



SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
MATERIÁLOVOTECHNOLOGICKÁ FAKULTA SO SÍDLOM V TRNAVE

Ing. Szabolcs Kováč

Autoreferát dizertačnej práce

**Analýza, návrh a verifikácia inteligentných metód riadenia energetických
systémov**

na získanie akademického titulu: doktor (philosophiae doctor, PhD.)

v doktorandskom študijnom programe: Automatizácia a informatizácia procesov

v študijnom odbore: Kybernetika

Forma štúdia: externá

Miesto a dátum: Trnava, 31.8.2023



Dizertačná práca bola vypracovaná na Katedre aplikovanej informatiky a automatizácie a Ústave aplikovanej informatiky, automatizácie a matematiky

Predkladateľ: Ing. Szabolcs Kováč
Ústav aplikovanej informatiky, automatizácie a matematiky
Materiálovotechnologická fakulta so sídlom v Trnave,
Slovenská technická univerzita v Bratislave
Jána Bottu 2781/25
917 24 Trnava

Školiteľ: doc. Ing. Michal Kebísek, PhD.
Ústav aplikovanej informatiky, automatizácie a matematiky
Materiálovotechnologická fakulta so sídlom v Trnave,
Slovenská technická univerzita v Bratislave
Jána Bottu 2781/25
917 24 Trnava

Oponenti:

Autoreferát bol rozoslaný:

Obhajoba dizertačnej práce sa bude konať dňa **o** **h.**

Na Materiálovotechnologickej fakulte fakulte STU so sídlom v Trnave, J. Bottu 25, 917 24, Trnava

.....
prof. Ing. Miloš Čambál, CSc.
dekan MTF STU

OBSAH

1	VÝCHODISKÁ A CIELE PRÁCE	5
2	ANALÝZA SÚČASNÉHO STAVU.....	6
2.1	ANALÝZA SÚČASNÉHO STAVU SPOLOČNOSTI BRATISLAVSKÁ TEPLÁRENSKÁ, A.S.	6
2.1	SÚSTAVA ZÁPAD	7
2.2	DÁTOVÝ SET A ANALÝZA DÁT	9
2.2.1	<i>Predspracovanie dát.....</i>	<i>9</i>
2.2.2	<i>Úprava dát.....</i>	<i>10</i>
2.2.3	<i>Transformácia dát.....</i>	<i>11</i>
2.2.4	<i>Popis a analýza spotreby tepla</i>	<i>11</i>
2.2.5	<i>Popis a analýza technologických faktorov.....</i>	<i>13</i>
2.2.6	<i>Popis a analýza meteorologických faktorov.....</i>	<i>15</i>
3	NÁVRH A TVORBA NÁVRH A TVORBA PREDIKČNÝCH MODELOV	18
3.1	HODNOTIACE KRITÉRIA KVALITY MODELOV.....	18
3.2	TVORBA PREDIKČNÝCH MODELOV	18
3.2.1	<i>ARIMAX.....</i>	<i>19</i>
3.2.2	<i>Neurónové siete.....</i>	<i>22</i>
3.2.3	<i>Neuro-fuzzy siete.....</i>	<i>26</i>
4	OVERENIE A POROVNANIE NAVRHNUTÝCH RIEŠENÍ	30
4.1	SIMULÁCIA TEPLoty VÝTLAKU	30
4.1.1	<i>Simulačný scenár 1.....</i>	<i>31</i>
4.1.2	<i>Simulačný scenár 2.....</i>	<i>33</i>
4.1.3	<i>Simulačný scenár 3.....</i>	<i>36</i>
4.1.4	<i>Simulácia návrhu na celé validačné obdobie.....</i>	<i>38</i>
4.2	VPLYV REDUKCIE DIMENZIONALITY	41
4.3	BUDÚCE SMEROVANIE PRÁCE	45
5	PRÍNOSY DIZERTAČNEJ PRÁCE.....	47
5.1	VYHODNOTENIE VÝSKUMNÝCH OTÁZOK.....	48
	ZOZNAM PUBLIKAČNEJ ČINNOSTI.....	51

ÚVOD

Dostupnosť tepla a elektriny je pre ľudskú spoločnosť a priemysel neodmysliteľnou súčasťou každodenného života. Pravidelný prístup k týmto komoditám berieme ako samozrejmosť, nakoľko dôsledky ich absencie našťastie ani nepocitujeme. Za stabilnou dodávkou týchto komodít stojí rokmi vybudovaná energetická infraštruktúra, ktorá každodenne je vystavená obrovskému náporu konzumnej spoločnosti. Je zrejmé, že takýto nátlak vyvinutý spoločnosťou má negatívny dopad na našu Zem. Ľudstvo si plne uvedomuje tieto dôsledky a aj fakt, že máme k dispozícii obmedzené množstvo obnoviteľných zdrojov energií. Práve tieto hrozby sú mementom pre spoločnosť aby energetická infraštruktúra prešla modernizáciou, ktorá zaručuje ekologicky prijateľnú, ekonomicky výhodnú výrobu a dodávku energií.

V súčasnosti sme svedkami veľkých zmien v energetike, ktoré sa týkajú najmä využívania kogeneračných jednotiek, obnoviteľných zdrojov energie, skladovania energie v akumulčných jednotkách a v neposlednom rade integrácie informačných a komunikačných technológií do jednotlivých fáz plánovania, výroby a distribúcie. Digitalizácia vo všetkých fázach výroby a distribúcie hrá významnú úlohu v optimalizácii výroby, ktorého dôsledkami je znižovanie cien energií a v neposlednom rade význame prispieva aj k znižovaniu emisných plynov. Dôsledkom digitalizácie výroby a distribúcie je veľké množstvo dát, ktoré vhodnými algoritmi dokážeme spracovať do takej formy, ktoré dokážeme využiť za účelom optimalizácie rôznych procesov, podpory plánovania, rozhodovania a pod.

Predkladaná dizertačná práca pojednáva o inteligentných metódach predikcie spotreby tepla a teploty spiatocky pre sústavu centrálného zásobovania teplom. Naším cieľom je návrh predikčných modelov odberu tepla a teploty spiatocky, ktoré sú použiteľné v rôznych ročných obdobiach. Tieto spomínané atribúty sú nevyhnutné pre výpočet teploty výtlaku teplonosného média, ktorá je kritická pre efektívne a udržateľné fungovanie teplárenskej sústavy. Centrálné zásobovanie teplom je charakteristické tým, že je to systém s pomalou dynamikou t.j. akákoľvek zmena riadenia sa prejaví až o niekoľko hodín a preto je obzvlášť nevyhnutné poznať budúci vývoj, aby prevádzkovatelia sústav dokázali čo v najkratšom čase reagovať na akúkoľvek zmenu. Častokrát sa stáva to, že operátori sú odkázaní na svoje skúsenosti dôsledkom absencie predikčných modelov odberu tepla. Ak chceme predísť nežiaducim stavom je nevyhnutné minimalizovať zlyhanie ľudského faktora. Budúci vývoj akéhokoľvek systému dokážeme predpovedať pomocou jeho modelu, ktorý disponuje analogickými vlastnosťami ako skúmaný systém. Model predstavuje základný pilier efektívneho riadenia sústavy centrálného zásobovania teplom. Za účelom vytvorenia modelu, ktorý najlepšie charakterizuje dynamické vlastnosti sústavy centrálného zásobovania teplom využijeme prvky umelej inteligencie – nelineárne modely neurónových sietí a neuro-fuzzy logiky, ktorých efektivitu porovnáваме s lineárnym autoregresívnym modelom

1 VÝCHODISKÁ A CIELE PRÁCE

Predkladaná dizertačná práca rieši problematiku predikcie spotreby tepla. Teplárenské systavy sú charakteristické svojou nelinearitou, veľkou zotrvačnosťou a nepravidelnosťou. Tieto spomínané vlastnosti sťažujú úlohu operátorov riadiaceho centra, ktorí sú zodpovední za riadenie sústavy. Značným deficitom je absencia predikcie spotreby tepla, ktorá je dôležitá pre plánovanie výroby t.j. radenia zdrojov tepla do prevádzky. Akýkoľvek chybný krok vypnutia či zapnutia zdroja môže predstavovať značné finančné straty a hlavne nedodanie množstva tepla v požadovanej kvalite ku koncovým odberateľom.

Na zabezpečenie efektívneho chodu sústavy CZT je nevyhnutné poznať plánovaný dopyt po teple tak, aby sme vyhli vyššie uvádzaným ťažkostiam. Efektívnym nástrojom je aplikácia pokročilých metód dátovej analýzy, ktorá otvára možnosti pochopenia správania sa odberateľov, ktorých tendencia odberu ovplyvňuje výrobu tepla. Tieto poznatky slúžia ako vstupy pre vytvorenie predikčného modelu na báze vstupno-výstupných vzťahov.

Vyššie uvádzané problémy tvoria podklad pre náš hlavný cieľ, ktorý formulujeme nasledovne: *Analýza dát z teplárenského prostredia a následný návrh predikčných modelov spotreby tepla a ich overenie pomocou simulačných výpočtov pre potreby plánovania výroby tepla.*

Úspešné splnenie hlavného cieľa dizertačnej práce je definované čiastkovými úlohami, ktoré sú nasledovné:

- *Vymedzenie teoretických východísk skúmanej problematiky z dostupnej vedecko-výskumnej literatúry* – vytvorenie prehľadu dostupných riešení z oblasti predikcie spotreby tepla. Tento krok zahŕňa štúdium teórie potrebnej k analýze dát a modelovaniu. Súčasťou je aj oboznámenie sa s metodikou CRISP-DM, ktorú použijeme pri riešení dizertačnej práce.
- *Stanovenie výskumných cieľov* – počiatočné oboznámenie sa s dátami a jednoznačné určenie smeru riešenia problematiky. V tejto predkladanej práci sa zameriame na efektivitu dátových modelov, kde porovnáme presnosť a efektivitu generalizácie štatistických metód a metód strojového učenia na nových dátach.
- *Analýza skúmaného objektu a modelovanie spotreby tepla* – na základe analýzy dát jednoznačne stanovíme signifikantné faktory, ktoré popisujú dynamiku odberu tepla. Keďže pracujeme s nestacionárnymi dátami pre časovo-frekvenčnú analýzu budeme využívať štatistickú analýzu. Druhým dôležitým krokom bude návrh predikčných modelov. Zameriame sa predovšetkým na dve skupiny a to na štatistické modely a modely strojového učenia.
- *Overenie navrhnutých riešení* – pomocou štatistických kritérií popíšeme kvalitu jednotlivých modelov a zhodnotíme ich klady a zápory.
- *Zhodnotenie prínosov dizertačnej práce* – na základe analýzy, návrhu a validácie riešenia stanovíme oblasti, v ktorých môže byť predkladaná dizertačná práca prínosná.

Na základe hore uvedenej analýzy problémovej oblasti môžeme sformulovať nasledovné výskumné otázky:

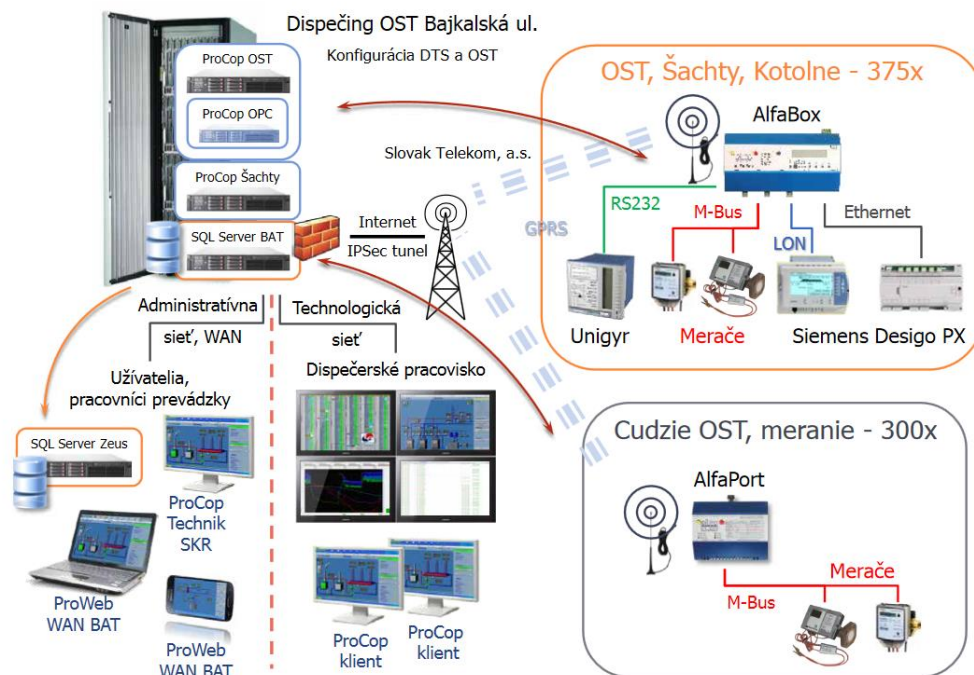
- *Štatistické modelovanie či modelovanie pomocou umelej inteligencie je vhodnejšie na riešenie problematiky predikcie spotreby tepla?*
- *Ako dokážeme znížiť komplexnosť a zvýšiť schopnosť generalizácie navrhnutých modelov?*

2 ANALÝZA SÚČASNÉHO STAVU

Súčasťou tejto kapitoly je popis sústavy CZT a analýza dát prostredia teplárne.

2.1 Analýza súčasného stavu spoločnosti Bratislavská teplárenská, a.s.

Sústavu CZT spoločnosti Bratislavská teplárenská, a.s. je rozdelená na tri časti a to na sústavu Východ, sústavu Západ a na prevádzku Juh. Túto komplexnú sústavu tvoria zdroje s celkovým inštalovaným tepelným výkonom 518,9 MW, pričom tento výkon je dodávaný cez primárne potrubia, ktorých dĺžka presahuje 358 km a sústavu dotvára približne 1390 odberných miest (MHTH, 2023). Spoločnosť v roku 2021 dodala celkovo 943 GW tepla pričom straty v tepelno-technických zariadeniach dosiahli hodnotu 89 GW (MHTH, 2021). Táto obrovská sústava obsahuje takmer 3000 kusov meracích prístrojov tepla a prietoku. Takáto veľká sústava vyžaduje riadiace systémy, ktoré zabezpečujú plynulú, bezpečnú a stabilnú prevádzku celej sústavy CZT. Zber údajov zo snímacích, meracích a lokálnych riadiacich systémov je zabezpečené pomocou zberníc RS232, M-bus a Ethernet. Zozbierané údaje sú koncentrované v AlfaBoxoch, ktoré v pravidelných 10 minútových intervaloch odosielajú zozbierané dáta z OST do riadiaceho systému dispečingu pomocou bezdrôtovej technológie GPRS. Monitorujú sa údaje ako okamžitý výkon, prietok, teplota výtlaku a vratného média, celkový tepelný výkon a celkový prietok. Schéma komunikácie OST s dispečingom je zobrazená na obrázku 1 (Bartoš, 2016).



Obrázok 1 Schéma zberu údajov (Bartoš, 2016)

Prevádzkový režim riadenia výkonu zdrojov vychádza z vypracovaného denného teplotného zaťaženia dispečingom a krytie jednotlivých zdrojov je vopred stanovený na týždennej báze, ktorý je denne upresňovaný. Pri zaraďovaní zdrojov do prevádzky musí byť dodržaná zásada prednostného využívania KVET (kombinovaná výroba elektriny a tepla) a najnižších nákladov na výrobu.

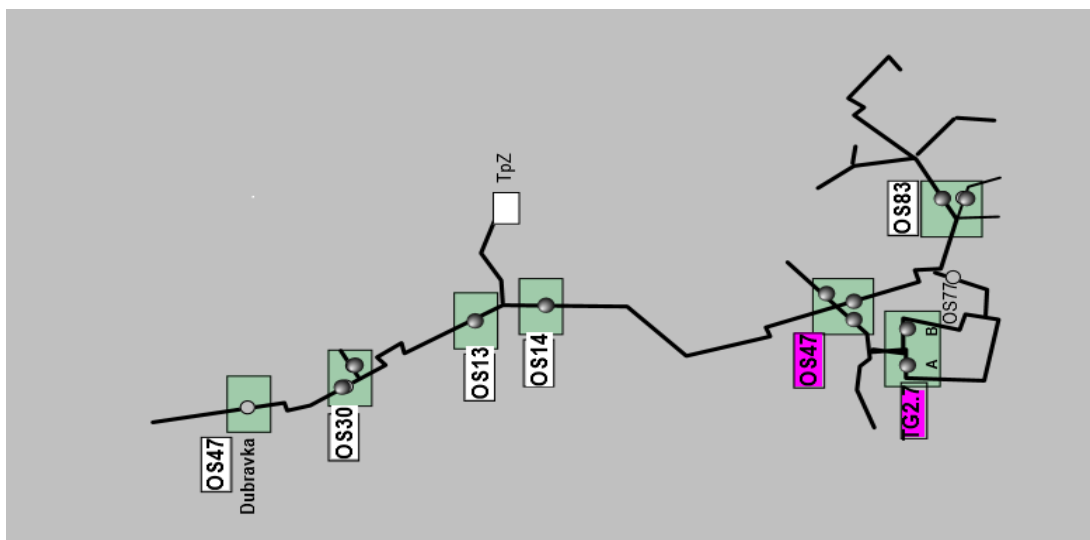
Neodmysliteľným nástrojom pre efektívny chod celej sústavy je softvérový produkt Termis od spoločnosti Schneider Electric. Program je založený na matematickom modeli,

ktorý komplexne popisuje všetky prvky v sústave CZT. Spoločnosť pre efektívnu prevádzku využíva nasledovné moduly (ASB, 2017), (Schneider Electric 2014):

- OFF LINE – zabezpečuje statické výpočty hydraulických a tepelných pomerov celej sústavy t.j. výstupom je prerozdelenie výkonu zdrojov, stanovenie teplotných i tlakových pomerov v rôznych bodoch sústavy, určenie teplotných strát a pod. Veľkým prínosom je, že tento modul dokáže nasimulovať a aj vyhodnotiť vplyv pripojenia nových odberateľov do sústavy.
- ON LINE – predstavuje rozšírenú verziu OF LINE modulu, nakoľko ON LINE modul na výpočet tepelných a hydraulických pomerov využíva aktuálne dáta z prevádzky.
- Optimalizátor teploty – tento modul zabezpečuje optimalizáciu teploty výtlaku a prietoku. Optimalizácia je založená na metóde lineárneho programovania. Predpokladom optimalizácie je predikcia odberu tepla, ktorá je tvorená regresným modelom. V súčasnom nastavení tento modul dokáže predikovať predpokladaný tepelný výkon na 18 hodín vopred.

