



AUTOREFERÁT DIZERTAČNEJ PRÁCE

Žilina, 2025

Ing. Miriam Nicolanská



Ing. Miriam Nicolanská

AUTOREFERÁT DIZERTAČNEJ PRÁCE

INTELIGENTNÉ RIADENIE SPAĽOVACIEHO PROCESU MALÝCH ZDROJOV TEPLA

Na získanie akademického titulu **doktor**
(„**philosophiae doctor**“, v skratke „**PhD.**“) v študijnom
odbore Strojárstvo v študijnom programe Energetické
stroje a zariadenia

Žilina 2025



Dizertačná práca bola vypracovaná v dennej forme doktorandského štúdia na Žilinskej univerzite v Žiline, Strojníckej fakulte, Katedre energetickej techniky

Školiteľ: doc. Ing. Michal Holubčík, PhD.
Žilinská univerzita v Žiline
Strojnícka fakulta
Katedra energetickej techniky

Oponenti: 1. prof. Ing. Miroslav Rimár, CSc.
2. prof. Ing. Róbert Olšiak, PhD.
3. doc. Ing. Peter Ďurčanský, PhD.

Autoreferát bol rozoslaný dňa: 30.06.2025

Obhajoba dizertačnej práce sa koná dňa 26.8.2025 o 9:30 hod. v miestnosti BC 309 na Katedre energetickej techniky (Strojnícka fakulta, Univerzitná 8215/1, 010 26, Žilina) pred komisiou pre obhajobu dizertačnej práce schválenou odborovou komisiou v študijnom odbore Strojárstvo, v študijnom programe Energetické stroje a zariadenia, vymenovanou dekanom Strojníckej fakulty, Žilinskej univerzity v Žiline.

S dizertačnou prácou je možné sa oboznámiť na referáte pre vedu a výskum dekanátu SjF, UNIZA, Univerzitná 8215/1, 010 26 Žilina.

prof. Ing. Jozef Jandačka, PhD. predseda komisie pre obhajobu dizertačnej práce



Úvod

Znečisťovanie ovzdušia patrí k najkritickejším environmentálnym výzvam, pričom lokálne vykurovacie zariadenia významne prispievajú k emisiám oxidov dusíka, síry a jemných prachových častíc, najmä v husto osídlených regiónoch počas vykurovacej sezóny. Perspektívnym riešením je inteligentné riadenie spaľovania využívajúce internet vecí, ktorý umožňuje priebežné monitorovanie prevádzkových parametrov v reálnom čase a cloudové vyhodnocovanie taktiež umožňuje okamžitú adaptáciu algoritmov, čím sa znižuje produkcia emisií a zvyšuje energetická účinnosť malých zdrojov tepla.

Analýza 4100 slovenských domácností odhalila priemerný vek kotlov na tuhé palivá 11 rokov (kachľové zariadenia 17,3 roka) a poukázala taktiež na to, že v Žilinskom kraji tvorili tieto kotly v roku 2019 približne 23% vykurovacích systémov. Smernica Ecodesign (STN EN 303-5:2022) pritom stanovuje prísne hranice ($\eta > 90 \%$, $\text{CO} < 500 \text{ mg/m}^3$, $\text{NO}_x \leq 200 \text{ mg/m}^3$, $\text{TZL} \leq 20 \text{ mg/m}^3$ pri 10 % O_2).

Dizertačná práca preto navrhuje a experimentálne overuje **IoT - monitorovaciu zostavu** – prototyp bezdrôtového monitorovacieho systému skladajúceho sa z nízkonákladových emisných snímačov, mikropočítača a elektronickej zložky, z meracieho úseku spalín a taktiež z modulárnej jednotky s frekvenčnými meničmi – testovanej pri statických i dynamických prevádzkových podmienkach. Výskum analyzuje dostupné IoT riešenia, identifikuje kľúčové faktory ovplyvňujúce účinnosť riadenia a predkladá vlastný adaptívny riadiaci systém, ktorý dokáže významne zmierniť negatívny dopad malých zdrojov tepla na kvalitu ovzdušia.



