí byly zjištěny následující poznatky: Nutností je mít dat dostatek a odstranit z nich outlinery (které zcela znehodnotí normalizaci běžnými přístupy) a chybějící hodnoty. Vhodné je, aby byla data nepřetržitá, protože skokové změny jsou vyhodnoceny jako chyby. Zato nebyl zaznamenán významný rozdíl mezi daty obsahujícími šum a daty vyhlazenými. Při ladění sítě také nebylo nutné dělat velký počet epoch, protože hlavní rysy výsledku byly viditelné již po několika prvních epochách.

Učící proces sítě je nutné kontrolovat. Několikrát se prokázalo, že síť byla natolik špatná, že nejlepších výsledků dosáhla po několika prvních epochách a pak už její výkonnost jen degradovala. Vyzkoušen byl také přístup, kdy se síť učila anomálie pouze na defrostech. Toto však nevedlo k žádným přínosným výsledkům, mimo jiné i proto, že učících dat bylo málo.

Výrazného nedostatku dosahuje použitá metodika v oblasti vyhodnocování. Vzhledem k tomu, že identifikovaná porucha je časová řada, lze obtížně určit okamžik, kdy již má být stav označen jako porucha a kdy ještě ne. Výstup z neuronových sítí by bylo vhodné dále zpracovávat, aby byl omezen počet „planých poplachů“. Tuto hranici a algoritmus by bylo potřeba ladit. Porovnání sítí navzájem kvalitativně podle grafů není dostatečně průkazné. Kvantitativní vyhodnocení však může být zjednodušující. Celkově je vysvětlení příčin chování sítí obtížné a jedná se jen o domněnky, neboť je složité ověřit, co se uvnitř modelu skutečně děje.

K zamyšlení je, zda je lepší mít jednu velkou neuronovou síť společnou pro všechny stavy nebo mít pro každý stav vlastní. Taktéž je diskutabilní, zda má smysl vyhodnocovat poruchy, pokud tepelné čerpadlo neběží.

Obecně patří mezi velké potíže spojené s neuronovými sítěmi odhalení naučených závislostí nebo oprava chyb. Pokud chceme chybu opravit, je nutné celou síť přetrénovat. Dalším problémem může být to, že trénovací data nemusí obsahovat všechny stavy.

Často opomíjenou problematikou je kybernetická bezpečnost. Data jsou ve většině případů odesílána na výpočetní server. Trénovací data pak mohou být ukradena nebo záměrně ovlivněna, za účelem natrénovat jiné výsledky. Nějakými extrémně odlišnými daty je možné vytvořit zadní vrátka do systému. U neuronových sítí pak platí, že stokrát opakovaná lež

se stává skutečností. Při zneužití ovládání může dojít i ke zničení instalovaných přístrojů a vždy by měly být takové systémy zálohovány běžným deterministickým řízením.

Neuronové sítě neposkytují potenciál pouze v diagnostice poruch TČ. Bylo by možné použít je také k predikci výkonu, příkonu a dalších veličin. Zajímavou možností je také extrakce závislostí z naučených sítí (u autoenkoderů): do sítí jsou vložena data, pro která chceme danou veličinu simulovat a ona nám sama vydá závislost. Tímto způsobem je možné získat alespoň částečný vhled do vnitřního fungování.

Další perspektivní, avšak výrazně náročnější oblastí, je přímé využití neuronových sítí pro řízení samotného provozu tepelného čerpadla. Základní přístup by mohl spočívat v řízení otáček klíčových komponent, jako jsou kompresor, ventilátor venkovní jednotky a oběhové čerpadlo, a také v řízení stupně otevření expanzního ventilu. Pro zjednodušení prvotních experimentů by bylo možné, alespoň dočasně, vynechat komplexní logiku odmrazovacích cyklů a soustředit se na dosažení kontinuálního běhu.