2.1 Sústava Západ


Sústava Západ disponuje celkovým maximálnym tepelným výkonom 146 MW. Tento tepelný výkon dodáva tepláreň Západ, ktorý disponuje aj s kogeneračnou jednotkou, ktorá je schopná dodať elektrický výkon do 25 MW do prenosovej sústavy. Tepelný výkon zo zdrojov je dodávaný do OST, ktoré sa nachádzajú v mestských častiach Bratislavy a to konkrétne v Karlovej Vsi a v Dúbravke vid' obrázok 2. Tepláreň Západ obsahuje parný kotol K6 s maximálnym tepelným výkonom 102 MW a turbogenerátor Tg1 s maximálnym elektrickým výkonom 25 MW. Táto kombinácia zabezpečuje takzvanú kombinovanú výrobu elektriny a tepla (KVET). Tento zdroj primárne zabezpečuje tepelný výkon, ktorý je potrebný počas vykurovacieho obdobia a jeho nábeh je približne na úrovni štyroch až piatich hodín. Súčasťou sú aj horúcovodné kotly HK1 a HK3. Maximálny výkon týchto zariadení je 15 MW resp. 45 MW a ich primárne využitie je počas špičiek a zabezpečenie letného teplotného zaťaženia. Nábeh týchto zdrojov je približne polhodina. Maximálny výkon zdrojov tepla je dosiahnuteľný pri súčasnej prevádzke jednotlivých zdrojov tepla pri prietoku 2100 t/h a pri teplotnom spáde teplotnosného média 115/55°C (výtlak/spiatočka) (MHTH, 2021), (Kostolanská, 2021).



Obrázok 2 Schéma sústavy Západ

Tepelný výkon zo zdrojov Západ je dodávaný cez dvojicu potrubí DN 600, ktorý sa rozdeľuje na dve vetvy Dúbravka (DN 450) a Karlova Ves (DN 600). Tieto potrubia celkovo zásobujú teplom výše 160 OST. Celková dĺžka primárnych potrubí v sústave Západ je približne 56 km.

Zdroj CogenWest sa nachádza v blízkosti zdroja Tepláreň Západ a už zo samotného názvu vyplýva, že sa jedná o kogeneračnú výrobu elektriny a tepla pomocou dvoch motorových generátorov. Tieto motorové generátory pri maximálnom zaťažení sú schopné dodať 9,2 MW tepelného výkonu a 8,6 MW elektrickej energie. Dodaný výkon do sústavy z jednotlivých zdrojov je zobrazený na obrázku 3.



Obrázok 3 Tepelný výkon zdrojov (zdroj: vlastné spracovanie)

Celkový výkon SCZT je určený orientačne v závislosti od vonkajších klimatických podmienok a na základe skúseností operátorov dispečingu. Požadované zmeny výkonu vykonáva operátor dispečingu na základe poveternostnej situácie a predpokladaného denného teplotného zaťaženia.

Dodané množstvo tepla Q_t môžeme vypočítať na základe nasledovného vzťahu (1):


$$Q_{(t)} = c_p \times m_{(t)} \times (Tv_{(t)} - Ts_{(t)}) \quad (1)$$

kde c_p merné skupenské teplo vody, $m_{(t)}$ – prietok, $Tv_{(t)}$ – teplota výtlaku, $Ts_{(t)}$ – teplota spiatočky.

Operátor dispečingu počas plánovania výroby tepla vychádza z ekvitermických kriviek (ET), ktoré predstavujú závislosť teploty výtlaku $Tv_{(t)}$ a spiatočky $Ts_{(t)}$ od vonkajšej teploty. Táto závislosť je definovaná nasledovným matematickým vzťahom (2):

$$\begin{aligned} Tv_{(t)} &= -1,334 \times \text{vonkajšia teplota} + 99 \\ Ts_{(t)} &= -0.1667 \times \text{vonkajšia teplota} + 54 \end{aligned} \quad (2)$$

ET krivky s teplotným spádom 115°C/75°C pre teplotu výtlaku a 55°C/50°C sú zobrazené na obrázku 4.



Obrázok 4 Ekvitermické krivky

Prietok teplotnosného média dokážeme vypočítať úpravou vzťahu (1), z ktorého dostaneme nasledovný vzťah (3):

$$m_{(t)} = \frac{Q_{(t)}}{cp \times (T_{v(t)} - T_{s(t)})} \quad (3)$$

Vypočítané hodnoty slúžia ako žiadané hodnoty pre riadiaci systém. Je potrebné poznamenať, že celkové dodané množstvo tepla $Q_{(t)}$ sa skladá z teplotných strát spojených s distribúciou tepla a odberu tepla odoberateľmi (4):

$$Q_{(t)} = Q_{straty} + Q_{odber} \quad (4)$$

Pre efektívne fungovanie sústavy CZT je nevyhnutné vedieť čo najpresnejšie predpovedať odber tepla aby straty spojené s distribúciou a zlým odhadom odberu boli čo najnižšie pretože nadbytočné teplo dôsledkom absencie zásobníkov nie je možné skladovať. V súčasnosti firma disponuje predikčným modelom odberu tepla na 18 hodín vopred.

2.2 Dátový set a analýza dát

Dáta, ktoré popisujú teplárenskú sústavu v tejto dizertačnej práci boli poskytnuté Bratislavskou teplárenskou, a.s., vo formáte *.xlsx. Historické meteorologické dáta boli zakúpené a stiahnuté zo stránky www.meteoblue.com, takisto vo formáte *.xlsx. K dispozícii máme dáta z obdobia 2019 až začiatok roka 2022. Dáta boli evidované v hodinových intervaloch. Bližší popis jednotlivých dát je v podkapitolách.

2.2.1 Predspracovanie dát

Predspracovanie dát môžeme chápať ako transformáciu a úpravu (čistenie) dát, za účelom zvýšenia presnosti predikčných modelov. Predspracovanie pozostáva z dvoch hlavných krokov a to z čistenia a transformácie.

2.2.2 Úprava dát

Proces čistenia dát predstavuje súbor krokov, ktoré vedú k identifikácii a nahradení chýbajúcich resp. poškodených záznamov za účelom zvýšenia kvality dát. Príčinou chýbajúcich záznamov môže byť niekoľko. K najčastejším príčinám patria chyby počas merania, výpadok komunikácie a pod.

Nasledovné kritéria boli skúmané pre účely identifikácie dát, ktoré je nevyhnutné predspracovať:

- *Systémové obmedzenia* – predstavuje súbor obmedzení, ktoré musia dáta spĺňať, aby boli považované za relevantné. Ak takúto podmienku dáta nespĺňajú, tak ich môžeme vymazať alebo nahradiť. K systémovým obmedzeniam patria napr. fyzické obmedzenia systému t.j. neexistuje aby spotreba tepla bola negatívna.
- *Odláhlé hodnoty merania* – pod odláhlými meraniami budeme chápať dáta, ktoré značným spôsobom odlišujú od ostatných meraní. Príčinou odláhlých dát môže byť mnoho najčastejšie je to zle kalibrované meracie zariadenie. Musíme si uvedomiť, že nie každá odláhlá hodnota musí predstavovať chybný záznam často sú to záznamy, ktoré predstavujú extrémne hodnoty, ktoré boli spôsobené určitými udalosťami. Preto je potrebné správne identifikovať a odlíšiť chybné hodnoty merania od extrémov.
- *Chýbajúce záznamy* – za chýbajúce záznamy budeme považovať, postupnosť takých záznamov, kde neexistuje meranie v danom časovom okamihu. Príčinou chýbajúcich záznamov môže byť porucha meracieho zariadenia či problémy počas prenosu dát do nadriadeného systému.

Pri predspracovaní dát si musíme uvedomiť, že akýkoľvek nadmerný zásah môže zmeniť pôvodnú štruktúru dát čo môže skresliť úspešnosť predikčných modelov, preto pri tomto kroku treba postupovať s rozvahou a snažiť sa zanechať čo najpôvodnejšiu štruktúru dát. Prvotným krokom pri úprave dát je vizuálna inšpekcia, pomocou ktorej dokážeme identifikovať chýbajúcu sekvenciu dát či niektoré odláhlé merania. Pri identifikácii meraní mimo rozsahu je nevyhnutné použiť štatistické ukazovatele napr. kľzavé priemery, kvartilové rozpätie, ktoré popisujú dáta. Pomocou týchto ukazovateľov dokážeme identifikovať a aj potvrdiť, že sa jedná o chybné merania, ktoré následne môžeme nahradiť. Predspracovanie dát sme vykonali pomocou interaktívneho nástroja Data Cleaner v prostredí Matlabu. Tabuľka 1 zobrazuje aplikované algoritmy pre identifikácie chýbajúcich/odláhlých záznamov a aplikované algoritmy nahradenia chýbajúcich/odláhlých záznamov.

Tabuľka 1 Súhrn vykonaných operácií počas úpravy dát

Názov	Chýbajúce záznamy		Odláhlé hodnoty merania	
	počet	Metóda nahradenia	Metóda identifikácie	Metóda nahradenia
Teplota výtlaku	7	24 hod. kľzavý priemer	24 hod. kľzavý priemer	Lineárna interpolácia
Teplota spiatocky	7	24 hod. kľzavý priemer	24 hod. kľzavý priemer	Lineárna interpolácia
Prietok	7	24 hod. kľzavý priemer		

Tlak výtlak	7	24 hod. kľzavý priemer	Kvartilové rozpätie	Lineárna interpolácia
Tlak spiatocky	7	24 hod. kľzavý priemer	/	
Odber tepla	561	168 hod kľzavý priemer		

Chýbajúce záznamy zo systémových parametrov pochádzali z letného obdobia obdobne aj chýbajúce záznamy z odberu tepla. Toto zistenie je mimoriadne dôležité nakoľko sme nevykonali žiadnu manipuláciu dát vo vykurovacom období, v ktorom odber tepla závisí od rôznych faktorov.

2.2.3 Transformácia dát

Proces transformácie dát reprezentuje postupnosť krokov, ktorých účelom je transformácia dátových množín do takej podoby, ktoré zvýšia kvalitu navrhnutých predikčných modelov.


Najznámejšou takouto transformáciou je transformácia dátumu merania na maticu kalendárnych dát. Pod kalendárnymi dátami budeme chápať dáta, ktoré sú späté kalendárnymi udalosťami. Tieto dáta nepriamo ovplyvňujú spotrebu tepla. Slúžia predovšetkým na lepšiu charakteristiku predikčného modelu, pretože sú zdrojom informácií, cyklicky sa opakujúcich komponentov, ktoré predovšetkým popisujú správanie sa odoberateľov. Pomocou kalendárnych udalostí vieme popísať hlavne dynamiku jednotlivých dní v týždni a taktiež aj vzťahy s meteorologickými dátami napr. dopyt v jednotlivých ročných obdobiach a pod.

Nasledovné kalendárne faktory boli odvodené z dátumu merania:

- *Hodina* – predstavuje hodinu dňa v rozsahu 0 až 23 hodín
- *Deň* – predstavuje vektor celých čísel, pričom nedele sú zakódované ako 1, pondelky ako 2 atď.
- *Mesiac* – predstavuje vektor celých čísel, ktoré popisujú aktuálny mesiac v roku.
- *Víkend* - predstavuje vektor binárnych hodnôt t.j. ak deň nie je pracovným dňom potom premenná víkend nadobúda hodnotu 1 inak povedané pracovné dni sú zakódované ako 0.


2.2.4 Popis a analýza spotreby tepla

Pri pohľade na graf spotreby tepla (obrázok 5), dokážeme identifikovať základné znaky, ktoré popisujú tendenciu spotreby tepla používateľov. Prvotným takýmto znakom je, že odber tepla rapídne klesá počas letných teplých dní kedy dodané teplo je predovšetkým využité vo forme TÚV a naopak počas chladnejších dní odber tepla sa zvyšuje prevažne dôsledkom vykurovania.



Obrázok 5 Odber tepla a vonkajšia teplota


Tento sezónny jav je dobrý známy, avšak obsahuje predovšetkým informácie, ktoré sú relevantné pre potreby predikcie z dlhodobého hľadiska. Pre extrakciu detailnejších informácií potrebujeme preskúmať kratšie časové horizonty. Prvou takouto analýzou je priemerná týždňová analýza odberu tepla, ktorá je rozdelená do ročných období (obrázok 6).



Obrázok 6 Ročné obdobia

Z obrázka 6 vieme vyčítať zaujímavé informácie ako napr. mesiace september až november a marec až máj majú vysokú fluktuáciu. Tento fakt predstavuje nevyspytateľnosť vykurovacieho obdobia spôsobenú predovšetkým poveternostnými podmienkami. Ďalej potvrdzujeme aj fakt, že počas letných mesiacov je odber takmer

konštantný za celé obdobie. Ďalším relatívne stabilným obdobím môžeme považovať aj zimné mesiace, kde celkový odber je niekde pri hranici 45 MW až na zopár výnimiek nad touto hranicou resp. pod, ktoré sú dôsledkom chladnejších/teplejších dní. Pre získanie podrobnejších informácií potrebujeme analyzovať denné profily (obrázok 7).

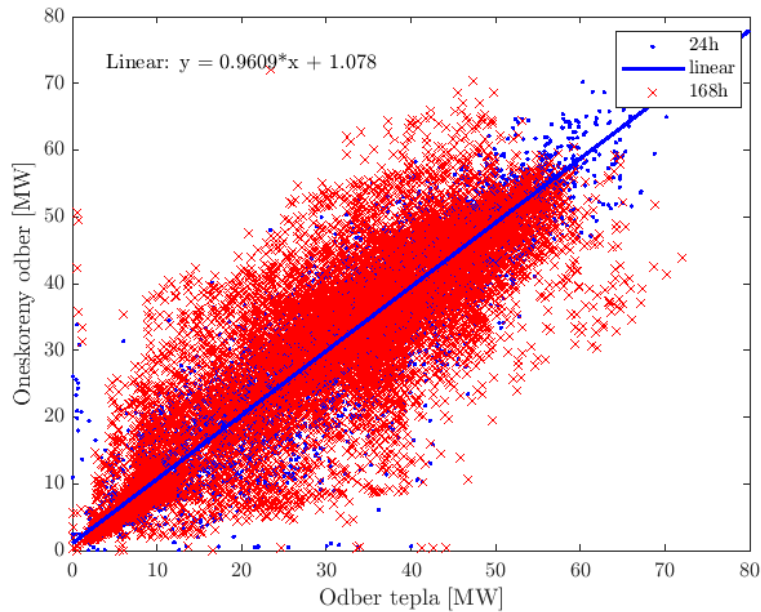


Obrázok 7 Priemerné denné profily

Z denných profilov obrázka 7 dokážeme identifikovať rannú špičku kedy odoberatelia sa chystajú do práce, škôl a pod. dôsledkom zvýšeného odberu môže byť ranné prikúrenie, či zvýšená úroveň použitia TÚV a následný pokles odberu, ktorý je spôsobený pravdepodobne odchodom ľudí do zamestnaní, škôl a pod. Ďalšou takouto špičkou je večerná špička, kedy sa obyvatelia vracajú z roboty a prikurujú si obydlia, či využívajú väčšie množstvo TÚV pre potreby hygieny a potom nasleduje nočný útlm. Zaujímavým zistením je rozdiel medzi víkendom a pracovnými dňami. Počas víkendov priemerná hodnota odberu tepla počas ranej špičky je signifikantne nižšia ako počas pracovných dní. Ranná špička má dve fázy, prvá fáza medzi 5 a 7 hodinou a následný útlm. Tento jav môže spôsobiť aj to, že istá časť odoberateľov vstáva skôr. Druhá fáza ranej špičky začína od 8 do 10 hodiny kedy sa väčšina ľudí zobúdzajú. Z denného profilu môžeme skonštatovať, že odber má 24 hodinový cyklus (denný).

2.2.5 Popis a analýza technologických faktorov

Pod technologickými dátami budeme chápať tie dáta, ktoré súvisia s teplárenskou technológiou. Na základe poznatkov z fyziky vieme, že teplárenské systémy sú systémy, ktoré sú charakteristické s pomalou dynamikou teda jednoduchšie povedané systémy majú veľkú zotrvačnosť. Akákoľvek zmena vo výrobe sa môže prejaviť u koncového užívateľa až o niekoľko hodín. Na základe týchto faktov s vysokou pravdepodobnosťou môžeme skonštatovať, že aktuálny odber tepla zo sústavy bude približne rovný odberu zo sústavy o pár dní skôr. Toto tvrdenie potvrdzuje analýza obrázka 8, z ktorého vidieť silnú lineárnu závislosť aktuálneho odberu od odberu z predchádzajúceho dňa (modré bodky), kde koeficient determinácie r^2 je 0,92 v porovnaní s odberom o 168 hodín t.j. o týždeň neskôr (červené krížiky) kde koeficient determinácie $r^2 = 0,70$.




Obrázok 8 Závislosť aktuálneho odberu od predchádzajúceho dňa

Vychádzajúc z faktu zotrvačnosti sústavy a princípom fungovania dodávky tepla ku koncovým užívateľom tak môžeme povedať, že dôležitým faktorom sú aj teplota teplonosného média v primárnom okruhu či prietok. Štatistické vlastnosti spomínaných parametrov sú zobrazené v tabuľke 2.