Stručný prehľad problematiky + základná literatúra z ktorej sa pri riešení DDP vychádzalo

Proces spaľovania je fyzikálno-chemická reťazová reakcia, pri ktorej sa horľavé látky zlučujú s kyslíkom zo vzduchu a uvoľňujú značné množstvo tepla; k zápalu môže dôjsť samovznietením alebo vonkajším tepelným impulzom. Pri tuhých palivách prebiehajú štyri fázy: (1) ohrev paliva do 200 °C s odparom vody a prchavých zložiek; (2) anaeróbne splyňovanie medzi 200 – 500 °C, pri ktorom termický rozklad generuje CO_2 , H_2O , CH_4 , H_2 a uhlíkovodíky; (3) horenie prchavých plynov nad 500 °C, kde sa uvoľňuje najväčšia časť plameňového tepla; a (4) pomalé spaľovanie uhlíkového zvyšku v rozmedzí 200 – 500 °C s výraznou spotrebou kyslíka.

Počas spaľovania drevných peliet vzniká spektrum znečisťujúcich látok monitorovaných podľa vyhlášky 411/2012 Z. z. Dôležité sú tuhé častice PM_{25} a PM_{10} , ktoré prenikajú hlboko do dýchacích ciest a zhoršujú kardiopulmonálne zdravie; oxidy dusíka (NO_x) a siričitý (SO_2) spôsobujúce kyslý dážď, smog a prízemný ozón; oxid uhoľnatý (CO) navodzujúci hypoxiu; prchavé organické zlúčeniny (VOC) s karcinogénnym potenciálom; a skleníkový oxid uhličitý (CO_2) prispievajúci k otepleniu klímy. Európska únia pritom stanovila, že do roku 2030 musia byť čisté emisie skleníkových plynov znížené aspoň o 55 % oproti roku 1990 a do roku 2050 dosiahnuť klimatickú neutralitu, čo bude vyžadovať výrazné obmedzenie CO_2 , NO_x aj prachových častíc z malých spaľovacích zdrojov.



Kvalitu spaľovania charakterizuje súbor parametrov, ktoré určujú rovnováhu medzi energetickou účinnosťou a tvorbou emisií. Základom je pomer vzduchu k palivu (AFR); pri biomase optimálne 3–7 % prebytočného vzduchu zabezpečuje úplné prehorenie bez nadbytočných tepelných strát. Bezrozmerná lambda ($\lambda = \text{AFR skutočné} / \text{AFR ideálne}$) signalizuje, či je zmes bohatá ($\lambda < 1$), stechiometrická ($\lambda \approx 1$) alebo chudobná ($\lambda > 1$) a priamo súvisí s tvorbou CO, nespálených uhľovodíkov a NOx. Vlhkosť paliva má zostať pod 20 %; každé dodatočné percento vody znižuje teplotu plameňa, predlžuje splyňovanie a exponenciálne zvyšuje CO.

Regulačné stratégie malých zdrojov tepla sa pohybujú od dvojstavového Štart/Stop cez PID až po modelovo prediktívne a adaptívne algoritmy. Otvorená slučka iba zapína či vypína zariadenie podľa časovača, kým zatvorená PID sleduje teplotnú odchýlku a kombinuje P-, I- a D-člen. Modelovo prediktívne riadenie vytvára matematický obraz kotla a optimalizuje budúci chod pri rešpektovaní obmedzení. Najpokročilejší prístup využíva strojové učenie: neurónové siete či podporné vektorové stroje sa učia z historických dát, identifikujú nelineárne vzťahy a v reálnom čase upravujú dávkovanie paliva aj vzduchu, aby maximalizovali účinnosť a minimalizovali CO, NOx a PM.




Tézy dizertačnej práce

- I. Analýza a spracovanie parametrov spaľovania malých zdrojov tepla.
- II. Vytvorenie a aplikácia numerického modelu pre riadenie procesu spaľovania v malých zdrojoch tepla.
- III. Návrh a realizácia inteligentného riadenia procesu spaľovania v malom zdroji tepla.
- IV. Experimentálne overenie inteligentného riadenia procesu spaľovania v malom zdroji tepla v rôznych režimoch.
- V. Analýza a vyhodnotenie experimentov.
- VI. Návrh inteligentného riadenia pre malý zdroj tepla.