Sofistikovanější úroveň by pak mohla zahrnovat optimalizaci specifických parametrů, například přehřátí na výparníku, kde by neuronová síť dynamicky upravovala čas nebo úroveň otevření a zavření expanzního ventilu s cílem maximalizovat výkon nebo efektivitu. Pro tento typ úlohy se jeví jako vhodný přístup reinforcement learning (zpětnovazební učení), kde by se síť učila na základě definované účelové funkce – například maximalizace topného výkonu, dosažení nejvyššího COP nebo udržování požadované teploty v místnosti či na výstupu z tepelného čerpadla. Výběr vhodné účelové funkce je však kritický, neboť jednoduché cíle, jako maximální topný výkon, mohou vést k neefektivnímu provozu, zatímco snaha o nejvyšší COP za všech okolností může naopak vést k nedostatečnému výkonu – model by nejspíš časem zjistil, že nejnižší spotřeba tepelného čerpadla je, pokud je vypnuto.

Experimentování s přímým řízením pomocí neuronových sítí by umožnilo získat hlubší pochopení jejich chování a schopnosti adaptace, včetně odpovědi na otázku, zda je pro optimální výkon lepší poskytnout síti maximum dostupných senzorických informací nebo provést selektivní výběr nejdůležitějších vstupů. Vzhledem ke komplexnosti a často obtížně predikovatelnému chování neuronových sítí, zejména v počátečních fázích učení, je však nezbytné implementovat robustní bezpečnostní mechanismy a hardwarová opatření (např. kontrola mezních příkonů, teplotní pojistky, sběrače kapalného chladiva), která by chránila tepelné čerpadlo před poškozením v důsledku nelogických řídicích zásahů ze strany neuronové sítě.

Bylo by tedy vhodnější indikovat poruchy TČ neuronovou sítí než vnitřní řídicí jednotkou TČ? Některé poruchy nemá smysl řešit neuronovou sítí, protože mohou být snadno odhaleny deterministicky vlastními algoritmy TČ. Na druhou stranu ale například porucha výpadku čidla řídicí jednotky expanzního ventilu byla řídicí jednotkou TČ ignorována 8 hodin běhu v kuse. Řídicí jednotka sice ohlížela, že žádná veličina nepřekročila zakázaný stav, ale na nesoulad veličin a jejich změny v čase nijak nereagovala. Zatímco neuronová síť ukazovala hodnoty anomálie řádově odlišné od běžných hodnot. Tento příklad ukazuje, že byť je deterministické řízení ve většině případů dostatečné a není důvod od něj upustit, nedokáže podchytit jiné než implicitně nakonfigurované poruchy, a to i přesto, že naprogramování tohoto systému je velmi náročné.

Závěrem bych uvedl, že cílem práce nebylo vytvořit síť s dokonalými výsledky. Každé TČ v kombinaci s otopnou soustavou a chováním uživatelů je unikátní systém. Pokud by bylo použito stejné čerpadlo, jen s jinou otopnou soustavou, mohlo by však pokračování trénování na již naučeném modelu značně ušetřit čas (v jiných oblastech se tohoto přístupu běžně využívá [37]). Smyslem však bylo popsat proces, který je nutný podstoupit pro nasazení takového systému do provozu.

S tématem neuronových sítí souvisí i vývoj vlastní umělé inteligence. Poslední roky patřily přestupu od textových k multimodálním modelům. Dalším obrovským skokem je reasoning, což umožňuje sítím „přemýšlet“ a lépe se rozhodovat. AI již má také schopnost využívat nástroje (například naprogramovat kód, který vypracuje nějaký úkol) a jejich výsledky pak dále použít. Velký důraz je mimo programování kladen i na analýzy vědeckých výsledků. Zajímavé bude, zda se nakonec budou používat různé úzce specializované nástroje AI podle toho, co bude uživatel potřebovat nebo nás čeká pouze jedna univerzální AGI (Artificial General Intelligence).

„Intelligence is the ability to adapt to change.“ Stephen Hawking

13 ZÁVĚR

V rámci diplomové práce „Možnosti využití neuronových sítí při provozu tepelného čerpadla“ byl vytvořen dataset zaznamenávající tříměsíční provoz tepelného čerpadla vzduch-voda s měřením vybraných parametrů. Dataset obsahuje přibližně 1,2 milionu záznamů běžného provozu. Mimo to zahrnuje také údaje o chování tepelného čerpadla během několika simulovaných poruch.