Tabuľka 2 Súhrn interných faktorov

Názov	Jednotka	Min	Max	Priemer
Teplota výtlaku	°C	77,85	113,88	81,57
Teplota spiatočka	°C	41,73	70,47	50,54
Tlak výtlaku	MPa	0,80	1,33	1,01
Tlak spiatočky	MPa	0,23	0,84	0,65
Prietok	kg/s	0	1594,4	716,38

Z pohľadu na korelačnú mapu obrázok 9 môžeme určiť, že takmer všetky interné faktory majú silnú koreláciu s odberom tepla. Dôležité je vyzdvihnúť predovšetkým dva parametre. Prvým parametrom je prietok, ktorý predstavuje množstvo dodaného teplonosného média za jednotku času. Regulovaním hodnoty prietoku dokážeme zvýšiť/znížiť dodané množstvo tepla. Druhým dôležitým parametrom je teplota výtlaku, ktorá obdobne popisuje množstvo dodaného tepla, teda ak zvýšime teplotu výtlaku potrebujeme nižší prietok na dodanie istého množstva tepla a naopak.



Obrázok 9 Korelačná mapa odberu tepla a interných faktorov

2.2.6 Popis a analýza meteorologických faktorov

Meteorologické faktory patria k najdôležitejším a najčastejšie použitým faktorom na tvorbu predikčných modelov spotreby tepla. K tomuto prispieva hlavne fakt, že klimatické vplyvy značne ovplyvňujú reakciu ľudí čo sa týka spotreby tepla. Jedným z kľúčových činiteľov, ktorý popisuje spotrebu tepla je predovšetkým vonkajšia teplota. Medzi spotrebou tepla a vonkajšou teplotou existuje silná záporná korelácia, ktorá hovorí pri poklese vonkajšej teploty sa zvyšuje spotreba tepla. K menej dôležitým faktorom môžeme priradiť ďalšie meteorologické vplyvy ako napr. úhrn zrážok. Tento vplyv ovplyvňuje predovšetkým ľudské aktivity, ktoré môže spôsobiť zvýšenú spotrebu tepla. Takisto je potrebné zmierniť sa aj o iných faktoroch ako rýchlosť vetra či slnečný svit, oblačnosť. Tieto faktory síce nepredstavujú významnú koreláciu medzi spotrebou tepla avšak z pocitového vnímania vieme, že tieto ukazovatele značne vplyvajú na celkový ľudský komfort. Preto tieto faktory dokážu zvýšiť presnosť predikčného modelu.

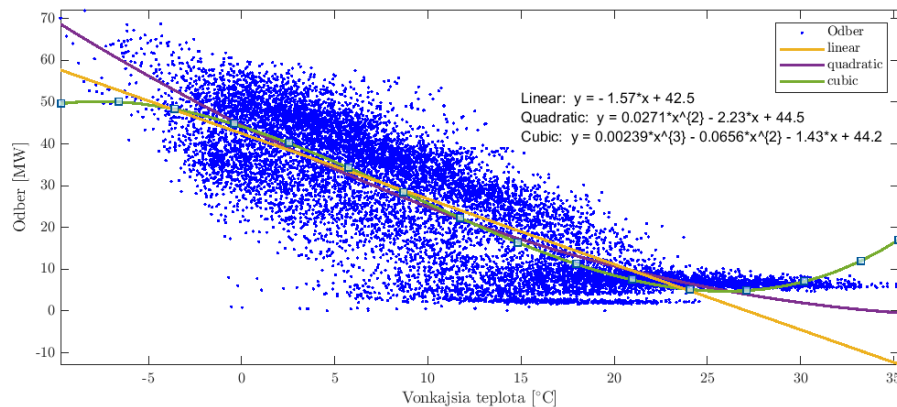
V tejto práci budeme analyzovať vplyvy nasledovných meteorologických dát na spotrebu tepla, ktoré sú prezentované v tabuľke 3:

Tabuľka 3 Súhrn meteorologických faktorov

Názov	Jednotka	Min	Max	Priemer	Korelačný koeficient
Vonkajšia teplota	°C	-9,71	38,5	11,24	-0,81
Dĺžka slnečného svitu	min	0	60	17,85	-0,16
Slnečné žiarenie	W/m ²	0	884,66	162,71	-0,20
Zrážky	mm	0	7,7	0,046	-0,01
Snehové zrážky	cm	0	1,89	0,001	0,06
Vlhkosť	%	17	100	67,38	0,32

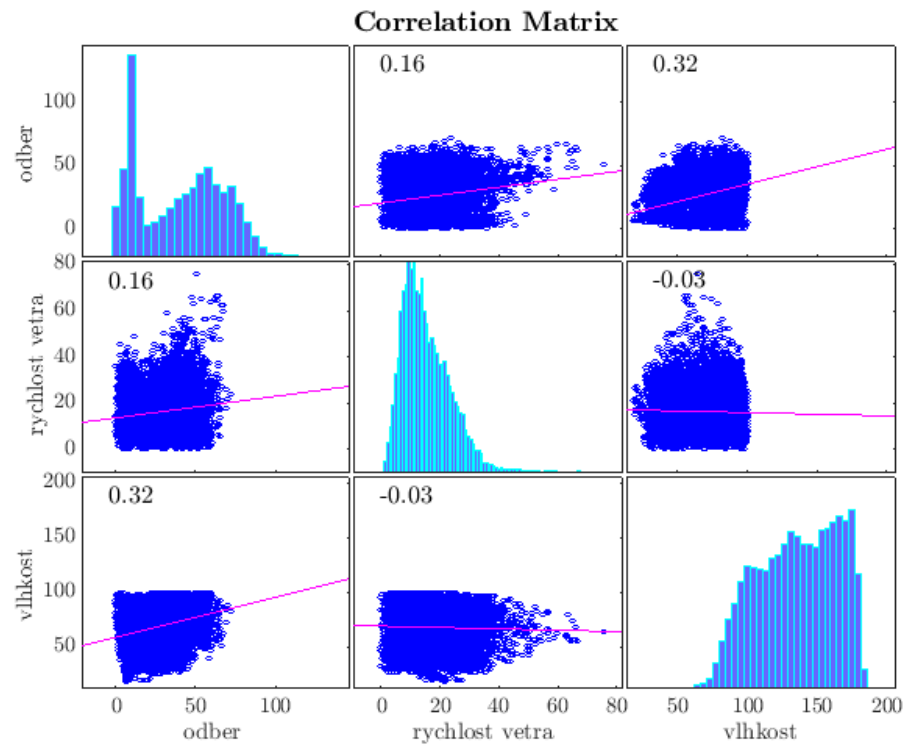
Oblačnosť	%	0	100	41,23	0,15
Rýchlosť vetra	km/h	0	75,71	16,27	0,16
Smer vetra	°	0.52	360	213,21	0

Výchádzajúc z korelačných koeficientov z tabuľky 3, môžeme zhodnotiť, že najsilnejšia korelácia je medzi odberom tepla a vonkajšou teplotou. Táto závislosť je vizuálne prezentovaná na obrázku 10, z ktorej vidieť silnú negatívnu závislosť predovšetkým po bod zlomu, ktorý je približne na úrovni 15 °C čo predstavuje teplotu, pre potreby vykurovania. Táto závislosť nie je čisto lineárna nakoľko nelineárne funkcie (kvadratická, kubická) mali vyšší koeficient determinácie r^2 než lineárna funkcia.



Obrázok 10 Vonkajšia teplota vs odber tepla

Relatívne silná korelácia je medzi intenzitou slnečného žiarenia a vlhkosťou. Intenzita slnečného žiarenia ovplyvňuje správanie sa odoberateľov nakoľko niektoré materiály dokážu absorbovať, prepúšťať teplo a teda sa môže javiť, že pocitová teplota je vyššia. Ďalším parametrom je vlhkosť a obdobne môže vyvolať opačný pocit ako intenzita slnečného žiarenia. Príliš vlhké prostredie či už vyššia rýchlosť vetra dokáže budovy „schladiť“ čo môže spôsobiť nižšiu pocitovú teplotu. Na základe analýzy korelačných koeficientov z obrázka 11 a z tabuľky 3 môžeme skonštatovať, že niektoré meteorologické faktory síce nemajú silnú koreláciu s odberom tepla. Avšak nemôžeme celkom vylúčiť tieto faktory, nakoľko ako celok značne ovplyvňujú pocitové vnímanie vonkajšej teploty.



Obrázok 11 Korelačná mapa meteorologických faktorov

3 NÁVRH A TVORBA Návrh a tvorba predikčných modelov

Táto kapitola popisuje jednotlivé kroky tvorby jednotlivých predikčných modelov odberu tepla a teploty spiatocky v prostredí MATLABu.

3.1 Hodnotiace kritéria kvality modelov

Aby sme mohli kvalitu navrhnutých modelov vyhodnotiť je nutné zaviesť numerické ukazovatele, ktoré vyjadrujú kvalitu prezentovaných riešení. Existuje množstvo metrík, ktoré je možné použiť na vyhodnotenie presnosti modelov, preto je nevyhnutné použiť viacero ukazovateľov pre objektívne vyhodnotenie presnosti. Kvalita predikčných modelov bude ohodnotená pomocou nasledovných ukazovateľov:

- *Mean Absolute Error (MAE)*

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{Y}_i - Y_i| \quad (5)$$

kde n je počet vzoriek, \hat{Y}_i – predikované hodnoty a Y_i sú namerané hodnoty

- *Root Mean Square Error (RMSE)*

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2} \quad (6)$$

- *Mean Absolute Percentage Error (MAPE)*

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{Y}_i - Y_i|}{Y_i} \times 100\% \quad (7)$$

3.2 Tvorba predikčných modelov

Počas tvorby predikčných modelov sme vychádzali z nameraných dát z obdobia 1.1.2020 až po 1.5.2021 toto obdobie obsahovalo dostatočné množstvo dát z rôznych období, počas ktorých dynamika odberu tepla resp. fluktuácia teploty spiatocky je rozmanitá. Vstupné dáta pre navrhnuté modely boli určené na základe dátovej analýzy z kapitoly 2.2.4 až 2.2.6. Výstupom analýzy z uvádzaných kapitol vzniklo dvojdimenzionálne pole (matica), kde každý vstup predstavuje zvlášť stĺpec, potom takúto maticu vo všeobecnosti môžeme napísať nasledovne:

$$vstupy_{odber} = \begin{bmatrix} vonkT, vietor, vlhkosť, teplV, hodiny, \dots \\ odber_{t-24}, odber_t \end{bmatrix} \quad (8)$$

kde *vonkT* – vonkajšia teplota, *vietor* – rýchlosť vetra, *teplV* - teplota výtlaku, *hodiny* – hodina dňa, *odber_{t-24}* – odber tepla pred 24 hodinami, *odber_t* – aktuálny odber.

a pre teplotu spiatocky:

$$vstupy_{spiatocka} = \begin{bmatrix} vlhkosť, teplV, hodiny, \dots \\ spiatocka_{t-24}, spiatocka_t \end{bmatrix} \quad (9)$$

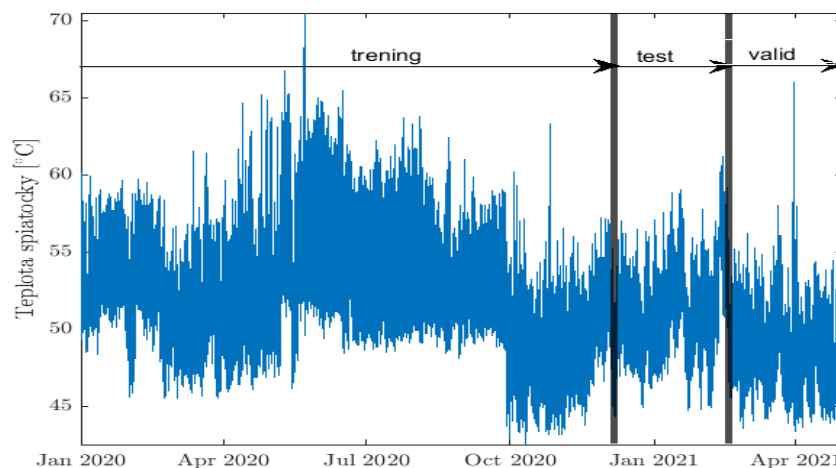
Zodpovedajúce výstupy k uvedeným vstupom (8) a (9) sú odber tepla a teplota spiatocky.

Naším cieľom je predikcia na 24 hodín vopred, samozrejme počas modelovania predikované hodnoty nepoznáme, preto potrebujeme transformáciu nameraných hodnôt odberu tepla a teploty spiatocky posunúť aby predstavovali nameranú hodnotu v čase t_{+24} . Obrázok 12 ilustruje logiku posunutia stĺpcov, ktorá pre najjednoduchšie pochopenie je demonštrovaná na dátume teda nameraný odber 2. septembra predstavuje aktuálny odber v čase t . Nameraný odber 1. septembra predstavuje odber v čase t_{-24} a odber 3. septembra teda predstavuje požadovaný výstup v čase t_{+24} , ktorý je predmetom predikcie.

	1	2	3
1	01-Sep-2021 00:00...	02-Sep-2021 00:00...	03-Sep-2021 00:00...
2	01-Sep-2021 01:00...	02-Sep-2021 01:00...	03-Sep-2021 01:00...
3	01-Sep-2021 02:00...	02-Sep-2021 02:00...	03-Sep-2021 02:00...
4	01-Sep-2021 03:00...	02-Sep-2021 03:00...	03-Sep-2021 03:00...
5	01-Sep-2021 04:00...	02-Sep-2021 04:00...	03-Sep-2021 04:00...
6	01-Sep-2021 05:00...	02-Sep-2021 05:00...	03-Sep-2021 05:00...
7	01-Sep-2021 06:00...	02-Sep-2021 06:00...	03-Sep-2021 06:00...
8	01-Sep-2021 07:00...	02-Sep-2021 07:00...	03-Sep-2021 07:00...

Obrázok 12 Vytvorenie $t+24$ matice

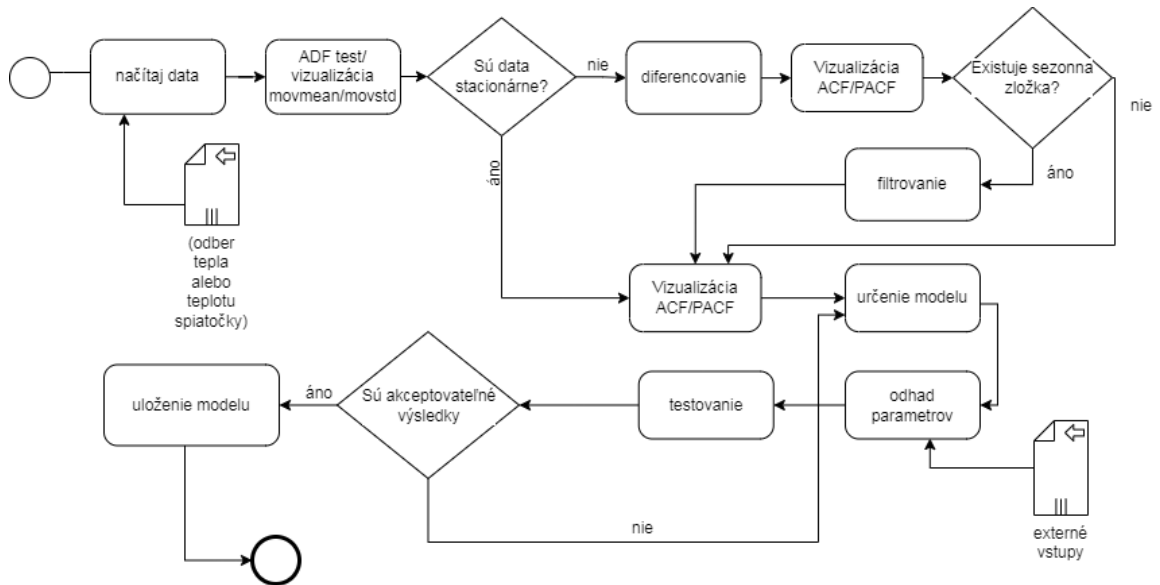
Predspracovanú sadu vstupných dát sme rozdelili pomocou funkcie *divideblock* a to v pomere 70:15:15 t.j. 70% dát bolo použitých na tréningovanie, 15% na testovanie a zvyšných 15% na validáciu navrhnutých modelov. Pri časových radoch je dôležité rozdelenie tak, aby ostala zachovaná pôvodná postupnosť meraní preto funkciu *dividerand* pri modelovaní časových radov nemôžeme použiť nakoľko prvky vektora sa rozdelia náhodne.



Obrázok 13 Rozdelenie dát


3.2.1 ARIMAX

Tvorba štatistických modelov je podmienená postupnosťou krokov, ktoré je nevyhnutné dodržať pre dosiahnutie akceptovateľných výsledkov. Pre lepšie pochopenie procesu modelovania bol navrhnutý BPMN diagram, ktorý je zobrazený na obrázku 14.



Obrázok 14 ARIMAX modelovanie BPMN(zdroj: vlastné spracovanie)


Z teoretických poznatkov vieme, že predpokladom tvorby štatistických modelov je to, že dáta sú stacionárne teda priemer a smerodajná odchýlka počas skúmanej doby sa nemení. Kľzavý priemer a kľzavá smerodajná odchýlka sú skvelým ukazovateľom na získanie prvotného obrazu o stacionarite dát. Pohľadom na obrázok 15 môžeme skonštatovať, že dáta odberu tepla a teploty spiatocky sú nestacionárne preto je nevyhnutné vykonať diferencovanie dát.