Zvolené metódy spracovania – metodika riešenia

Experimentálna zostava inteligentného radiaceho systému je rozdelená do troch hlavných častí a je zobrazená na obrázku:



Obr. 1 : Schéma experimentálnej zostavy



(1) Modulárna jednotka s frekvenčnými meničmi

Modulárna jednotka pozostáva z dvoch identických frekvenčných meničov typu INVT GD20-0R7G-4-B „Goodrive20“ s menovitým výkonom 0,75 kW. Frekvenčné meniče zabezpečovali plynulé riadenie rýchlostí elektromotorov:

- a) zapojený na ventilátor experimentálneho kotla (kontinuálne ovládanie prietoku prírodného vzduchu do spaľovacej komory) – Funkčný frekvenčný rozsah 10 až 50 Hz
- b) zapojený na podávač paliva (kontinuálne riadenie rýchlosti podávania peliet) - Funkčný frekvenčný rozsah 25 až 50 Hz

Oba meniče boli zapojené pomocou prevodníka RS485 na USB, ktoré umožnilo ovládanie jednotlivých frekvencií v programe MATLAB.



Obr. 2 : Modulárna jednotka s frekvenčnými meničmi



(2) Experimentálne IoT zariadenie

Monitorovací IoT prototyp „Nicolite V2.0“ slúži ako senzorický uzol regulačnej sústavy a pozostáva z mikropočítača Arduino Mega, batérií, Wi-Fi modulu a viacerých nízkonákladových emisných snímačov. V reálnom čase zaznamenáva hodnotu teploty, koncentrácie kyslíka O_2 , oxidu uhoľnatého CO, oxidu uhličitého CO_2 , tuhých znečisťujúcich látok (PM) a údaje pochádzajúce z nich odosiela do cloudovej platformy ThingSpeak - tým je umožnené v reálnom čase sledovať kvalitu spaľovania. Konkrétnejší popis prítomných emisných snímačov nachádzajúcich sa v zariadení je uvedený nižšie:

- Infračervený snímač SCD41 (400 – 5000 ppm CO_2)
- Gravity I2C O_2 snímač (0 – 25 % O_2)
- DFROBOT PM snímač (0 – 1000 $\mu g/m^3$ PM₁₀)
- Gravity P100 termočlánok (30 – 350 °C)
- Odporový snímač MQ-7 (0 – 2000 ppm CO)
- ENS160 + BME280 (400 – 65 000 ppm e CO_2 , 0 – 65 000 ppm TVOC, –40 °C až 85 °C)



Obr. 3 : IoT bezdrôtové monitorovacie zariadenie kvality spaľovania



(3) Laboratórne meracie prístroje

Referenčné analyzátory v päťsekundových intervaloch simultánne monitorujú koncentrácie CO, CO₂, O₂ a tepelný výkon kotla, čím slúžia na overenie presnosti nízkonákladových senzorov integrovaných v bezdrôtovom IoT monitorovacom systéme. V meracom profile spalín sú inštalované nasledovné zariadenia::

- **Analyzátor spalín ABB AO2020** : Modulárne prevedenie: O₂ 0 – 25 vol %, CO 0 – 1000 ppm (voliteľne NO_x, SO₂, CO₂), presnosť $\leq \pm 1$ % rozsahu, prevádzka -5 °C až $+45$ °C, krytie IP54.
- **Merač komínového ťahu**: – Diferenčný tlak -20 až $+20$ Pa, presnosť $\pm 0,5$ Pa, kapilárny senzorový systém poskytuje stabilné meranie ťahu.
- **Termočlánky PT100** – Tri odporové snímače triedy B (IEC 60751), rozsah do 600 °C, presnosť $\pm (0,3 + 0,005 \cdot t)$ °C, trojvodičové zapojenie zabezpečuje presné sledovanie tepelného výkonu.
- **Magnetický prietokomer Yokogawa AXG**: Meria vodivé kvapaliny (≥ 1 $\mu\text{S/cm}$) pri DN $2,5$ – 1800 mm, presnosť $\pm 0,35$ %, výstupy 4 – 20 mA, HART a impulzy, diagnostika elektród zvyšuje spoľahlivosť.

Experimentálne merania na zber dát

Experimentálne meranie boli vykonané v dvoch režimoch, pomocou ktorých bol inteligentný regulačný systém navrhnutý. Merania boli rozdelené do dvoch hlavných skupín - statické a dynamické. Cieľom zberu dát je porozumenie dopadu nastavenia výkonu ventilátora a podávača na produkciu emisných látok, tepelný výkon a všeobecnú efektivitu v čase a porozumieť hysterezie emisných prvkov pri zmenách podmienok.