Získaná data byla využita pro trénování neuronových sítí za účelem diagnostiky poruch tepelného čerpadla. Vyzkoušen byl autoenkodér, rekurentní neuronová síť a transformer.

Autoenkodér se osvědčil při vyhledávání nejrušnějších typů anomálií provozu. Nejprůkaznějších výsledků dosahoval zejména s trénovacím datasetem, ve kterém nebyla obsažena žádná porucha, s vhodně zvolenými features (především rozdíly a podíly hodnot teplot) a pouze v sekvencích běhu tepelného čerpadla.

Pro identifikace konkrétních poruch byly použity rekurentní neuronová síť a transformer. Přestože byl transformer vyvinut pro strojový překlad, osvědčil se překvapivě lépe. U RNN sítě sice bylo nižší procento falešných poplachů (0,59 vs. 1,4 %). Přesnost vyhodnocení jednotlivých poruch však byla mnohem lepší u transformeru: porucha zakrytí výparníku (99,6 vs. 30,7 %), porucha odpojení ventilátoru (100 vs. 93,8 %), porucha změny přehřátí (99,2 vs. 70,0 %).

Vzhledem k tomu, že každý systém tepelného čerpadla je unikátní a jeho provoz ovlivňuje řada proměnných, nelze výsledné modely sítí využít u jiných instalací bez jejich přetrénování. Přesto však výsledky dokazují vysoký potenciál sítí pro zvýšení spolehlivosti a efektivity provozu tepelných čerpadel, čímž byly naplněny cíle práce.

Indikace poruch není jediná oblast, ve které lze v souvislosti s tepelnými čerpadly, neuronové sítě aplikovat. Cennější, než indikace poruch, by byla jejich predikce. Za tímto účelem by však musel být dataset obohacen o poruchy, které neprobíhají skokově, ale vznikají postupně, což by umožnilo model validovat. Predikovat by bylo možné i výkon a spotřebu, což by se mohlo uplatnit pro stabilizaci elektrické sítě.

Do budoucna lze očekávat další zvyšování dostupného výpočetního výkonu, což umožní rychlé trénování hlubokých neuronových sítí. Neměli bychom však podcenit nutnost dlouhodobého reprezentativního záznamu nejrušnějších dat, které budou stále základem každé kvalitní sítě.