Obrázok 15 Nestacionárne dáta (zdroj: vlastné spracovanie)

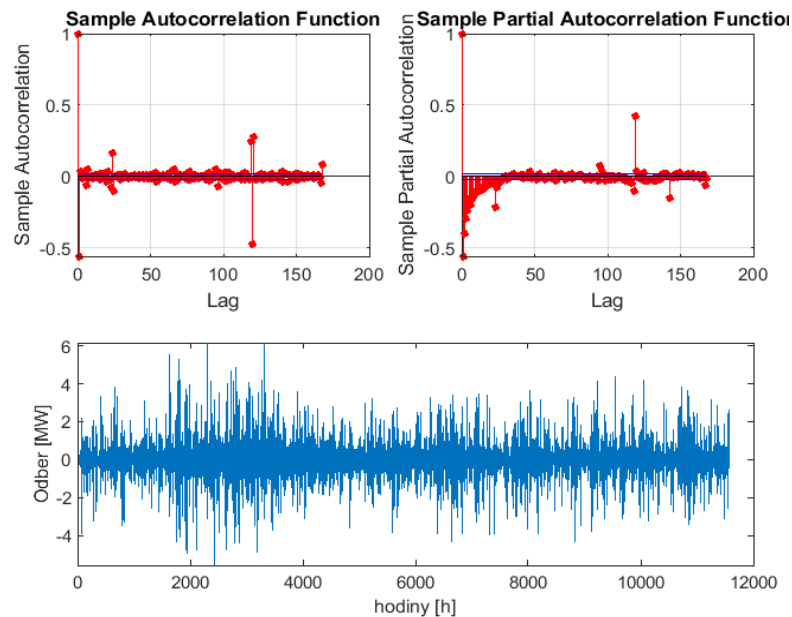
Nestacionaritu dát potvrdilo aj testovanie hypotézy pomocou metódy Dickey-Fuller kde hypotéza o stacionarite dát bola zamietnutá pre oba prípady (odber, teplota spiatocky).

Po aplikovaní diferencovania prvého rádu týždenné ACF a PACF grafy vyzerajú nasledovne (obrázok 16):



Obrázok 16 ACF a PACF po diferencovaní (zdroj: vlastné spracovanie)

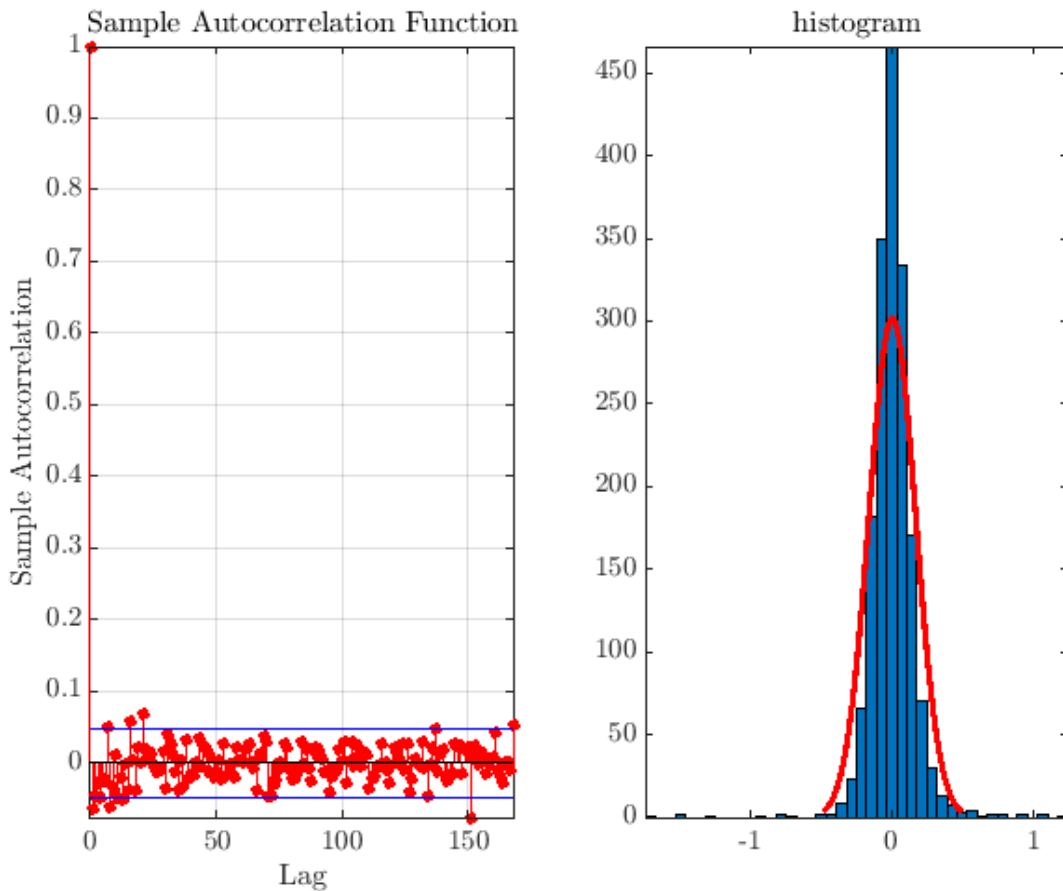
Inšpekciou obrázka 16 vidieť, že ACF graf obsahuje silnú sezónnu zložku, ktorá sa opakuje periodicky, každých 24 hodín. Tento sezónny komponent je nevyhnutné odstrániť aby sme mohli presne určiť rád modelu. Po aplikovaní sezónneho filtra na dáta ACF a PACF vyzerá nasledovne vid'. obrázok 17:



Obrázok 17 ACF a PACF po diferencovaní a filtrácii (zdroj: vlastné spracovanie)

Na základe poznatkov z kapitoly o štatistických modeloch dokážeme určiť typ a rád modelu. Keďže PACF funkcia exponenciálne klesá a ACF mizne po oneskorení q môžeme jasne stanoviť, že sa jedná o MA(q) model, ktorý podľa notácie ARIMA (p,d,q) \times (P,D,Q), kde P,D,Q hovoria o sezónnych zložkách môžeme prepísať ako ARIMA(0,1,1) \times (0,1,0) $_{24}$ a po zahrnutí externých vstupov dostávame konečný model ARIMAX (0,1,1) \times (0,1,0) $_{24}$. Parametre t.j. numerické koeficienty vstupných premenných boli určené pomocou funkcie estimate, ktorá využíva metódu maximálnej vierohodnosti na odhad parametrov modelu.

Na základe analýzy zvyškov (residuals) môžeme skonštatovať, že navrhnuté modely pre odber tepla a teploty spiatocky ARIMAX $(0,1,1) \times (0,1,0)_{24}$ sú správne a dostatočne popisujú dynamiku odberu tepla a teploty spiatocky. Toto tvrdenie potvrdzujú nasledovné zistenia, vychádzajúc z obrázka 18:

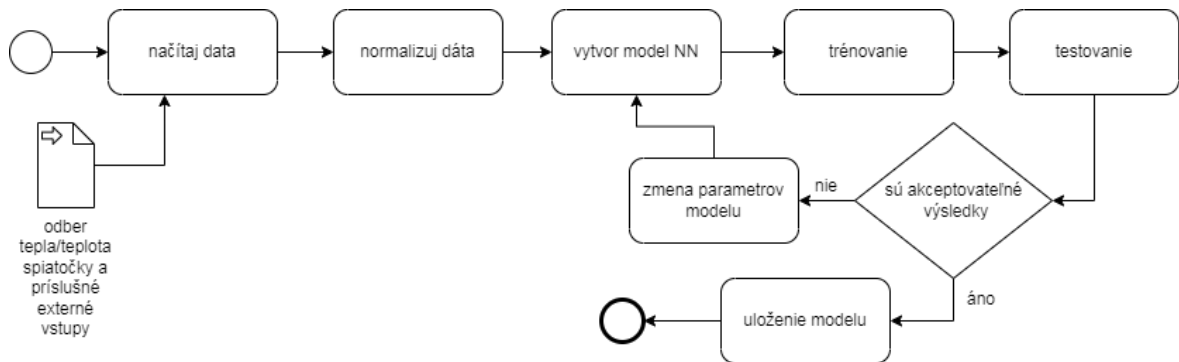


Obrázok 18 Analýza zvyškov

Autokorelačný graf zvyškov potvrdzuje, že neexistuje významná závislosť medzi jednotlivými pozorovaniami t.j. jedná sa o náhodné nekorelované pozorovania (biely šum) a histogram chýb má normálne rozdelenie priemer je rovný nule. Počas tvorby modelov boli otestované ďalšie kombinácie, avšak presnosť modelov bola nedostatočná.

3.2.2 Neurónové siete

Táto podkapitola popisuje proces tvorby modelov predikcie spotreby tepla a teploty spiatocky pomocou neurónových sietí. Modely neurónových sietí patria do skupiny dátovo orientovaných modelov. Celý proces tvorby modelov je zobrazený na BPMN diagrame na obrázku 19.



Obrázok 19 BPMN diagram tvorby NN modelu

Keďže sa jedná o dátovo orientované modelovanie je samotný proces podmienený dostatočným predspracovaním dát, ktoré sme bližšie špecifikovali v predchádzajúcich kapitolách. Dôležitým krokom je proces normalizácie predspracovaných dát, častokrát tento proces je zamieňaný štandardizáciou. Pri normalizácii (škálovaní) sa jedná o takú transformáciu dát, pri ktorej sa zmení interval dát na zvolený rozsah, zväčša 0 až 1 alebo -1 až 1. Takouto transformáciou transformujeme dáta na bez jednotkový interval. Druhým zaužívaným spôsobom je štandardizácia dát (z-score), ktorá sústreď dáta okolo nuly so smerodajnou odchýlkou rovnej jedna. V predkladanej práci bola použitá štandardizácia dát, nakoľko lepšie uchováva informácie napr. o extrémnom odbere počas studenších dní. Táto transformácia je definovaná nasledovným vzťahom:

$$x_z = \frac{x_i - \mu}{\sigma} \quad (10)$$

kde x_i – dáta, μ – priemer, σ – smerodajná odchýlka

Z vymedzených teoretických pojmov z kapitoly o neurónových sieťach vieme, že neexistuje žiadna metodika, ktorá jasne popisuje návrh neurónovej siete pre riešenie danej problematiky. V predkladanej dizertačnej práci bola použitá dopredná neurónová sieť, nakoľko jej výpočtové nároky sú menšie v porovnaní s rekurentnou neurónovou sieťou. Neurónová sieť bola vytvorená v prostredí Matlabu pomocou funkcie *feedforwardnet()*, ktorá vyžaduje dva vstupné parametre počet skrytých neurónov a učiaci sa algoritmus. Hodnoty týchto parametrov sa nedajú jednoznačne určiť, avšak existujú zaužívané pravidlá ako napr. prezentované vzorce v tabuľke 4.

Tabuľka 4 Vzorce pre výpočet skrytých neurónov


Výskum	Vzorec	Počet neurónov pre odber	Počet neurónov pre spiatočku
Tamura, et al., 1997	$N-1$ (N počet vstupných neurónov)	$7 - 1 = 6$	$5 - 1 = 4$
Xu. et al., 2008	$2/3$ z počtu vstupných neurónov	$7 \times \frac{2}{3} \cong 5$	$5 \times \frac{2}{3} \cong 3$
Trenn, 2008	$N_{in} + N_{out} - 1/2$	$7 + 1 - \frac{1}{2} \cong 8$	$5 + 1 - \frac{1}{2} \cong 6$

Je zrejmé, že ide o empirické odporúčenie, ktoré nemusí byť tým optimálnym riešením. Častokrát nájdenie optimálneho riešenia je zdĺhavý iteratívny proces, pri ktorom sa určí

počiatočný počet skrytých neurónov, ktorý predstavuje východzí stav. Následne sa tento počet zvyšuje, resp. znižuje (zvyšovanie/znižovanie závisí od chybovosti siete), avšak takýto proces je časovo veľmi náročný. Druhým požadovaným parametrom je výber učiaceho sa algoritmu (optimalizačný), rovnako ako pri určení počtu skrytých neurónov neexistuje stanovená metodika, ktorý algoritmus je vhodný pre riešenie problematiku. V predkladanej dizertačnej práci overíme efektívnosť troch gradientových metód a to konkrétne Levenberg-Marquardt (`trainlm`), Scaled Conjugate Gradient (`trainscg`) a Newtonovej metódy (`trainbfg`). Po zadenovaní požadovaných parametrov vznikne objekt neurónovej siete `netOdber`, ktorý volaním funkcie `train` spustíme proces tréovania.

```
trainFcn = 'trainlm'; % Levenberg-Marquardt metoda
hiddenLayerSize = 6; % pocet skrytych neuronov
netOdber = feedforwardnet(hiddenLayerSize,trainFcn);%vytvorenie NS
[netOdber,tr] =
train(netOdber,dataTrening_odber(:,1:7)',dataTrening_odber(:,8)');%spustenie trenovania
netOdber.divideFcn = 'divideblock'; %rozdelenie dat po blokoch(tren,test,val)
netOdber.trainParam.max_fail = 10;%ukoncenie trenovania ak chybovost neklesa po 10
valid.
```

Počas tréovania je nevyhnutné zadenovať kritérium ukončenia procesu tréovania aby sa predišlo tzv. preučeniu sa (overfitting/underfitting) teda k zlým generalizačným vlastnostiam neurónovej siete na nové nepoznané dáta. V našom prípade bolo použité kritérium `max_fail` t.j. proces tréovania sa skončí ak úspešnosť na validačnej sade dát 10 po sebe idúcich iterácií (epochov) neklesá vid'. obrázok 20.



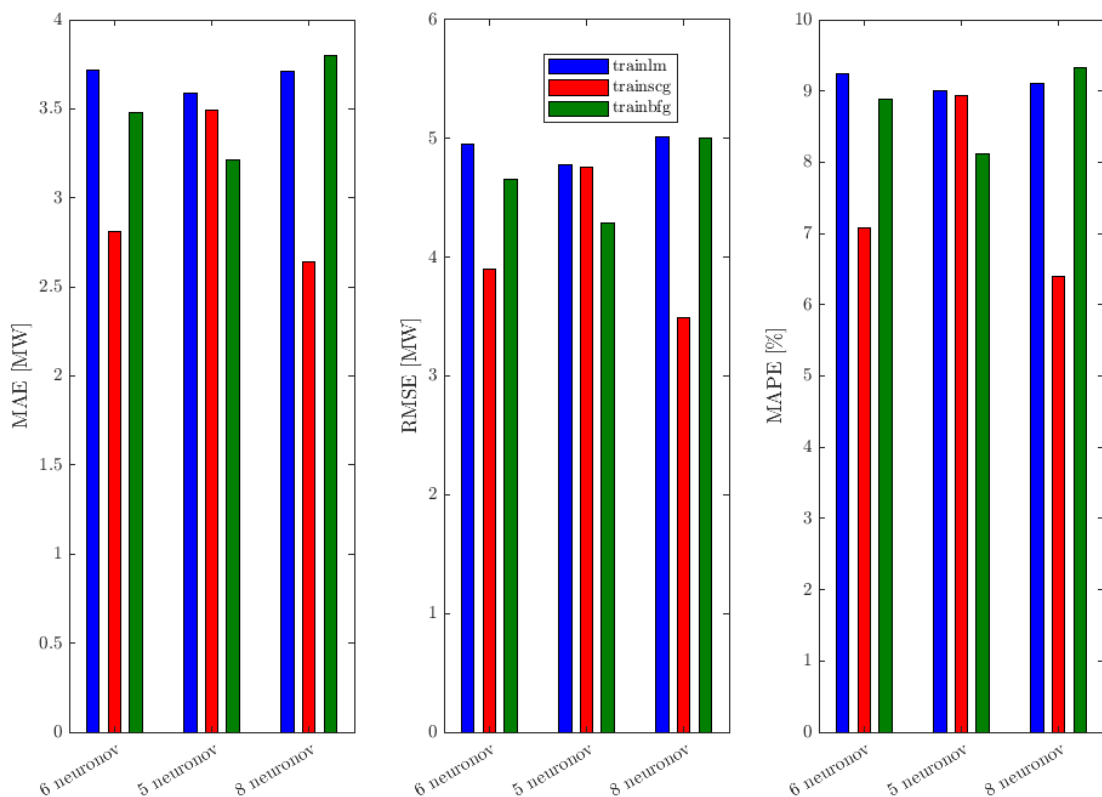
Obrázok 20 Proces tréovania - `trainscg` a 8 neurónov

Analýzou výsledkov z obrázka 21 vyplývajú nasledovné zistenia:

- `trainlm` - medzi uvádzanými počtami neurónov pri použití algoritmu LM (modré pružky) takmer neexistujú žiadne významné rozdiely pri jednotlivých hodnotiacich kritériách. Rozdiel bol spozorovaný predovšetkým v počte potrebných epochov na

nájdenie optimálnych váh neurónovej siete, pričom najmenší počet iterácií sme zaznamenali pri počte 8 neurónov. V tomto prípade proces učenia siete skončil po 15 epochách-iteráciách.

- *trainscg* – tento algoritmus bol spomedzi ostatných algoritmov najpresnejší. Zaujímavým zistením je fakt, že pre tento algoritmus už zohráva počet neurónov významnú úlohu, najlepšie výsledky boli dosiahnuté pri scenári kedy počet skrytých neurónov bol najvyšší t.j. 8. Pri týchto nastaveniach proces tréovania skončil po 35 iteráciách, v porovnaní s LM bolo potrebných vyše dvojnásobný počet iterácií na nájdenie vhodných váh neurónovej siete.
- *trainbr* – tento algoritmus mal podobnú úspešnosť ako LM. Obdobne ako pri prvom scenári najlepšie výsledky boli dosiahnuté pri modeli, ktorý obsahoval 5 skrytých neurónov a v tomto prípade bolo potrebných 44 iterácií pre nájdenie vhodných váh neurónovej siete. Rozdiely medzi jednotlivými počtami neurónov obdobne ako pri LM je minoritný.