Merania sa uskutočnili pri konštantných rýchlostiach podávania peliet a rýchlosť podávača bola rozdelená do troch kategórií:


- **NÍZKA** rýchlosť : **2,09 až 2,6 kg/h** (25 - 30 Hz)
- **STREDNÁ** rýchlosť : **3,10 až 3,62 kg/h** (35 - 40 Hz)
- **VYSOKÁ** rýchlosť : **4,11 až 4,62 kg/h** (45 - 50 Hz)

Statické merania

Každá konfigurácia otáčok podávača a ventilátora bola analyzovaná v 20-minútových intervaloch, pričom úvodných 5 minút každého cyklu bolo vylúčených z hodnotenia z dôvodu potrebnej stabilizácie systému po úprave výstupnej frekvencie meniča. Ventilátor bol riadený v krokoch po 2 Hz v rozsahu od 10 Hz (13 m³/h) do 50 Hz (110 m³/h).


Dynamické merania

Dynamické merania boli navrhnuté tak, aby simulovali reálne zmeny tepelného zaťaženia kotla prostredníctvom riadeného kolísania výstupnej frekvencie ventilátora. Skoková záťažová skúška („STEP“) bola realizovaná pomocou funkcie, ktorá v časovom intervale náhle zmenila otáčky elektromotora ventilátora pri rôznych dĺžkach fázy T_2 : 15 s, 30 s a 60 s.



Obr. 4 : Skokové meranie : „STEP“ profil výkonu ventilátora

Druhým typom dynamického merania, realizovaným aj za účelom validácie nízkonákladových senzorov, boli tzv. krokové merania („RAMP“), založené na plynulej lineárnej zmene otáčok ventilátora v rozsahu trvania od 15 sekúnd do 2 minút. Zaznamenané veličiny – teplota, koncentrácie CO, NO_x a PM – identifikovali prechodové javy relevantné pre vývoj adaptívnych stratégií riadenia spaľovania a zároveň umožnili kvantifikovať časy stabilizácie a medzné parametre účinnosti kotlového cyklu.



Obr. 5 : Krokové meranie : „RAMP“ profil výkonu ventilátora

Základná regulačná logika

Riadiaca stratégia kotla je koncipovaná tak, aby pri danej požiadavke udržiavala cieľový tepelný výkon. Používateľ môže definovať časový horizont, v ktorom má sústava výkon dosiahnuť. Predikčný model, zostavený z experimentálne získaných dát, podporuje dve PID slučky riadiace frekvencie meničov ventilátora a podávača. Pre reguláciu je stanovená tolerancia výkonovej odchýlky $\pm 2\%$ a päťminútový limit priemernej koncentrácie CO - 550 mg/m³. Algoritmus preferuje nižšiu rýchlosť podávača, čím minimalizuje spotrebu paliva, pokiaľ je zároveň dodržaný definovaný limit produkovanej koncentrácie




emisií. Okrem toho neustále vyhodnocuje dynamiku spaľovania, aby predišiel tepelným šokom a limitným stavom ventilátora i podávača.

Dosiahnuté výsledky


Spracovanie dát zo statického merania

Obrázok zobrazuje časový priebeh koncentrácie oxidu uhoľnatého (CO) prepočítaný na referenčných 10 % O₂ pri najnižšej frekvencii podávania paliva.




Obr. 6 : Časový priebeh koncentrácia CO pri 2,09 kg/h podávani paliva

Pri nízkom dávkovaní paliva 2,09 – 2,60 kg/h (25 – 30 Hz) bola hodnotená korelácia medzi tepelným výkonom a koncentráciou CO. V tomto rozsahu spôsobí mierne zvýšenie frekvencie podávača neúmerňný nárast výkonu ($\approx +4$ kW). Najlepší kompromis medzi výkonom a emisiami sa dosahuje pri objemovom prietoku vzduchu 30 – 40 m³/h. Ak sa však dávka peliet zvyšuje bez primeraného navýšenia vzduchu, rozširuje sa pásmo, v ktorom CO presahuje 500 mg/m³. Pri prietokoch nad 40 m³/h priebehy CO konvergujú až po menovitý výkon ventilátora.