14 SEZNAM PŘÍLOH

1 dataset.zip

SEZNAM POUŽITÝCH ZDROJŮ

- CHIANG, Lin; ZHENG, Lianmin; SHENG, Ying; ANGELOPOULOS, Anastasios Nikolas; LI, Tianle et al. *Chatbot Arena LLM Leaderboard: Community-driven Evaluation for Best LLM and AI chatbots*. Online. Chatbot Arena: An Open Platform for Evaluating LLMs by Human Preference. 2024. Dostupné z: <https://lmarena.ai/?leaderboard>. [cit. 2025-03-26].
- DOUNIS, Anastasios. *Intelligent Control in Energy Systems*. Online. MDPI, 2019. ISBN 9783039214167. Dostupné z: <https://doi.org/10.3390/books978-3-03921-416-7>. [cit. 2025-04-12].
- GOODFELLOW, Ian; BENGIO, Yoshua a COURVILLE, Aaron. *Deep learning*. Online. Adaptive computation and machine learning series. Cambridge, Massachusetts: The MIT Press, [2016]. ISBN 978-0-262-03561-3. Dostupné z: <https://www.deeplearningbook.org/>. [cit. 2025-01-18].
- DONLON, Mike. *Machine Learning in HVAC Controls*. Online. 2016. Dostupné z: YouTube, <https://www.youtube.com/watch?v=VpHv8SZE0eI>. [cit. 2025-04-10].
- VASWANI, Ashish; SHAZEER, Noam; PARMAR, Niki; USZKOREIT, Jakob; JONES, Llion et al. Attention Is All You Need. Online. *Neural Information Processing Systems*. 2017, roč. 30, s. 5998-6008. Dostupné z: <https://proceedings.neurips.cc/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf>. [cit. 2025-05-23].
- EVENS, Maarten a ARTECONI, Alessia. Heat pump digital twin: An accurate neural network model for heat pump behaviour prediction. Online. *Applied Energy*. 2025, roč. 2025, č. 378, article 124816, s. 16. Dostupné z: <https://doi.org/10.1016/j.apenergy.2024.124816>. [cit. 2025-05-08].
- CHIFU, Viorica Rozina; CIOARA, Tudor; POP, Cristina Bianca; ANGHEL, Ionut a PELLE, Andrei. Physics-Informed Neural Networks for Heat Pump Load Prediction. Online. *Energies*. 2025, roč. 18, č. 1. ISSN 1996-1073. Dostupné z: <https://doi.org/10.3390/en18010008>. [cit. 2025-01-27].
- BARANDIER, Pedro; MENDES, Mateus a CARDOSO, Antonio J. M. Comparative analysis of four classification algorithms for fault detection of heat pumps. Online. *Energy and Buildings*. 2024, roč. 2024, č. 316, s. 1-13. Dostupné z: <https://doi.org/https://doi.org/10.1016/j.enbuild.2024.114342>. [cit. 2025-02-01].
- KIM, Minsung; PAYNE, W. Vance; DOMANSKI, Piotr A.; YOON, Seok Ho a HERMES, Christian J. L. Performance of a residential heat pump operating in the cooling mode with single faults imposed. Online. *Applied Thermal Engineering*. 2009, roč. 29, č. 4, s. 770-778. Dostupné z: <https://doi.org/10.1016/j.applthermaleng.2008.04.009>. [cit. 2025-05-08].
- KŘEPELA, Jan. *Možnosti použití umělé inteligence pro on-line vibrodiagnostiku*. Online. Vše o průmyslu. 2021. Dostupné z: <https://www.vseoprmyslu.cz/udrzba-a-diagnostika/vibrodiagnostika/moznosti-pouziti-umele-intelligence-pro-on-line-vibrodiagnostiku.html>. [cit. 2025-04-07].
- , Ministerstvo průmyslu a obchodu. Dodávka tepelných čerpadel na trh v České republice v roce 2024: Výsledek statistického šetření za rok 2024. Online. In: . 2025, s. 1-3. Dostupné z: https://mpo.gov.cz/assets/cz/energetika/statistika/obnovitelne-zdroje-energie/2025/4/Rocni-dodavka-TC-na-trh_2024.pdf. [cit. 2025-03-12].