Obrázok 21 Úspešnosť modelov odberu tepla na validačnej sade dát

Pre model teploty spiatocky vplyva na presnosť kombinácia parametrov počtu skrytých neurónov a typ optimalizačného algoritmu nasledovne vid'. obrázok 22:

- *trainlm* – rozdiely medzi jednotlivými evaluačnými kritériami sú obdobne ako pri modeloch odberu tepla minimálne. Pri jednotlivých scenároch priemerná odchýlka teploty bola na úrovni 1,15°C. Najlepší výsledok bol spozorovaný pri 6 skrytých neurónoch. Pre tento scenár skončilo tréovanie v 16 iteráciách.
- *trainscg* – znova sme spozorovali rovnakú citlivosť na počet neurónov. Pri najmenšom počte skrytých neurónov (3) model vykazoval najvyššiu chybovosť a zároveň proces tréovania trval najdlhšie (56 iterácií). Ak vychádzame z kritéria RMSE, ktoré dôsledkom kvadrátu penalizuje vyššiu chybovosť, potom najlepšie výsledky boli spozorované pri 4 neurónoch avšak rozdiel v presnosti je minimálny

v porovnaní so 6 skrytými neurónmi. Čo sa týka počtu iterácií, tak rozdiel už bol jasne spozorovateľný, nakoľko pre scenár 6 neurónov bolo potrebných 35 epoch v porovnaní so 4 neurónmi kde bolo potrebných až 48 epoch.

- *trainbr* – pri tomto algoritme sme spozorovali najhoršie výsledky pri jednotlivých kritériách, keď počet skrytých neurónov bol nastavený na 3, zároveň aj proces tréovania trval najdlhšie (56 iterácií). Ak vychádzame z RMSE, ktorý penalizuje veľké rozdiely, tak potom sme dosiahli najlepšie výsledky pri 4 skrytých neurónoch.

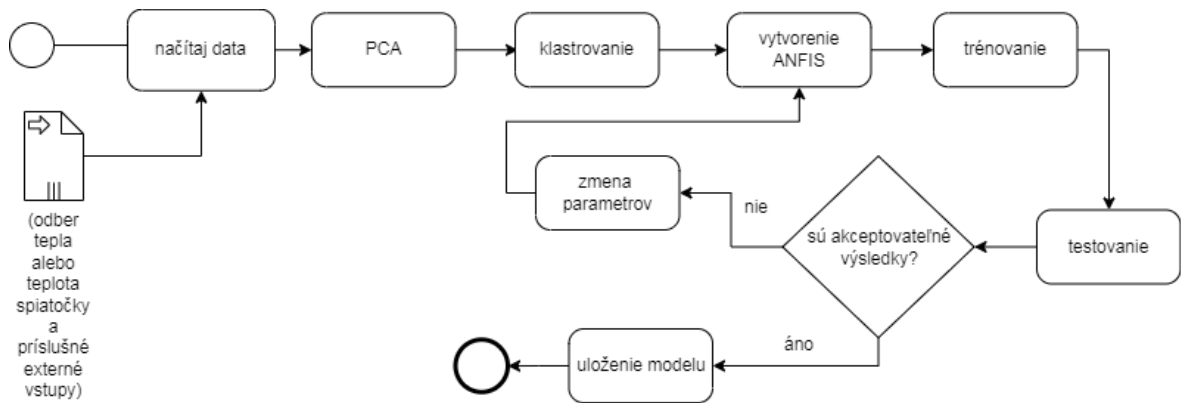


Obrázok 22 Úspešnosť modelov teploty spiatocky na validačnej sade dát

Počas tvorby neurónových modelov bolo dokopy navrhnutých 18 modelov, ktoré mali rôzne parametre t.j. počet skrytých neurónov a optimalizačný algoritmus. Experimentami boli zistené, že pre model spotreby tepla je najvyhovujúcejšou kombináciou 8 skrytých neurónov v kombinácii s trainscg algoritmom. Pre predikciu teploty spiatocky boli dosiahnuté najlepšie výsledky v kombinácii trainscg algoritmu a 4 skrytých neurónov. Pre model odberu tepla predstavoval počet skrytých neurónov vyššiu hodnotu než počet vstupov t.j. nie je vylúčené, že model s viacerými skrytými neurónmi ako 8 by dosiahol lepšie výsledky ako nami identifikovaná kombinácia.


3.2.3 Neuro-fuzzy siete

Úspešné vytvorenie neuro-fuzzy modelu je podmienené krokmi, ktoré sú znázornené na BPMN diagrame, ktorý je prezentovaný na obrázku 23. Proces modelovania vo veľkej miere je totožný s procesom tvorby neurónových sietí. Celý proces začína načítaním matice predspracovaných vstupných a výstupných dát (odber tepla alebo teplota spiatocky).



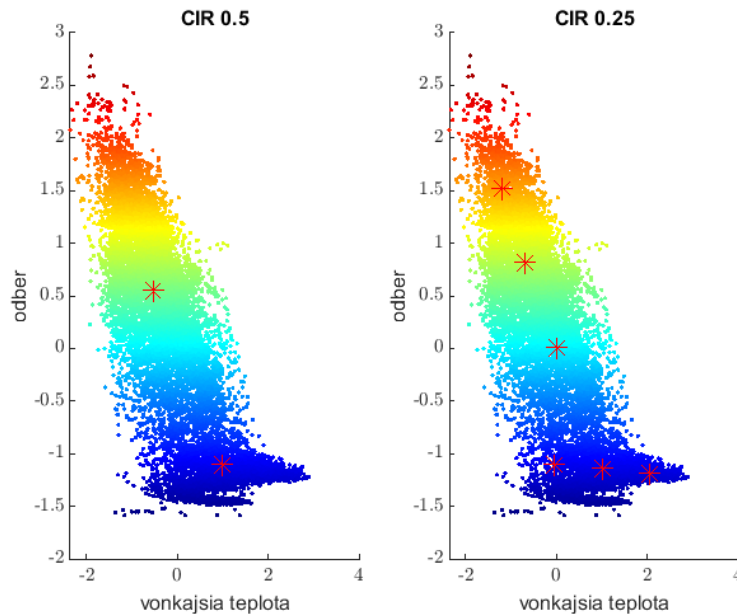
Obrázok 23 BPMN Diagram tvorby ANFIS modelu

Počas tvorby neuro-fuzzy modelu je kľúčovou úlohou spôsob vytvorenia fuzzy inferenčného mechanizmu. Na výber existuje *grid partitioning* a *subtractive clustering* metóda. Prvá zmienená metóda v našom prípade je takmer nepoužiteľná, keďže pri siedmich vstupoch odberu tepla a pri piatich funkcií príslušnosti pre každý vstup by vzniklo dokopy 7^5 t.j. 16807 pravidiel. Takto vysoký počet pravidiel je algoritmicky náročný na spracovanie a preto táto metóda vyhovuje len pre prípady s malým počtom vstupov. Subtractive clustering algoritmus rozdelí maticu vstupných dát na n počet klastrov kde každý klaster predstavuje zvlášť fuzzy pravidlo. Nevýhodou tejto metódy je správny odhad počtu klastrov pretože neexistuje žiadna metodika, ktorá jednoznačne popisuje určenie počtu klastrov. Jedným zo zaužívaných spôsobov je redukcia dimenzionality dát pomocou metódy hlavných komponentov PCA (Principle Component Analysis). V našom prípade vstupné dáta pre odber tepla predstavujú závislosť v 7 dimenzionálnom priestore. Takúto závislosť je ťažko vizualizovať a interpretovať a navyše pri vysokom počte vstupov nastáva aj problematika multikolinearity t.j. vzájomná závislosť vstupných faktorov. Pomocou PCA algoritmu sa zistilo, že prvé dva hlavné komponenty popisujú celkový rozptyl vstupnej množiny dát na 80% (49% pre prvý hlavný komponent a 31% pre hlavný komponent číslo 2).




Obrázok 24 Závislosť dvoch hlavných komponentov

Tieto hlavné komponenty už dokážeme vizualizovať (obrázok 24) a interpretovať a je zrejmé, že každý vstup nepredstavuje zvlášť klaster t.j. 7 jednoznačných klastrov vo vstupných dátach nemáme, nakoľko niektoré klastre sa prekrývajú. Riešením je aplikácia klastrovacieho algoritmu na prvé dva hlavné komponenty aby sme mohli stanoviť reálny počet klastrov. Po použití funkcie *evalclusters* sa zistilo, že optimálny počet klastrov je dva. Pre každý vstup je nevyhnutné zadať rozsah vplyvu klastra (ClusterInfluenceRange - CIR), ktorý predstavuje numerickú hodnotu v rozsahu 0 až 1 pričom malá hodnota predstavuje veľký počet klastrov a veľká hodnota zas malý počet klastrov. Následne toto riešenie sme overili pre každý vstup. Vplyv rôznych hodnôt CIR je demonštrované na obrázku 25, z ktorého vyplývajú nasledovné zistenia.



Obrázok 25 Rozsah vplyvu klastrov

Pri CIR hodnote 0,5 algoritmus identifikoval dva klastre, ktoré korešponujú výsledku, ktorý sme dostali pomocou klastrovania analýzy hlavných komponentov. Pre porovnanie hodnotu CIR sme znížili na 0,25 tým pádom sa zvýšil počet klastrov. Nemôžeme jednoznačne stanoviť, že vysoká resp. nízka hodnota CIR je vyhovujúca pre skúmanú problematiku avšak ak vychádzame z tvrdenia, ktoré sme demonštrovali na obrázku 24 tak potom niektoré klastre sa prekrývajú t.j. teoreticky stačí aj menší počet klastrov. Analogicky sme postupovali pri určovaní hodnoty CIR pre jednotlivé vstupy odberu tepla resp. teploty spiatocky. Následne sa vytvoril ANFIS model pomocou funkcie *genfis*, kde sme postupne otestovali vplyv troch rôznych funkcií príslušnosti *gaussmf*, *gbellmf* a *gauss2mf*. Vytvorený fuzzy inferenčný mechanizmus *fis* obsahoval desať pravidiel – pre odber tepla a šesť pravidiel pre teplotu spiatocky. Zároveň tento objekt *fis* je vstupným parametrom funkcie *anfisOptions*. Táto funkcia slúži na nastavenie základných parametrov potrebných pre tréning neuro-fuzzy modelu. Proces tréningu začína volaním funkcie *anfis*, ktorá vracia natrénovaný neuro-fuzzy objekt. Proces tréningu je zobrazený na obrázku 26, z ktorého jasne vidieť, že optimálne parametre modelu sa našli pri 7 iteráciách kedy bola najnižšia chybovosť tréningového modelu. Tento model sa uložil, a obdobne sme postupovali pri jednotlivých nastaveniach funkcií príslušnosti.



Obrázok 26 Proces trenovania anfis

Výsledky natréovaných neuro-fuzzy modelov sú zobrazené v tabuľke 5.

Tabuľka 5 Porovnanie modelov odberu tepla ANFIS

Funkcia príslušnosti	gaussmf			gbellmf			gauss2mf		
	tren	test	valid	tren	test	valid	tren	test	valid
Dátová vzorka	tren	test	valid	tren	test	valid	tren	test	valid
MAE [MW]	2,55	4,61	3,73	2,55	4,68	3,61	2,46	4,45	3,51
RMSE [MW]	3,88	6,12	4,97	3,90	6,15	4,78	3,77	5,94	4,65
MAPE [%]	17,95	37,41	19,62	17,83	38,77	19,14	17,2	34,49	17,28

Pohľadom na tabuľku 5 vidieť, že *gauss2mf* funkcia príslušnosti je najvhodnejšia na predikciu odberu tepla pretože model trévaný týmto algoritmom dosiahol najnižšiu chybovosť. Taktiež z dosiahnutých výsledkov vidieť, že jednotlivé neuro-fuzzy modely mali najvyššiu chybovosť na testovacej sade dát, ktorá predstavuje obdobie od 15. februára 2021 až po 1. mája 2021, ktoré je charakteristické postupným znižovaním dopytu tepla potrebného pre vykurovanie, kde jednotlivé denné profily sú rozmanité. Dôsledkom tejto vyššej chybovosti je premenlivosť denných profilov odberu tepla.

Dosiahnuté výsledky modelov teploty spiatocky sú zobrazené v tabuľke 6, z ktorej vyplýva, že model, ktorý mal *gbellmf* funkciu príslušnosti bol najpresnejší avšak v porovnaní s ostatnými funkciami sú tieto rozdiely zanedbateľné.

Tabuľka 6 Porovnanie modelov teploty spiatocky ANFIS

Funkcia príslušnosti	gaussmf			gbellmf			gauss2mf		
	tren	test	valid	tren	test	valid	tren	test	valid
Dátová vzorka	tren	test	valid	tren	test	valid	tren	test	valid
MAE [°C]	1,05	1,22	1,10	1,05	1,05	1,09	1,05	1,20	1,09
RMSE [°C]	1,51	1,69	1,45	1,51	1,65	1,43	1,51	1,68	1,45
MAPE [%]	2,04	2,52	2,19	2,04	2,43	2,17	2,04	2,49	2,17

4 OVERENIE A POROVNANIE NAVRHNUTÝCH RIEŠENÍ

Súčasťou tejto kapitoly je overenie navrhnutých modelov ako možný simulačný nástroj počas plánovania výroby tepla. Modely, ktoré boli navrhnuté v predchádzajúcej kapitole sú validované na vzorke dát z obdobia z 1.9.2021 až 22.1.2022. Táto dátová množina slúži na overenie generalizačných schopností navrhnutých modelov, ktoré simulujú praktickú aplikovateľnosť modelov počas plánovania výroby. Je nevyhnutné poznamenať, že tieto dáta neboli použité počas tréningu a ani testovania modelov odberu tepla a teploty spiatočky. Dáta musia mať podobné štatistické vlastnosti ako dáta, ktoré boli využité počas tréningu.

Robustnosť navrhnutých modelov sme overili na troch náhodne vybraných dňoch, ktoré predstavujú nasledovné výzvy z hľadiska plánovania výroby:

- *Simulačný scenár 1* – vybraný deň 12. september predstavuje teplý deň kedy dodané teplo je primárne využité vo forme TUV.
- *Simulačný scenár 2* – tento deň 11. november predstavuje prechodné počasie, ktoré z hľadiska odberu tepla je charakteristické nevyspytateľnosťou. Dodané množstvo tepla sa už primárne využíva pre potreby vykurovania.
- *Simulačný scenár 3* – vybraný deň 6. január predstavuje sviatočný zimný deň, kedy sa profil môže líšiť od klasického denného profilu.

4.1 Simulácia teploty výtlaku

V predkladanej dizertačnej práci sme sa zamerali na aplikovateľnosť dátovo orientovaných modelov ako možný simulačný nástroj počas plánovania výroby. Jedným z úzkych miest v teplárenstve sú vysoké teploty výtlaku, ktoré spôsobujú značné teplotné straty v systéme a zároveň zvyšujú náklady, ktoré sú nežiadúce. Súčasná ET závislosť vonkajšej teploty a teploty výtlaku je neefektívna nakoľko teplota teplonosného média je vysoká čo spôsobuje väčšie teplotné straty a zvýšenú spotrebu energií na vyrobenie požadovaného množstva tepla. Výstupom je nasimulovaný priebeh teploty výtlaku za 24 hodinové obdobie na základe predikčných modelov, ktoré boli navrhnuté v predchádzajúcej kapitole.

Teplotu výtlaku sme vypočítali na základe rovnice (1), ktorú sme upravili do nasledovnej podoby:


$$\widehat{T}_{v(t)} = \widehat{T}_{s(t)} + \frac{\widehat{Q}_{(t)}}{cp \times m_{(t)}} \quad (11)$$

kde $\widehat{T}_{v(t)}$ je vypočítaná teplota výtlaku, $\widehat{T}_{s(t)}$ - predikovaná teplota spiatočky, $\widehat{Q}_{(t)}$ - predikovaný odber tepla, cp – merné skupenské teplo vody a $m_{(t)}$ predstavuje prietok.

Prietok $m_{(t)}$ sme určili na základe závislosti od odberu tepla. Táto závislosť je definovaná vzt'ahom (12):

$$m_{(t)} = 16,47 + \widehat{Q}_{(t)} + 322,36 \quad (12)$$

kde $\widehat{Q}_{(t)}$ predstavuje predikované množstvo odberu tepla. Závislosť prietoku od odberu je zobrazená na obrázku 27.



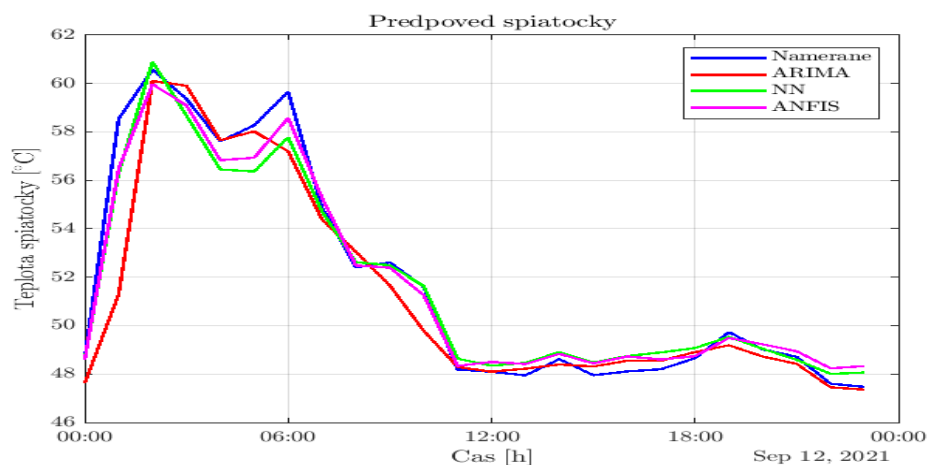
Obrázok 27 Závislosť odberu a prietoku (zdroj:vlastné spracovanie)

Analýzou obrázka 27 vidieť lineárnu závislosť medzi odberom a prietokom s korelačným koeficientom $r = 0.84$, 95% intervaly spoľahlivosti potvrdzujú, že väčšina meraní leží v tomto rozsahu. Z toho vyplýva, že identifikovaná závislosť (12) medzi odberom tepla a prietokom je dostatočne relevantná na to, aby sme mohli použiť túto závislosť (12) pre výpočet prietoku vo vzťahu (11). Ďalšie iné závislosti (polynómy vyššieho rádu) boli aplikované na nameraných dátach avšak nebolo spozorované žiadne zlepšenie v korelačnom koeficiente.