Obr. 7 : Koncentrácia CO a tepelný výkon pri nízkych rýchlostiach podávača


Pri strednom dávkovaní 3,1 – 3,61 kg/h (35 – 40 Hz) je výrazne zvýšenie výkonu, približne o 0,5-1 kW, výrazný rozdiel pri nízkych rýchlostiach podávača. Do 20 m³h⁻¹ koncentrácia CO prekračuje 4000 mg/m³. Najnižšie koncentrácie dosahujú 200 mg/m³ (35 Hz) a 300 mg/m³ (40 Hz) v pásme 40 – 50 mg/m³, ktoré tak tvorí optimum medzi výkonom a emisiami. Zóna, ktorá spĺňa emisnú limitu CO je viac ako 20 násobne užšia pri 3,61 kg/h oproti 3,1 kg/h čo je veľmi dôležité pre ladenie regulačného modelu a jeho stabilitu.



Obr. 8 : Koncentrácia CO a tepelný výkon pri stredných rýchlostiach podávača



Pri najrýchlejšom dávkovaní 4,11 – 4,62 kg/h (45 – 50 Hz) sa pri prívode vzduchu < 40 m³/h je výrazná nestabilita: CO kulminuje okolo 17000 mg/m³, čo signalizuje kritický nedostatok kyslíka a riziko neúplného spaľovania. Po prekročení tejto hranice sa proces upokojí; výkonové krivky zostávajú takmer paralelné, pričom zvýšenie podávania zvyšuje priemerný výkon z $\approx 12,2$ kW (45 Hz) na ≈ 14 kW (50 Hz). Ako optimálne sa javí pásmo 50 – 80 m³/h, kde CO klesá 200-400 mg/m³ a výkon vykazuje stabilný mierny pokles bez prudkých fluktuácií, čo poskytuje prijateľný kompromis medzi energetickým výstupom a emisnou záťažou.




Obr. 9 : Koncentrácia CO a tepelný výkon pri vysokých rýchlostiach podávača

Validácia nízkonákladových snímačov

Graf ukazuje teplotu spalín namerané prostredníctvom nízkonákladového termočlánku DFROBOT PT100 umiestneného približne 4,5 m nad referenčným snímačom. V dôsledku tejto výškovej odchýlky zaznamenal referenčný snímač rozsah 140 – 230 °C, zatiaľ čo bezdrôtové IoT monitorovacie zariadenie zaznamenalo 110 – 180 °C. Po numerickej




jednoduchej korekcie (+30 °C) sa priebehy prakticky prekrývajú, čo poukazuje na to, že aj s absolútnou chybou dokáže cenovo výhodnejší snímač spoľahlivo sledovať trend a dynamiku spaľovania.




Obr. 10 : Koncentrácia CO a tepelný výkon pri vysokých rýchlostiach podávača

Skoková skúška pri dávke 3,6 kg/h porovnáva koncentráciu O_2 zaznamenanú referenčným analyzátorom ABB a nízkonákladovým snímačom DFRobot. Po skokovom znížení prietoku vzduchu na $13 \text{ m}^3\text{h}^{-1}$ zachytili oba senzory dynamický pokles O_2 . Po aplikácii korekcie výšky snímača (-7% O_2) sa koncentrácie (fialová a zelená čiara) skoro identicky zhodovali počas stabilizácie kotla.



Obr. 11 : Porovnanie koncentrácie kyslíka meraná ABB a DFROBOT snímačom (s posunutím) pri 3,6 kg/h (skoková skúška)


Na ďalšom grafe je zobrazené porovnanie koncentrácie oxidu uhoľnatého (CO) zo snímača MQ-7 pri podávaní 2,6 kg/h. Napriek veľkému rozdielu pozície snímačov v komíne sa krivky referenčného ABB a nízkonákladového MQ-7 prakticky zhodujú: po prenasťavení ventilátora na 13 m³/h prebiehajú vysoko dynamické zmeny koncentrácie CO. Pri oboch snímačoch má priebeh koncentrácie rovnakú monotónnosť na rovnakých časových úsekoch. Záverom merania je, že nízkonákladový snímač môže byť spoľahlivo aplikovaný na aktívne potláčanie koncentrácie CO počas regulácie pomocou strojového učenia (napr. gradientovou metódou).