- MINISTERSTVO PRŮMYSLU A OBCHODU. *Dodávka tepelných čerpadel na trh v České republice v roce 2024*. Online. Ministerstvo průmyslu a obchodu. 2024. Dostupné z: https://mpo.gov.cz/assets/cz/energetika/statistika/obnovitelne-zdroje-energie/2025/4/Rocni-dodavka-TC-na-trh_2024.pdf. [cit. 2025-04-08].
- Sinclair ASH-09AIM PT. Online. In: Sinclair. C2025. Dostupné z: <https://www.sinclair-solutions.com/files/products/residential/ash-09-13aim2-outdoor-800x600px-72dpi-en.png?>. [cit. 2025-05-08].
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. ISO 5151, 14] *Non-ducted air conditioners and heat pumps — Testing and rating for performance*. 3rd ed. Switzerland, 2017.
- Technical data sheet R-410A. Online. In: Gas servei. C2025. Dostupné z: <https://gas-servei.com/wp-content/uploads/2024/06/Technical-data-sheet-R-410A-Gas-Servei-1.pdf>. [cit. 2025-02-08].
- ČESKÁ AGENTURA PRO STANDARDIZACI. ČSN EN 60529, *Stupně ochrany krytem*. 11/1993.
- SWEP INTERNATIONAL AB. B25. Online. Swep. C2022. Dostupné z: <https://www.swep.net/products/b25/>. [cit. 2025-03-19].
- Danfoss AK-CC 550a: case controller. Online. In: Hunter Liberty. C2025. Dostupné z: https://www.hunterliberty.com/images/thumbs/0005680_danfoss-ak-cc-550a-case-controller.jpeg. [cit. 2025-05-08].
- STRAKA, Tomáš. *Nejčastější chyby při výběru, instalaci a provozu tepelných čerpadel*. Online. In: TZB info. 2018. Dostupné z: <https://vytapani.tzb-info.cz/tepelna-čerpadla/17752-nejcastejsi-chyby-pri-vyberu-instalaci-a-provozu-tepelných-čerpadel>. [cit. 2025-05-08].
- GT ENERGY S.R.O. *Nejčastější chyby v projektech tepelných čerpadel*. Online. 20] Projektuj tepelná čerpadla. C2019-2025. Dostupné z: https://www.projektuj-tepelna-čerpadla.cz/cz/chyby-v-projektech?gl=1*13faks1*up*MQ.*ga*MTY4NjE1NzQ2NS4xNzQ2NzA3MTE5*_ga_VPNKN1FQKE*cZE3NDY3MDcxMTc6bzEkZzEkdDE3NDY3MDcxNjckajAkbaDAkaDA.. [cit. 2025-01-29].
- ŽERAVÍK, Antonín. *Stavíme tepelné čerpadlo*. Kroměříž: Antonín Žeravík, 2003. 21] ISBN 80-239-0275-X. Dostupné také z: <http://krameriusndk.nkp.cz/search/handle/uuid:a5ea49a0-65ad-11e4-8214-005056827e51>.
- ICM CONTROLS. *Compressor Staging/ Startup Delay Timer*. Online. 22] <https://jacksonsystems.com/>. C2025. Dostupné z: https://jacksonsystems.com/wp-content/uploads/2024/07/ICMControls_ICM102B_Installation_Instructions.pdf?srltid=AfmBOoqulefkjZY7Jo67aKGWkbMByQIdfJS_8nf3BJru1WsrGI4KjKFn. [cit. 2025-05-08].
- BASS, Mark a RAFALOVICH, Alexander P. (US). *Scroll compressor with liquid injection*. Přihl.: 3. 5.1994. Uděl.: 28. 11. 1995. 5,469,716. Dostupné také z: <https://patentimages.storage.googleapis.com/b2/a4/cb/514c1683255324/US5469716.pdf>.
- FRANCO, Michael. *Zooglea: What Is It and How Can It Harm Your HVAC System?* Online. In: Home Serve. 2024. Dostupné z: <https://www.homeserve.com/en-us/blog/home-improvement/zooglea>. [cit. 2025-02-26].

- HIOKI. *Heat flow logger LR8432*. Online. HIOKI E.E. CORPORATION. Hioki. C2021. Dostupné z: https://www.hioki.com/global/products/field-measuring/measurement/id_6586. [cit. 2025-01-04].
- MASTER THERM. *Tepelná čerpadla s nejpohodlnějším online ovládáním*. Online. MasterTherm tepelná čerpadla. 2025. Dostupné z: <https://mastertherm.cz/o-firme/ovladani-pres-internet/>. [cit. 2025-03-12].
- OFFICE OF ENERGY EFFICIENCY AND RENEWABLE ENERGY. *Study Data Search*. Online. Office of Energy Efficiency and Renewable Energy. 2025. Dostupné z: <https://heatpumpdata.energy.gov/data/studies>. [cit. 2025-02-25].
- ANALOG DEVICES, INC. *DS18B20*. Online. Analog Devices. C2025. Dostupné z: <https://www.analog.com/en/products/ds18b20.html>. [cit. 2025-05-08].
- MANDULA, Jakub. *PZEM-004T-v30*. Online. Git Hub. 2024. Dostupné z: <https://github.com/mandulaj/PZEM-004T-v30>. [cit. 2025-02-11].
- PYTHON. Online. C2001-2025. Dostupné z: <https://www.python.org/>. [cit. 2025-05-30].
- WU, James. *Pytorch*. Online. GITHUB, INC. Git hub. C2025. Dostupné z: <https://github.com/pytorch/pytorch>. [cit. 2025-05-08].
- TENSORFLOW. *Tensor Flow*. Online. 2025. Dostupné z: <https://www.tensorflow.org/>. [cit. 2025-02-03].
- Scikit-learn. Online. 2025. Dostupné z: <https://scikit-learn.org>. [cit. 2025-03-11].
- Visual Studio. Online. Microsoft. 2025. Dostupné z: <https://visualstudio.microsoft.com/cs/>. [cit. 2025-04-17].
- NVIDIA CORPORATION. *CUDA Toolkit*. Online. Nvidia developer. C2025. Dostupné z: <https://developer.nvidia.com/cuda-toolkit>. [cit. 2025-05-08].
- LF PROJECTS, LLC. *MLflow*. Online. C2025. Dostupné z: <https://mlflow.org/#learning-resources>. [cit. 2025-04-20].
- THE LINUX FOUNDATION. *PyTorch Hub For Researchers*. Online. C2025. Dostupné z: <https://pytorch.org/hub/>. [cit. 2025-02-03].