V nasledujúcich podkapitolách demonštrujeme dosiahnuté výsledky na troch testovacích dňoch, ktoré sme zdefinovali na začiatku tejto kapitoly.

4.1.1 Simulačný scenár 1

Počas tohto vybraného dňa dosiahla najnižšia denná teplota hodnotu 12°C a najvyššia 28°C , priemerná denná teplota bola na úrovni 20°C . Je zrejmé, že pri týchto klimatických podmienkach nemôžeme hovoriť o potrebe tepla pre potreby vykurovania a teda hlavnou zložkou dodaného množstva tepla je teplo potrebné pre potreby TÚV. Pri pohľade na predikciu spiatocky (obrázok 28) vidieť, že modely dokázali veľmi presne predpovedať očakávanú teplotu spiatocky. Zaujímavosťou je relatívne vysoká teplota spiatocky v nočných až začiatkom ranných hodín. Príčinou tohto javu je nočný útlm.



Obrázok 28 Scenár 1 predikcia spiatocky (zdroj: vlastné spracovanie)

Kvalitatívne ukazovatele predikcie sú zobrazené v tabuľke 7. Najnižšia hodnota predstavuje najlepší výsledok.


Tabuľka 7 Presnosť predikcie spiatočky - Scenár 1

	ARIMA	Neurónová sieť	ANFIS
MAE [°C]	0,80	0,58	0,51
RMSE [°C]	1,66	0,83	0,68
MAPE [%]	1,46	1,08	0,95

Analýzou predikcie odberu tepla (obrázok 29) vidíme, že model ARIMA najlepšie predpovedal očakávaný odber. Model neurónovej siete a neuro-fuzzy model majú vysokú chybovosť priemerne 3 MW čo je neakceptovateľný v situácii keď odber tepla je maximálne na úrovni 10 MW. Porovnanie presnosti jednotlivých modelov sa nachádza v tabuľke 8.

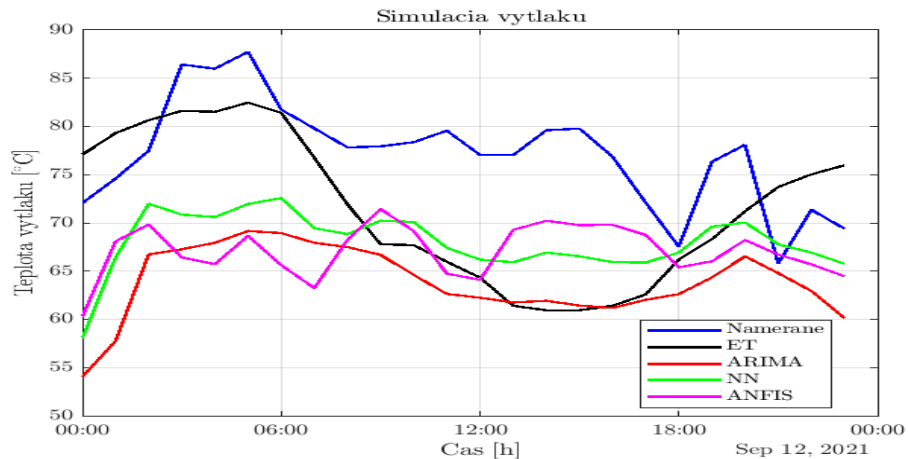
Tabuľka 8 Presnosť predikcie odberu - Scenár 1

	ARIMA	Neurónová sieť	ANFIS
MAE [MW]	0,58	2,99	2,65
RMSE [MW]	0,76	3,04	3,57
MAPE [%]	11,73	34,95	29,27

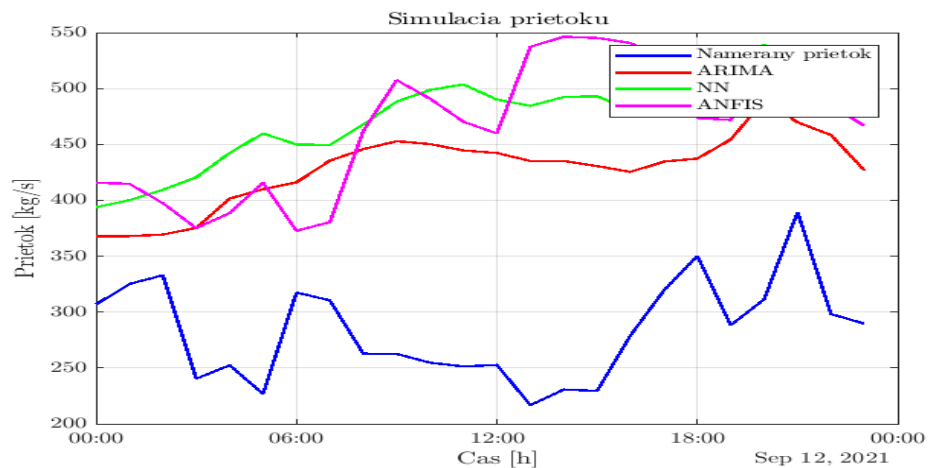


Obrázok 29 Scenár 1 predikcia odberu (zdroj: vlastné spracovanie)

Nasimulované hodnoty teploty výtlaku (obrázok 30) na základe predikcií odberu tepla a teploty spiatočky spadajú, pod letnú ET krivku, ktorá by nemala presiahnuť maximálnu teplotu 75°C, ktorá je stanovená pre letné (nevykurovacie) obdobie. Namerané hodnoty teploty výtlaku túto hodnotu výrazne prevyšujú.



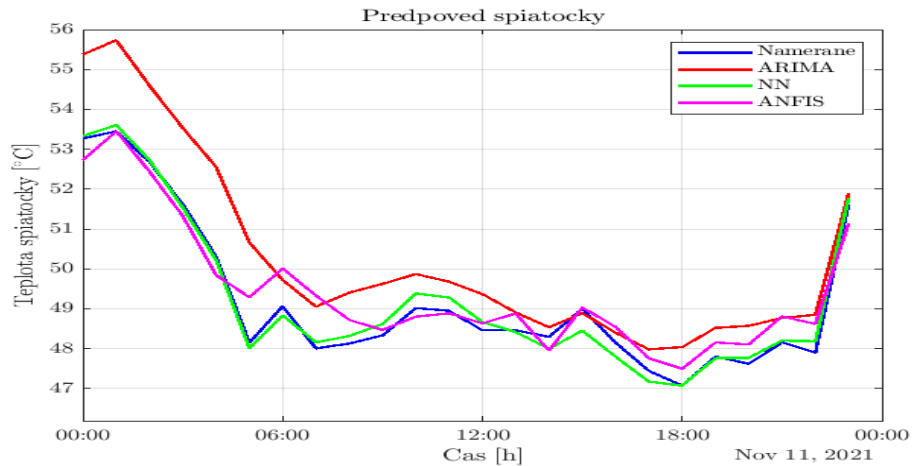
Obrázok 30 Scenár 1: Simulovaná teplota výtľaku (zdroj: vlastné spracovanie)
Dôvodom nameraných vyšších teplôt výtľaku je nižší prietok (obrázok 31), ktorý je výstupom optimalizácie súčasného systému riadenia Termis.



Obrázok 31 Scenár 1 - Simulovaný prietok (zdroj: vlastné spracovanie)

4.1.2 Simulačný scenár 2

Simulačný scenár 2 predstavuje typický chladný novembrový jesenný deň kedy už priemerné denné teploty klesajú resp. už sú pod zákonom definovanou hranicou 13°C (dva dni po sebe priemerná teplota) to znamená že je nevyhnutné dodať teplo pre odberateľov pre potreby vykurovania. V tom vybranom scenári priemerná denná teplota dosiahla hodnotu 6°C pričom maximálna denná teplota bola na úrovni 11,1°C a minimálna teplota dosiahla hodnotu 1,9°C. Pri týchto klimatických podmienkach sa dopyt po teple stáva viac menej stály.



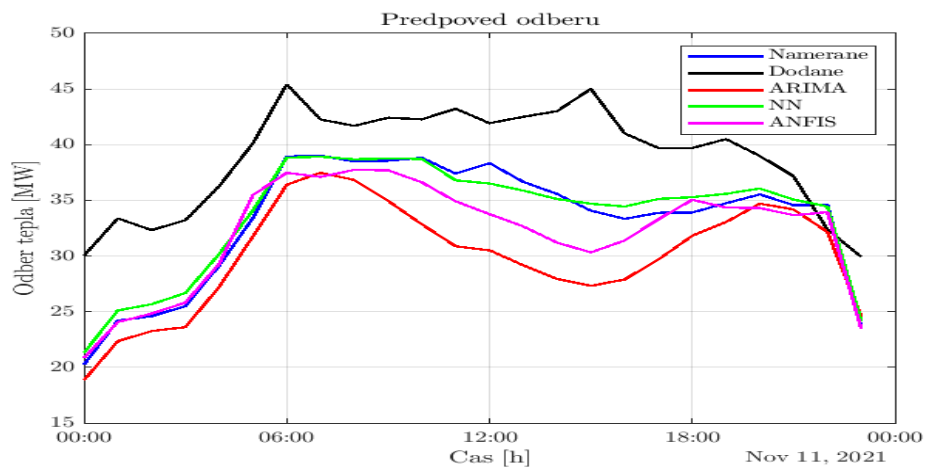
Obrázok 32 Scenár 2 predikcia spiatocky (zdroj: vlastné spracovanie)

Pohl'adom na obrázok 32 vidieť porovnanie predikcie teploty spiatocky z navrhnutých modelov v porovnaní s nameranou teplotou spiatocky. Dynamiku teploty spiatocky najlepšie zachytil model neurónovej siete (zelená krivka). Neuro-fuzzy model (ružová krivka) relatívne podobne zachytil dynamiku teploty ako neurónový model. Najhorší výsledok predikcie vidieť pri lineárnom ARIMA modely (červená krivka), síce model zachytil dynamiku teploty spiatocky avšak rozdiel medzi nameranou a predikciou je signifikantne väčší v porovnaní s modelmi neurónovej siete a neuro-fuzzy modelu. V tabuľke 9 sú zobrazené kvalitatívne ukazovatele jednotlivých modelov. Najnižšia hodnota predstavuje najlepší výsledok.

Tabuľka 9 Presnosť predikcie spiatocky - Scenár 2

	ARIMA	Neurónová sieť	ANFIS
MAE [°C]	0,80	0,18	0,45
RMSE [°C]	1,66	0,22	0,56
MAPE [%]	2,09	0,38	0,91

Analýzou obrázka 33 vidíme presnosť predikcie jednotlivých modelov a dodané množstvo tepla do sústavy (čierna krivka).



Obrázok 33 Scenár 2 predikcia odberu (zdroj: vlastné spracovanie)


Obdobne ako pri predikcii teploty spiatocky model neurónovej siete bol najpresnejší. Neuro-fuzzy model a ARIMA model majú veľkú odchýlku (max. 10 MW) počas

pracovných hodín. Tieto modely síce zachytili priemernú dynamiku odberu tepla počas pracovných dní, ktorá je zobrazená na obrázku 7, avšak použitie týchto dvoch modelov pre predikciu odberu tepla pre tento prípad je nevyhovujúce. Na druhej strane je potrebné dodať, že denný profil mohol byť ovplyvnený aj pandémiou. Vysvetlením horšej predikcie pre neuro-fuzzy model môže byť, že sme zvolili nedostatočný počet klastrov a algoritmus nedokáže klasifikovať dostatočne správne vstupy do klastrov. Model ARIMA trpí problémom modelovania nelineárnych závislostí, tento príklad dokonale reprezentuje stochastickosť jesenného obdobia, ktorú potvrdzuje aj nadmerné množstvo dodaného tepla, ktoré je dôsledkom absencie predikcie odberu tepla. V tabuľke 10 vidieť presnosť predikcie jednotlivých modelov.


Tabuľka 10 Presnosť predikcie odberu - Scenár 2

	ARIMA	Neurónová sieť	ANFIS
MAE [MW]	3,3	0,72	1,53
RMSE [MW]	4,09	0,85	2,05
MAPE [%]	11,27	2,35	4,65

Vypočítaná teplota výtlaku pomocou vzťahu (6) pre sledované obdobie je zobrazená na obrázku 34, z ktorého vychádzajú nasledovné zistenia. Simulované hodnoty teploty výtlaku sú takmer totožné s nameranou hodnotou teploty výtlaku až na rozdiel od 12:00 kedy sa teplota zvýšila dôsledkom zabezpečenia tepla počas večernej špičky. Dôsledkom tohto zvýšenia je zníženie prietoku (obrázok 35) od času začiatku zvýšenia teploty výtlaku t.j. od 12:00.



Obrázok 34 Scenár 2: Simulovaná teplota výtlaku (zdroj: vlastné spracovanie)




Obrázok 35 Scenár 2 - Simulovaný prietok (zdroj: vlastné spracovanie)

Z charakteristiky nameraného prietoku na obrázku 35 je vidieť, že v sledovanom období počas ranných hodín bol prietok vyšší dôsledkom nižšej teploty výtlaku. Náš výpočet prietoku je signifikantne menší s menšou variabilitou.

4.1.3 Simulačný scenár 3

Tento simulačný scenár modeluje sviatočný deň Troch kráľov kedy väčšina populácie sa nachádza doma, zároveň je to zimný deň kedy vonkajšie teploty klesajú aj dlhodobo pod 0°C . V tento vybraný deň najnižšia teplota dosiahla hodnotu -3°C pričom najvyššia denná teplota bola na úrovni 5°C . Priemerná denná teplota pre tento deň dosiahla úroveň $1,5^{\circ}\text{C}$. Je zrejmé, že pri týchto klimatických podmienkach počas sviatočného dňa sa jedná o zvýšený dopyt po teple v porovnaní s bežným zimným dňom.



Obrázok 36 Scenár 3 - predikcia spiatocky (zdroj: vlastné spracovanie)


Pohľadom na obrázok 36 sa javí analogický scenár ako pri predchádzajúcich predikciách teploty spiatocky. Neurónový model najpresnejšie zachytil dynamiku teploty spiatocky. Vo všeobecnosti všetky modely majú akceptovateľné výsledky. Presnosti jednotlivých modelov sú zobrazené v tabuľke 11.

Tabuľka 11 Presnosť predikcie spiatocky - Scenár 3

	ARIMA	Neurónová sieť	ANFIS
MAE [$^{\circ}\text{C}$]	1,25	0,43	0,77
RMSE [$^{\circ}\text{C}$]	1,65	0,57	0,88

MAPE [%]	2,46	0,88	1,57
----------	------	------	------

Pokračujúc analýzou obrázka 37 vidieť, že rozdiel medzi nameraným odberom tepla a predikciami nie je veľký. Príčinou presnej predikcie je silná korelácia vonkajšej teploty a odberu tepla počas zimy t.j. modely správne identifikovali tento vzťah. Obdobne ako v predchádzajúcich predikciách model neurónovej siete najlepšie aproximuje krivku nameraného odberu a najhoršia predikcia je od modelu ARIMA, ktorý modeluje odber lineárnou kombináciou chýb predikcie.




Obrázok 37 Scenár 3 - predikcia odberu

Porovnanie presnosti jednotlivých modelov je zobrazené v tabuľke 12.

Tabuľka 12 Presnosť predikcie odberu - Scenár 3


	ARIMA	Neurónová sieť	ANFIS
MAE [MW]	3,83	1,29	1,68
RMSE [MW]	4,27	1,51	2,13
MAPE [%]	9,67	3,5	4,65

Pri pohľade na vizualizácie vypočítaných teplôt výtlaku a nameranej teploty výtlaku (obrázok 38) vidíme, značný rozdiel medzi nameranými a vypočítanými hodnotami. Tento teplotný rozdiel je už významný nakoľko vyššie teploty predstavujú vyššie teplotné straty. Na základe navrhnutých modelov bolo možné znížiť teplotu výtlaku v priemere o 8°C pre tento simulačný scenár. Krivky simulovaných hodnôt výtlaku majú menší rozptyl v porovnaní s nameranou hodnotou to znamená, že zdroj má vyrovnaný režim prevádzky.



Obrázok 38 Scenár 3 - Simulovaná teplota výtlačku

Simulované hodnoty prietoku (obrázok 39) dosahujú podobné hodnoty ako nameraný prietok zo sledovaného obdobia. Z prislúchajúceho obrázka vieme vyčítať aj nasledovnú informáciu, dôsledkom nižšej teploty v sústave dispečing musel zvýšiť prudko prietok aby bolo zabezpečené dostatočné množstvo tepla v sústave.




Obrázok 39 Scenár 3 - Simulovaný prietok

Nižšia simulovaná hodnota teploty výtlačku v tomto scenári je kompenzovaná vyšším prietokom počas dňa aby bolo zabezpečené dostatočné množstvo tepla.

4.1.4 Simulácia návrhu na celé validačné obdobie

Z vyššie uvádzaných výsledkov z jednotlivých testovacích scenárov je zrejmé, že neuronové siete dokázali zachytiť najlepšie dynamiku odberu tepla. Efektivitu neuronových sietí porovnávame s nameranými hodnotami za celé validačné obdobie, ktoré je prezentované na obrázku 40.