Obr. 12 : Koncentrácia oxidu uhoľnatého (CO) pri 10% O₂ ABB a nízkonákladového snímača MQ-7 pri 2,6 kg/h (skokové meranie)


Spracovanie dát zo skokového merania

Výsledky merania potvrdili, že dominantný podiel tuhých častíc mal aerodynamický priemer menší než 2,5 μm , čo je zrejmé aj z priloženého grafu. Pri dávkovaní paliva rýchlosťou 2,6 kg/h a zníženom prietoku spaľovacieho vzduchu na 13 m³/h bolo maximálne množstvo častíc zaznamenané až po 145 sekundách. Merania zároveň preukázali výraznú hysteréziu v koncentráciách TZL pri dynamických zmenách výkonu ventilátora. Hodnota PM₁₀ dosahovala približne 640 $\mu\text{g}/\text{m}^3$, zatiaľ čo PM_{2,5} bola na úrovni 610 $\mu\text{g}/\text{m}^3$, čo poukazuje na veľmi nízky podiel väčších častíc (rozdiel len 30 $\mu\text{g}/\text{m}^3$). Získané dáta zároveň potvrdili technickú náročnosť inteligentného riadenia s cieľom aktívnej minimalizácie TZL, keďže systém vykazuje výrazne oneskorenú odozvu a pomalú časovú dynamiku.




Obr. 13 : Koncentrácia tuhých znečisťujúcich látok PM₂₅ a PM₁₀ pri 2,6 kg/h (skokové meranie)

S rastúcou rýchlosťou dávkovania peliet do spaľovacej komory sa priebeh koncentrácie CO v čase stával čoraz komplexnejším, vrátane pomeru voči tepelnému výkonu. Ilustrujú to nasledujúce dva grafy: prvý pri dávkovaní 2,09 kg/h a druhý pri zvýšenej rýchlosti 4,11 kg/h. Výsledky meraní naznačujú, že s narastajúcou intenzitou spaľovania dochádza k významnému zhoršeniu stability koncentrácie CO v spaľovacích podmienkach kotla.



Obr. 14 : Pomer koncentrácie CO a tepelného výkonu pri 2,09 kg/h (skokové meranie)



Obr. 15 : Pomer koncentrácie CO a tepelného výkonu pri 4,11 kg/h (skokové meranie)



Prínos pre ďalší rozvoj vedy a pre prax

Prínos pre vedu a výskum

Dizertačná práca ukázala praktickú realizovateľnosť inteligentného riadenia spaľovacieho procesu v malom zdroji tepla pomocou frekvenčných meničov, ktoré ovládajú ventilátor a podávač paliva. Tieto meniče boli úspešne riadené prostredníctvom programového kódu v prostredí MATLAB. Regulačný zásah bol generovaný pomocou modulu Deep Learning Toolbox, čím sa demonštrovalo priame prepojenie algoritmov umelej inteligencie so softvérovým riadením v reálnom čase.

Ďalším dôležitým výsledkom práce je overenie použiteľnosti nízkonákladových snímačov pri monitorovaní spaľovacích procesov. Experimenty potvrdili, že tieto cenovo dostupné senzory dokážu veľmi presne kopírovať výstupy špecializovaných meracích zariadení. To otvára nové možnosti ich využitia pri regulácii a diaľkovom monitoringu malých spaľovacích zariadení. Práca tak prispieva k lepšiemu porozumeniu možností merania a hodnotenia emisií pri nízkych obstarávacích nákladoch.

Prínos pre prax

Jednoznačným prínosom pre prax je možnosť integrovať nízkonákladové snímače priamo do existujúcich kotlov na tuhé palivá s cieľom zlepšiť riadenie spaľovania, zvýšiť tepelnú účinnosť a znížiť produkciu emisií. Tieto senzory umožňujú jednoduché a cenovo dostupné sledovanie kvality spaľovania, čo môže pomôcť prevádzkovateľom kotlov splniť prísnejšie legislatívne požiadavky. Nasadenie takejto technológie môže významne predĺžiť životnosť starších zariadení a



zefektívniť ich prevádzku bez potreby rozsiahlej modernizácie hardvéru.

Zásadným prínosom je aj nový spôsob programovania a zberu údajov z viacerých zdrojov súčasne. Vytvorený systém umožňuje pripojenie desiatok až stoviek malých kotlov do jednej cloudovej siete, kde sú dáta centralizované a ďalej spracovávané. Takto vzniká distribuovaná databáza reálnych spaľovacích podmienok, ktorá môže slúžiť na kolektívnu optimalizáciu regulácie, výskum spaľovania konkrétnych palív alebo testovanie regulačných algoritmov v rôznych prevádzkových režimoch – čo nie je možné (ani potenciálne realizovateľné) v tradičných systémoch.