SEZNAM POUŽITÝCH ZKRATEK

Zkratka	Význam
AGI	Artificial General Intelligence (umělá obecná inteligence)
AI	Artificial Intelligence (umělá inteligence)
API	Application Programming Interface (rozhraní pro programování aplikací)
CNN	Convolutional Neural Network (konvoluční neuronová síť)
COP	Coefficient of Performance (topný faktor)
CUDA	Compute Unified Device Architecture (Platforma pro paralelní výpočty od NVIDIA)
ČSN EN	Česká státní norma Evropská norma
EEV	elektronický expanzní ventil
FDD	Fault Detection and Diagnostics (detekce a diagnostika poruch)
FNN	Feedforward Neural Network (dopředná neuronová síť)
GIGO	Garbage In, Garbage Out
GPU	Graphics Processing Unit (grafický procesor)
GPGPU	General-Purpose computing on Graphics Processing Units (obecné výpočty na grafických procesorech)
GRU	Gated Recurrent Unit (typ rekurentní neuronové sítě)
GWP-AR4	Global Warming Potential - Assessment Report 4 (potenciál globálního oteplování dle 4. hodnotící zprávy)
HVAC	Heating, Ventilation, and Air Conditioning (vytápění, větrání a klimatizace)
IDE	Integrated Development Environment (integrované vývojové prostředí)
IP24	Ingress Protection rating (stupeň krytí)
IPM	Intelligent Power Module (inteligentní výkonový modul)
ISO	International Organization for Standardization (Mezinárodní organizace pro normalizaci)
KNN	K-Nearest Neighbors (Algoritmus k-nejbližších sousedů)

LLM	Large Language Model (velký jazykový model)
LSTM	Long Short-Term Memory (dlouhodobá i krátkodobá paměť - typ RNN)
MDPI	Multidisciplinary Digital Publishing Institute (vydavatel)
ML	Machine Learning (strojové učení)
MLOps	Machine Learning Lifecycle Management (manažer cyklu strojové učení)
NN	Neural Network (neuronová síť)
NTC	Negative Temperature Coefficient (negativní teplotní koeficient - typ termistoru)
ODP	Ozone Depletion Potential (potenciál poškozování ozonové vrstvy)
PCB	Printed Circuit Board (deska plošných spojů)
PINN	Physics-Informed Neural Networks (fyzikálně informované neuronové sítě)
RAM	Random Access Memory (operační paměť)
RBF	Radial Basis Function (radiální báze funkce)
ReLU	Rectified Linear Unit (usměrněná lineární jednotka – aktivační funkce)
RMSE	Root Mean Square Error (střední kvadratická chyba)
RNN	Recurrent Neural Network (rekurentní neuronová síť)
SPZ	státní poznávací značka
SSD	Solid State Drive (polovodičový disk)
SVC	Support Vector Classification/Machine (metoda podpůrných vektorů pro klasifikaci)
TČ	tepelné čerpadlo
TEV	termostatický expanzní ventil
UV	Ultraviolet (ultrafialové)