Obrázok 40 Návrh novej ET krivky

Analýzou obrázka 40 existujú nasledovné konzekvencie týkajúce sa závislosti teploty výtlaku a vonkajšej teploty:

- *ET krivka* - súčasná ET krivka (zelená krivka), ktorá je definovaná vzťahom (2) je takmer nepoužiteľná pre výpočet teploty výtlaku, nakoľko pre sledované obdobie by do sústavy pri nameranom prietoku bola príliš vysoká teplota média, ktorého dôsledkom by boli vysoké teplotné straty.
- *Namerané hodnoty* – väčšina namerných hodnôt teploty výtlaku (červené krížiky) sa nachádza pod ET krivkou čo potvrdzuje našu domienku, že výpočet založený čisto len na ET krivke je nepoužiteľný. Vzťah vypočítanej ET krivky zo sledovaného obdobia je definovaný nasledovným vzťahom (13):


$$Tv_{\text{namerané}}(t) = -0,781 + \text{vonkajšia teplota} + 90,22 \quad (13)$$

- *Simulované hodnoty* – môžeme skonštatovať, že vypočítané hodnoty teploty výtlaku za simulované obdobie by boli dostatočné pre sledované obdobie. Dôvodom je, že simulované hodnoty (modré bodky) ležia v intervale spoľahlivosti nameraných hodnôt (tenká červená čiara) teploty výtlaku za sledované obdobie. Vypočítané hodnoty teploty výtlaku sú definované nasledovným vzťahom ((14):

$$Tv_{\text{simulácia}}(t) = -0,816 + \text{vonkajšia teplota} + 85,59 \quad (14)$$


Náš návrh potvrdzuje aj rozhodnutie dispečingu, ktorý počas riešenia dizertačnej práce znížil pôvodnú ET krivku, ktorá vychádzala z teplotného spádu 115°C/75°C (2) na teplotný spád 110°C/70°C (výtlak).

Simulované hodnoty teploty výtlaku pre celé obdobie sú zobrazené na obrázku 41a), z ktorého vidieť, že simulované hodnoty sú výrazne nižšie ako namerané hodnoty. Priemerná teplota výtlaku pre toto obdobie bola 84,06 °C náš simulačný model znížil teplotu výtlaku na 79,21°C.



Obrázok 41 Teplota výtlaku a prietok - celé obdobie

Pri hodnotách prietoku (obrázku 41b) sme rovnako dokázali znížiť prietok okrem obdobia kedy prevládajúcim prvkom spotreby tepla je len teplo potrebné pre potreby TÚV. Vyššia hodnota prietoku je dôsledkom nižšej teploty výtlaku vid'. obrázok 41a). Priemerná hodnota nameraného prietoku pre toto obdobie bolo 813,10 kg/s náš simulačný model dosiahol priemernú hodnotu 810,13 kg/s. Inak povedané náš návrh pri približne rovnakom prietoku avšak pri nižšej teplote výtlaku dokázal dodať takmer rovnaký výkon (obrázok 42a)) ako bol nameraný.



Obrázok 42 Predikcia odberu tepla a teploty spiatocky

Z obrázka 42a) vidieť porovnanie predikcie odberu tepla voči nameranému obdobiu za celé sledované obdobie. Vidieť obdobne citlivosť modelu t.j. vyššiu chybovosť pre letné obdobie. Zníženie chybovosti modelu je rozpísaná v nasledujúcej kapitole 4.2. Obrázok 42b) zobrazuje porovnanie predikcie teploty spiatocky a nameraných hodnôt pre sledované obdobie.

4.2 Vplyv redukcie dimenzionality

Model neurónovej siete mal najlepšie výsledky spomedzi navrhnutých modelov, avšak výsledky predikcie dokazujú, že predikcia odberu tepla konkrétnejšie z obdobia kedy dodané teplo je využívané iba vo forme teplej úžitkovej vody (letné obdobie) je neakceptovateľná. Naším cieľom je návrh relevantných modelov, ktoré sú čo a najvšeobecnejšie t.j. ich aplikácia má byť pre rôzne obdobia, preto je nevyhnutné sa zamerať na zvýšenie presnosti predikcie pre toto obdobie. Scenár uvádzaného obdobia je demonštrovaný v podkapitole

Vychádzajúc zo všeobecných poznatkov meteorológie a fyziky vieme, že ak sa zvýši intenzita slnečného žiarenia tak istou mierou sa zvýši aj vonkajšia teplota. Zvýšenie vonkajšej teploty spôsobí zníženie vlhkosti dôsledkom vyparovania. Takýmto závislostiam hovoríme multikolinearita.

vonkt	vietor	vlhkost	tepl. vytlak	hodiny	odber_t_24	odber_t
1	-0.11144	-0.55555	-0.82398	0.18996	-0.77586	-0.8141
0	1	-0.030379	0.093661	0.012447	0.14562	0.16408
0	0	1	0.40728	-0.32012	0.30199	0.31799
0	0	0	1	-0.18299	0.77321	0.81176
0	0	0	0	1	0.092314	0.091517
0	0	0	0	0	1	0.96062
0	0	0	0	0	0	1
0	0	0	0	0	0	0

Obrázok 43 Multikolinearita vstupných dát odberu tepla


Obrázok 43 predstavuje korelačné koeficienty medzi odberom tepla (posledný stĺpec) a vstupnou maticou (stĺpce 1 až 7). Analýzou týchto korelačných koeficientov môžeme skonštatovať, že multikolinearita medzi našimi vstupnými dátami existuje, nakoľko existujú silné negatívne závislosti medzi jednotlivými vstupmi. Túto vlastnosť dokážeme eliminovať pomocou metódy PCA. V predkladanej dizertačnej práci sme sa zamerali, na redukciu dimenzionality vstupných dát pre odber tepla, konkrétnejšie meteorologických faktorov ako vonkajšia teplota, rýchlosť vetra a vlhkosť. Pomocou analýzy PCA sme zistili, že prvý hlavný komponent popisuje celkový rozptyl týchto troch meteorologických faktorov na 55%. Táto hodnota síce nie je nejaká vysoká avšak reprezentuje dostatočné množstvo najdôležitejších informácií, ktoré popisujú dynamiku uvádzaných meteorologických dát.

Pomocou lineárnej kombinácie dokážeme vytvoriť novú premennú, ktorá kombinuje všetky uvedené klimatické dáta.

$$\text{novéMeteo} = 0,71 \times \text{teplota} - 0,103 \times \text{rýchlosť vetra} + 0,69 \times \text{vlhkosť} \quad (15)$$


Hodnoty koeficientov hlavných komponentov boli získané pomocou funkcie *pca* v Matlabe.

Vzniknutá nová premenná je zobrazená na obrázku 44, ktorá je porovnaná s nameranou vonkajšou teplotou pre začiatok tréningového obdobia. Kombinácia týchto troch meteorologických faktorov môže predstavovať aj tzv. pocitovú teplotu.



Obrázok 44 Nové meteorologické dáta vytvorené pomocou PCA

Vytvorená nová premenná predstavovala miesto troch meteorologických faktorov jednu vstupnú premennú, ostatné vstupy ostali nezmenené. Počas tvorby neurónovej siete sme postupovali rovnako ako pri modelovaní pomocou neurónových sietí v kapitole 3.2.2, t.j. počet skrytých neurónov bol nastavený na 8 a trainscg optimalizačný algoritmus bol použitý na nájdenie optimálnych váh. Grafická reprezentácia výsledkov predikcie spotreby tepla pre jednotlivé simulačné obdobia je zobrazená na obrázku 45, z ktorého vyplýva, že pri prvom simulačnom scenári (12. september) sme dosiahli významné zlepšenie presnosti modelu. Takisto sme dosiahli lepšie výsledky predikcie aj pre ostatné simulačný scenár 3 (6. január). V simulačnom scenári 2 (11. november) bola presnosť predikcie bola o niečo nižšia.



Obrázok 45 Efektivita PCA pre NS odberu tepla

Tabuľka 13 zobrazuje porovnanie presnosti modelu neurónovej siete s metódou PCA a bez.

Tabuľka 13 Porovnanie presností modelov NS odberu tepla s PCA a bez

	12. september		11. november		6. január	
	bez PCA	s PCA	bez PCA	s PCA	bez PCA	s PCA
MAE [MW]	2,99	0,98	0,72	0,90	1,29	0,45
RMSE [MW]	3,04	1,49	0,85	1,20	1,51	0,52
MAPE [%]	34,95	12,25	2,35	2,75	3,5	1,22

Numerické vyhodnotenie presnosti modelu s PCA ukazuje, že pre simulačný scenár 1 sme dokázali znížiť chybovosť takmer trikrát v porovnaní s prvým navrhnutým modelom. Obdobne trojnásobné zlepšenie sme dosiahli aj pri simulačnom scenári 3. Pre simulačný scenár 2 sa chybovosť modelu zhoršila, čo potvrdzuje náročnosť celého jesenného obdobia kedy sú klimatické podmienky premenlivé. V tomto prípade je pre toto jesenné obdobie nedostatok informácií v dátach (príčina: 55 % pokrytie rozptylu prvého hlavného komponentu pre meteorologické dáta), ktoré sme vytvorili na základe PCA analýzy – nové meteorologické dáta. Tieto informácie o dynamike odberu tepla sú nevyhnutné pre model neurónovej siete pre identifikáciu optimálnych vstupno-výstupných vzťahov. Inak povedané pocitová teplota je subjektívne vnímanie teploty, ktoré pôsobí na každého jedinca inak. Celková úspešnosť modelu s PCA redukciou v porovnaní s modelom bez

PCA, pre celé simulačné obdobie t.j. od 1.9.2021 až po 23.1.2022 je zobrazená v tabuľke 14.

Tabuľka 14 Presnosť PCA pre celý extra validačný set

	1.9.2021 – 23.1.2022	
	bez PCA	s PCA
MAE [MW]	1,39	0,65
RMSE [MW]	1,80	1,14
MAPE [%]	8,77	3,60

4.3 Budúce smerovanie práce

Komplexnosť prezentovanej sústavy CZT predstavuje výzvy a nezodpovedané otázky v rôznych smeroch, ktoré súčasne otvárajú priestor pre možný budúci výskum. K spomínaným výzvam patria nasledovné problematiky:

- *Pokročilé metódy dátovej analýzy* – táto oblasť je podmienená predovšetkým získaním viacerých dát z rôznych úrovní riadenia a distribúcie za účelom lepšieho pochopenia skúmaného objektu. K pokročilým metódam dátovej analýzy môžeme priradiť časovo-frekvenčnú analýzu napr. waveletovú analýzu, ktorá za pomoci tzv. vlniek rozkladá signál na nízke a vysoké frekvencie. Analýzou rôznych frekvenčných pásiem dokážeme objaviť detailnejšie informácie spojené s odberom tepla. Náš výskum v tejto oblasti preukázal, že predikcia odberu tepla je presnejšia ak pre každé frekvenčné pásmo natrénujeme zvlášť neurónovú sieť (Kováč 2021).
- *Detailnejšie modely spotreby* – ideálnym riešením by bolo zamerať sa na modelovanie tepla potrebné pre potreby TUV a pre potreby vykurovania zvlášť, nakoľko charakteristika odberu tepla pre uvádzané účely sú odlišné. Tieto modely by poskytovali pre výrobcov tepla lepšie podklady pre plánovanie a optimalizáciu výroby. Zostavenie takýchto modelov je podmienené relevantnými dátami.
- *Teplotné straty* – sú spôsobené predovšetkým stratami počas distribúcie tepla. Vychádzajúc z výročnej správy spoločnosti z roku 2021 predstavovali teplotné straty 10,48% z celkovej dodávky tepla (849 GW). Hlavným predpokladom, zníženia teplotných strát je zníženie teploty výtlaku a spiatočky, ktoré predstavujú základné piliere na prechod CZT štvrtej generácie. Zníženie teplôt, je podmienené dôkladnou izoláciou primárnych a sekundárnych potrubí. A taktiež aj integráciou meracích zariadení, ktoré podporujú obojstrannú komunikáciu v reálnom čase aby výrobcovia mali skutočný obraz o reálnej spotrebe odberateľov a za pomoci sofistikovaných nástrojov (analytické a predikčné modely umelej inteligencie) vedeli predpovedať spotrebu, ktorá je nevyhnutná pre potreby optimalizácie výroby.
- *Tepelné zásobníky* – jedným z možných riešení je výskum integrácie tepelných zásobníkov do sústavy. Tepelné zásobníky dokážu akumulovať teplo do určitého času a počas nedostatku tepla v systéme dokážu tento nedostatok kompenzovať. Integrácia tepelných zásobníkov kladne vplyva na výrobu tepla nakoľko časový profil fungovania zdroja je konštantný. Ďalšou výhodou je, že pre krátky časový horizont môže poslúžiť aj ako záložný zdroj. Implementovaním tepelným zásobníkov dokážeme integrovať aj teplo vyrobené z obnoviteľných zdrojov energie, ktoré majú nulovú ekologickú stopu a navyše zvyšujú zisk výrobcov tepla.

- *Oneskorenie systému* – sústava CZT je charakteristická s pomalou dynamikou, ktorú je potrebné brať do úvahy pri riešení komplexnej úlohy simulácie a optimalizácie výroby. Ak chceme zakomponovať faktor oneskorenia systému je nevyhnutné poznať topológiu a dimenziu potrubí a mať k dispozícii dáta z jednotlivých odovzdávacích staníc tepla.
- *Optimalizácia výroby* – štúdie optimalizácie výroby tepla predstavujú nročnú úlohu, ktorá je sužovaná rôznymi obmedzeniami a premennými, ktoré vstupujú do procesu optimalizácie. Optimalizácia výroby môže byť kategorizovaná do viacerých oblastí napr. ekonomická optimalizácia výroby, ktorá rieši problematiku radenia zdrojov tepla (kotlov, kogeneračných jednotiek) do prevádzky za rôznych obmedzení. Ďalšou problematikou je optimalizácia hydraulických pomerov sústavy (teploty, tlaky, prietoky).

Výskum v oblasti teplotných strát a tepelných zásobníkov a následná implementácia poznatkov z výskumu do existujúcej sústavy predstavuje pre výrobcov a dodávateľov tepla obrovské investície do celej vybudovanej infraštruktúry, ktoré sú väčšinou neakceptovateľné z hľadiska finančnej udržateľnosti pre výrobcov tepla a preto transformácia sústav CZT na novšiu generáciu potrvá v našich regiónoch desaťročia.

5 PRÍNOSY DIZERTAČNEJ PRÁCE

Súčasťou tejto kapitoly je prehľad prínosov predkladanej dizertačnej práce, ktorej hlavným cieľom *bola analýza dát z teplárenského prostredia a následný návrh predikčných modelov spotreby tepla a ich overenie pomocou simulačných výpočtov pre potreby plánovania výroby tepla.*

Základným pilierom riešenia komplexnej úlohy, ktorá bola predmetom predkladanej dizertačnej práce vyžaduje naštudovanie teoretických pojmov zo skúmanej oblasti a identifikovanie výskumných trendov. Tento krok bol naplnený v teoretickej časti dizertačnej práce – Teoretické východiská.

Vypracovaním analýzy súčasného stavu bolo možné identifikovať náročnosť plánovania výroby tepla pre komplexnú teplárenskú sústavu. Na základe výsledkov analýzy sme identifikovali úzke miesta procesu plánovania výroby a stanovili čiastkové ciele, ktoré je nevyhnutné úspešne naplniť aby hlavný cieľ dizertačnej práce bol splnený. Ďalším z čiastkových cieľov bola analýza skúmaného teplárenského objektu a modelovanie spotreby tepla. Tento čiastkový cieľ bolo nevyhnutné vykonať dôsledne, nakoľko získané poznatky sú hlavným podkladom pre úspešné splnenie hlavného cieľa dizertačnej práce. V práci sme sa zamerali na dátovo orientované modelovanie a demonštrujeme dva prístupy k modelovaniu. Rozhodli sme sa použiť dátovo orientované modelovanie, pretože firma explicitne nevyužíva poznatky z historických záznamov odberu tepla pre procesy plánovania výroby. Prvý zmienený prístup pojednáva o lineárnych modeloch – modely časových radov a druhý prístup používa metódy umelej inteligencie konkrétne neurónové siete a neuro-fuzzy logiku.

Výsledkom modelovania boli univerzálne použiteľné modely odberu tepla a teploty spiatočky, ktoré sú schopné predikovať na 24 hodín dopredu odber tepla a teplotu spiatočky koncových odoberateľov. Už samotné tieto modely predikcie priniesli výhodu v porovnaní so súčasným riešením, ktoré iba disponuje s predikciou na 18 hodinový interval. Získané poznatky z analýzy dát a výborné výsledky z predikčných modelov sme využili na simulačný výpočet teploty výtlaku a prietoku pre predikované 24 hodinový interval. Dosiiahnuté výsledky sú demonštrované na variabilných prípadoch použitia – pre odlišné nároky na odber tepla. Demonštrované výsledky výpočtov jednoznačne potvrdili, že jednotlivé čiastkové ciele ako analýza dát a návrh predikčných modelov boli úspešne splnené, nakoľko pomocou využitia predikcie z navrhnutých modelov a získaných poznatkov z analýzy dát bolo možné znížiť teplotu výtlaku pri rovnakom prietoku. Týmto bol naplnený čiastkový cieľ verifikácia navrhnutého riešenia, kde bolo preukázané, že navrhované modely sú univerzálne a aplikovateľné pre rôzne konfigurácie a stratégie výroby tepla. Tieto čiastkové ciele sú spracované v kapitolách Analýza súčasného stavu a Návrh a tvorba predikčných modelov.

Práca je zameraná tak, aby navrhované riešenie (neurónové siete) bolo čo najrobustnejšie pre rôzne prípady použitia. Bol aplikovaný prístup redukcie dimenzionality vstupnej množiny dát pre odber tepla. Konkrétnejšie sme sa zamerali na tri meteorologické faktory, ktoré sme nahradili jednou premennou, ktorá v sebe kombinovala spomínané meteorologické vstupy. Výsledky jednoznačne potvrdili, že väčší počet vstupov neznamená, že model je presnejší. Práve naopak, viaceré vstupy predstavujú vyššiu komplexnosť modelu a jeho použitie pre široké spektrum aplikácií je tým pádom relatívne obmedzené. Pomocou redukcie dimenzionality bola zvýšená presnosť modelov až trojnásobne.

Navrhnuté riešenie bolo validované spoločnosťou, ktorá potvrdila funkčnosť modelu, pretože počas riešenia dizertačnej práce dokázali upraviť pôvodnú ekvitermickú krivku (115°C/75°C) na 110°C/70°C. Na základe týchto skutočností je možné konštatovať, že splnením jednotlivých čiastkových cieľov bol splnený hlavný cieľ predkladanej dizertačnej práce. Tento čiastkový cieľ je popísaný v kapitole Overenie a porovnanie navrhnutých riešení.

K najdôležitejším prínosom práce považujeme jednoznačne aplikovateľnosť navrhutej metodiky výroby tepla. Prínosy dizertačnej práce môžeme zosumarizovať v troch hlavných oblastiach:

5.1 Vyhodnotenie výskumných otázok

V kapitole 1, na základe vykonanej analýzy problémovej oblasti sme stanovili dve hlavné výskumné otázky, ktoré sme sformulovali nasledovne:

- *Štatistické modelovanie či modelovanie pomocou umelej inteligencie je vhodnejšie na riešenie problematiky predikcie spotreby tepla?*
Na základe dosiahnutých výsledkov môžeme skonštatovať, že modely vytvorené pomocou metód umelej inteligencie (neurónové siete a fuzzy logika) dosiahli výraznejšie lepšie výsledky ako štatistické modely (AR, MA a ich kombinácie). Príčinou tohto javu je nestacionarita a nelineárny charakter odberu tepla. V teoretickej časti práce uvádzame ako významný plus umelej inteligencie, že dokážu namodelovať nelinearitu. Slabotu štatistických modelov sme spozorovali hlavne vo vykurovacom období nakoľko odber tepla je výrazne ovplyvnený stochastickým správaním sa odoberateľov. Počas letného obdobia, kedy denné profily sú rovnaké a dodané teplo je využívané pre potreby TÚV štatistický model mal lepšie výsledky ako modely umelej inteligencie. Nepresnosť modelov umelej inteligencie môžeme pripísať k chýbajúcemu vstupu, ktorý jednoznačne rozlišuje ročné obdobie. Naopak presnosť štatistických modelov môžeme pripísať správne identifikovanej sezónnej zložke. Odpoveď na túto otázku nie je triviálna, pretože výsledky jednoznačne ukázali silné a slabé stránky jednotlivých modelov. Dôležitým krokom je pochopenie pre aký prípad použitia chceme použiť štatistický model alebo model umelej inteligencie.
- *Ako dokážeme znížiť komplexnosť a zvýšiť schopnosť generalizácie navrhnutých modelov?*
Získané výsledky z kapitoly 4.2 jednoznačne potvrdzujú, že znížením komplexnosti modelu sa nezvýši chybovosť modelu. Zamerali sme sa výhradne na redukciu meteorologických faktorov pomocou metódy PCA. Výsledkom bola nová premenná, ktoré v sebe kombinovala tri meteorologické faktory. Takýmto krokom bolo dosiahnutie zvýšenie presnosti modelov v obdobiach kedy jednoznačne vieme určiť využitie dodávaného tepla, či už pre potreby TÚV alebo vykurovania. Mierne zhoršenie sme spozorovali počas jesenného obdobia kedy pre modely je žiaduce mať zvlášť meteorologické faktory ako vstupy. Príčinou tohto je nedostatok informácií/detailov v novej meteorologickej premennej.

ZÁVER

Predmetom predkladanej dizertačnej práce bolo vypracovanie 24 hodinových predikčných modelov odberu tepla a teploty spiatočky a ich validácia na reálnych dátach z prostredia teplárne. V experimentálnej časti práce bolo demonštrované na simulačných scenároch aplikovateľnosť navrhnutých predikčných modelov do procesu plánovania výroby tepla. Na základe simulačných výpočtov bola navrhnutá nová ekvitermická krivka, ktorá je nevyhnutná pre odhad teploty teplonosného média.

Naplnenie stanových cieľov dizertačnej práce vychádzalo z metodiky CRISP-DM, ktorej prvým krokom je pochopenie problematiky. Problematika dizertačnej práce je podrobne popísaná v prvej kapitole kde sme si zadefinovali objekt skúmania – teplárenskú sústavu a vymedzili sme teoretické pojmy z oblastí, ktoré súvisia s riešenou problematikou t.j. teplárenská sústava a metódy umelej inteligencie.

V druhej časti dizertačnej práce sme sa zamerali na proces prípravy a analýzy dát a na proces modelovania teplárenskej sústavy konkrétnejšie modelovanie odberu tepla a teploty spiatočky. V tejto časti sme uviedli sériu krokov (BPMN diagramy), ktoré je nutné dodržať, aby sme zostavili model, ktorý zachytáva dynamické vlastnosti skúmaného objektu. Taktiež v tejto kapitole porovnávame rôzne prístupy k modelovaniu konkrétne lineárne a nelineárne modely. V tejto časti kapitoly sme načrtli aj problematiku absencie jednotného postupu modelovania, ktorá je úzkym hrdlom pre metódy umelej inteligencie, ktorá zabráňuje globálnej aplikovateľnosti týchto nástrojov do rôznych sfér priemyslu.

Tretou časťou práce je validácia predikčných modelov na troch scenároch, ktoré simulujú rôzne prípady odberu tepla. Porovnaním predikčných modelov sme zistili, že nelineárne modely t.j. neurónové siete a neuro-fuzzy logiky sú presnejšie ako lineárny model ARIMAX. Ďalším zistením bola citlivosť nelineárnych modelov na teplé letné počasie kedy prevláda spotreba tepla pre potreby teplej úžitkovej vody. Navrhli sme redukciiu dimenzionality meteorologických dát pomocou metódy PCA t.j. tri meteorologické faktory – vonkajšiu teplotu, rýchlosť vetra a vlhkosť sme nahradili novou meteorologickou premennou, ktorá bola lineárnou kombináciou týchto troch činiteľov. Výsledný model neurónovej siete bol trikrát presnejší za použitia redukcie dimenzionality meteorologických dát v porovnaní s klasickým modelom.

V poslednej časti práci sa venujeme globálnemu riešeniu (celé validačné obdobie) pomocou neurónových sietí, nakoľko boli najpresnejšie modely spomedzi skúmanými modelmi. Zároveň demonštrujeme priebehy odberu tepla, teploty spiatočky a simulačné výpočty prietoku a teploty výtlaku. Porovnávame pôvodnú ekvitermickú krivku 115/75 °C s nameranými hodnotami a našimi simuláciami. Zistili sme, že pôvodná ekvitermická krivka je takmer nepoužiteľná pretože závislosť nemerných hodnôt je pod referenčnou ekvitermickou krivkou. Naše výpočty ležali v intervale spoľahlivosti nameraných hodnôt čo validuje správnosť nášho riešenia a zároveň samotná spoločnosť potvrdila, že samotná pôvodná ekvitermická krivka bola medzičasom znížená. Použitie predikcií v simulačných výpočtoch teploty spiatočky dokázali znížiť priemerne teplotu výtlaku takmer o 5°C pri rovnakom prietoku t.j. inak povedané pomocou simulácií sme potvrdili, že pri nižšej teplote výtlaku a pri pôvodnom prietoku dokážeme dodať rovnaký výkon do sústavy.

Aplikácia nášho riešenia by umožnila výrobcovi tepla efektívne plánovať výrobu tepla z krátkodobého hľadiska (24 hodín vopred), ktorej dôsledkom by bolo zníženie nákladov na výrobu tepla, emisných nákladov.

Na záver môžeme skonštatovať, že pretavené poznatky do modelov umelej inteligencie získaných počas dátovej analýzy musia byť v súčasnosti neodmysliteľnou súčasťou procesu plánovania výroby tepla pretože dokážu významne zefektívniť proces výroby v rôznych aspektoch.

Hlavným cieľom predkladanej dizertačnej práce bola analýza dát z teplárenského prostredia a následný návrh predikčných modelov spotreby tepla a ich overenie pomocou simulačných výpočtov pre potreby plánovania výroby tepla.

Úspešné splnenie hlavného cieľa dizertačnej práce bolo podmienené splnením čiastkových cieľov, ktoré sú zadefinované nasledovne:

- *Vymedzenie teoretických východísk skúmanej problematiky z dostupnej vedecko-výskumnej literatúry*
- *Stanovenie výskumných cieľov*
- *Analýza skúmaného objektu a modelovanie spotreby tepla*
- *Overenie navrhnutých riešení*
- *Zhodnotenie prínosov dizertačnej práce*

Na základe realizácie jednotlivých čiastkových cieľov predkladanej dizertačnej práci môžeme konštatovať, že stanovený **hlavný cieľ dizertačnej práce bol splnený.**

ZOZNAM PUBLIKAČNEJ ČINNOSTI

Skupina B - Publikácie v karentovaných vedeckých časopisoch (ADC, ADD, BDC, BDD, CDC, CDD, AGJ)

ADC Vedecké práce v zahraničných karentovaných časopisoch

ADC01 **KOVÁČ, Szabolcs** - MICHALČONOK, German - HALENÁR, Igor - VAŽAN, Pavel. Comparison of Heat Demand Prediction Using Wavelet Analysis and Neural Network for a District Heating Network. In *Energies*. Vol. 14, iss. 6 (2021), s. 1-21. ISSN 1996-1073 (2021: 3.252 - IF, Q3 - JCR Best Q, 0.653 - SJR, Q1 - SJR Best Q). V databáze: DOI: 10.3390/en14061545 ; WOS: 000634418600001 ; CC: 000634418600001 ; SCOPUS: 2-s2.0-85106426187. [Vnútrofakultná kategória: M*A].

Typ výstupu: článok; Výstup: zahraničný; Kategória publikácie do 2021: ADC

ADC02 STŘELEČ, Peter - HORÁK, Tibor - **KOVÁČ, Szabolcs** - NEMLAHA, Eduard - TANUŠKA, Pavol. IoT Device Prototype Design Using State Machine According to OPC UA. In *IEEE Access*. Vol. 10, (2022), s. 134004-134017. ISSN 2169-3536 (2021: 3.476 - IF, Q2 - JCR Best Q, 0.927 - SJR, Q1 - SJR Best Q). V databáze: DOI: 10.1109/ACCESS.2022.3232061 ; SCOPUS: 2-s2.0-85146224364 ; WOS: 000906231000001 ; CC: 000906231000001. [Vnútrofakultná kategória: M*A].

Typ výstupu: článok; Výstup: zahraničný; Kategória publikácie do 2021: ADC

Skupina C - Publikácie, ktoré nie sú karentované, ale sú registrované v databázach WoS alebo Scopus (ADM, ADN, BDM, BDN)

AFC Publikované príspevky na zahraničných vedeckých konferenciách

AFC01 HORÁK, Tibor - STŘELEČ, Peter - **KOVÁČ, Szabolcs** - NEMLAHA, Eduard - TANUŠKA, Pavol. IoT Device Using LoRaWAN for Data Transfer for Long Distances. In *Software Engineering Application in Systems Design : Proceedings of 6th Computational Methods in Systems and Software 2022 (CoMeSySo2022) conference, Volume 1*. 1. vyd. Cham : Springer, 2023, S. 491-500. ISSN 2367-3370. ISBN 978-3-031-21434-9. V databáze: DOI: 10.1007/978-3-031-21435-6_43 ; SCOPUS: 2-s2.0-85147996175. [Vnútrofakultná kategória: M].

Typ výstupu: príspevok z podujatia; Výstup: zahraničný; Kategória publikácie do 2021: AFC

AFC02 **KOVÁČ, Szabolcs** - HALENÁR, Igor - MICHALČONOK, German - NÉMETHOVÁ, Andrea [Peterková Andrea]. Heat load forecasting: comparison between neuro-fuzzy and neural network approaches a real world case study. In *Artificial Intelligence in Intelligent Systems : proceedings of 10th Computer Science On-line Conference 2021, Vol. 2*. 1. vyd. Cham : Springer, 2021, S. 507-517. ISSN 2367-3370. ISBN 978-3-030-77444-8. V databáze: DOI: 10.1007/978-3-030-77445-5_47 ; SCOPUS: 2-s2.0-85115835014. [Vnútrofakultná kategória: M*B].

Typ výstupu: príspevok z podujatia; Výstup: zahraničný; Kategória publikácie do 2021: AFC

- AFC03 **KOVÁČ, Szabolcs** - STŘELEČ, Peter - HORÁK, Tibor - MICHALČONOK, German - VAŽAN, Pavel. Forecasting Heat Production for a Large District Heating Network with NARX Neural Networks. In *Artificial Intelligence Trends in Systems : 11th Computer Science On-line Conference 2022 (CSOC 2022), Vol.2*. 1. vyd. Cham : Springer Nature, 2022, S. 131-139. ISSN 2367-3370. ISBN 978-3-031-09075-2. V databáze: DOI: 10.1007/978-3-031-09076-9_12 ; SCOPUS: 2-s2.0-85135059334 ; WOS: 000893642100012. [Vnútrofakultná kategória: M].
Typ výstupu: príspevok z podujatia; Výstup: zahraničný; Kategória publikácie do 2021: AFC
- AFC04 NEMLAHA, Eduard - STŘELEČ, Peter - HORÁK, Tibor - **KOVÁČ, Szabolcs** - TANUŠKA, Pavol. Suitability of MQTT and REST Communication Protocols for AIoT or IIoT Devices Based on ESP32S3. In *Software Engineering Application in Systems Design : Proceedings of 6th Computational Methods in Systems and Software 2022 (CoMeSySo2022) conference, Volume 1*. 1. vyd. Cham : Springer, 2023, S. 225-233. ISSN 2367-3370. ISBN 978-3-031-21434-9. V databáze: DOI: 10.1007/978-3-031-21435-6_19 ; SCOPUS: 2-s2.0-85148023204. [Vnútrofakultná kategória: M].
Typ výstupu: príspevok z podujatia; Výstup: zahraničný; Kategória publikácie do 2021: AFC
- AFC05 STŘELEČ, Peter - HORÁK, Tibor - **KOVÁČ, Szabolcs** - TANUŠKA, Pavol - NEMLAHA, Eduard. IoT Device Data Acquisition and Experimental Integration in Production Line Based on OPC UA Protocol. In *Software Engineering Perspectives in Systems [11th Computer Science On-line Conference 2022, Vol. 1]*. 1. vyd. Cham : Springer Nature, 2022, S. 215-223. ISSN 2367-3370. ISBN 978-3-031-09069-1. V databáze: DOI: 10.1007/978-3-031-09070-7_19 ; SCOPUS: 2-s2.0-85135041403 ; WOS: 000893645700019. [Vnútrofakultná kategória: M].
Typ výstupu: príspevok z podujatia; Výstup: zahraničný; Kategória publikácie do 2021: AFC
- AFC06 HORÁK, Tibor - STŘELEČ, Peter - **KOVÁČ, Szabolcs** - TANUŠKA, Pavol - NEMLAHA, Eduard. Detection of IoT Communication Attacks on LoRaWAN Gateway and Server. In *Artificial Intelligence Application in Networks and Systems : Proceedings of 12th Computer Science On-line Conference 2023, Volume 3*. 1. vyd. Cham : Springer Nature, 2023, S. 489-497. ISSN 2367-3370. ISBN 978-3-031-35313-0. V databáze: DOI: 10.1007/978-3-031-35314-7_43. [Vnútrofakultná kategória: M].
Typ výstupu: príspevok z podujatia; Výstup: zahraničný; Kategória publikácie do 2021: AFC

1 Citácia v publikácii registrovaná v citačných indexoch			13
	Zahraničné		13
2 Citácia v publikácii vrátane citácie v publikácii registrovanej v iných databázach okrem citačných indexoch			3
	Zahraničné		3
Súčet			16

Štatistika: indexované v databáze

CC	2
DOI	8
SCOPUS	7
WOS	4

ZOZNAM BIBLIOGRAFICKÝCH ODKAZOV

1. ASB: *Program na výpočet hydrauliky zložitých teplotných sústav*. [cit. 2023-04-30]. Dostupné na internete: <https://www.asb.sk/stavebnictvo/technicke-zariadenia-budov/vykurovanie/program-na-vypocet-hydrauliky-zlozitych-teplarenskych-sustav>
2. BARTOŠ, M. 2016. Dispečerské riadenie prevádzky odovzdávacích staníc tepla. *TZB Haustechnik*, **25**(5), 24-28. ISSN 1210-356X
3. KOSTOLANSKÁ, K. 2021. *Komplexné hodnotenie vplyvu nočných útlmov vykurovacej sústavy a prípravy teplej vody na prevádzku sústavy CZT*. Diplomová práca. Bratislava: STU SVF. 110 s.
4. MHTH: O nás, ©2023 [cit. 2023-04-27]. Dostupné na internete: <https://www.mhth.sk/bratislava/o-nas>
5. MHTH: Výročné správy, ©2023 [cit. 2023-04-27]. Dostupné na internete: <https://www.mhth.sk/verejne-informacie/vyroczne-spravy>
6. Schneider Electric: *Termis* ©2014 [cit. 2023-04-30]. Dostupné na internete: <https://www.se.com/il/en/product-range/61613-termis-engineering/#documents>
7. TAMURA, Shinichi; TATEISHI, Masahiko. Capabilities of a four-layered feedforward neural network: four layers versus three. *IEEE Transactions on Neural Networks*, 1997, 8.2: 251-255.
8. TRENN, Stephan. Multilayer perceptrons: Approximation order and necessary number of hidden units. *IEEE transactions on neural networks*, 2008, 19.5: 836-844.
9. XU, Shuxiang; CHEN, Ling. A novel approach for determining the optimal number of hidden layer neurons for FNN's and its application in data mining. 2008.