Resumé v anglickom jazyku

Improving combustion efficiency and reducing emissions from small-scale heat sources is a major challenge in the fields of energy and environmental protection. The aim of this dissertation was to design an intelligent control system for an experimental biomass boiler. The experimental setup consisted of three main components: (1) a modular unit equipped with INVT 0.75 kW frequency converters and RS485 transceivers, enabling programmable control of the fan and fuel feeder output via MATLAB; (2) a wireless Wi-Fi IoT prototype for combustion quality monitoring, equipped with low-cost emission and temperature sensors (installed on the flue); and (3) a measurement section composed of laboratory instruments, including thermometers for inlet and outlet water temperatures, water/combustion air flow meters, an ABB AO 2020 flue gas analyzer, and a chimney draft sensor. Experimental data were collected under both steady-state and dynamic thermal output conditions



across the entire control range of the frequency converters. Data were recorded in real time using MATLAB as well as the cloud platform ThingSpeak. Sensor validation—specifically for MQ-7, Gravity O₂, DFROBOT thermocouple, and the SCD41 CO₂ sensor—demonstrated sufficient agreement with the flue gas measurement section throughout the duration of the experimental campaign. Testing of the intelligent control system involved applying predictive PID control with constraints on the rate of frequency change and a maximum CO concentration limit (550 mg/m³). The target output was set to 9 kW, with the system maintaining stable performance between 8.7 and 9.3 kW. The results confirm that the proposed system is suitable for research, testing, and real-time control calibration.

Zoznam použitej literatúry

- 1) A. Backa, J. Drga, L. Martvoňová, and M. Polačiková, "Machine learning model designed to predict the amount of CO₂ produced by a small pellet boiler," MATEC Web of Conferences, vol. 345, p. 00002, Oct. 2021, doi: 10.1051/matec/202134500002.
- 2) A. Backa, N. Čajová Kantová, R. Nosek, and M. Patsch, "Evaluating the combustion of various biomass pellets in a small heat source with underfeed pellet burner: Heat output, gas emission and ash melting behavior," Journal of the Energy Institute, vol. 118, p. 101936, Feb. 2025, doi: 10.1016/j.joei.2024.101936.
- 3) A. Kaleli, B. Sungur, and C. Basar, "Comparative study of machine learning methods integrated with different optimisation algorithms for prediction of thermal performance and emissions in a pellet stove," Energy Sources, Part A: Recovery, Utilization, and Environmental Effects, vol. 45, no. 3, pp. 7673–7693, Aug. 2023, doi: 10.1080/15567036.2023.2223154.
- 4) A. M. Turing, "Computing Machinery and Intelligence," Mind, vol. LIX, pp. 433–460, 1950.
- 5) A. Potter, Principles and Applications of PID Controllers. NY Research Press, 2015.
- 6) AMR GmbH, "DPS Differential Pressure Gauge: Technical datasheet," Jan. 2025. [Online]. Dostupné z: <https://amr-pressuresensors.com/dps-datasheet.pdf>
- 7) B. Sungur, C. Basar, and A. Kaleli, "Multi-objective optimisation of the emission parameters and efficiency of pellet stove at different supply airflow positions



- based on machine learning approach,” *Energy*, vol. 278, p. 127896, Sep. 2023, doi: 10.1016/j.energy.2023.127896.
- 8) D. Petrocelli and A. M. Lezzi, “Modeling operation mode of pellet boilers for residential heating,” *J Phys Conf Ser*, vol. 547, p. 012017, Nov. 2014, doi: 10.1088/1742-6596/547/1/012017.
 - 9) D. Racero-Galaraga, J. D. Rhenals-Julio, S. Sofan-German, J. M. Mendoza, and A. Bula-Silvera, “Proximate analysis in biomass: Standards, applications and key characteristics,” *Results Chem*, vol. 12, p. 101886, Dec. 2024, doi: 10.1016/j.rechem.2024.101886.
 - 10) D. Sundararajan, *Control Systems: An Introduction*. Berlin: Springer, 2023.
 - 11) Daniel Parente, “Understanding Big Data through the 5 Vs,” *Medium*. Cit.: Jun. 14, 2025. [Online]. Dostupné z: <https://medium.com/daniel-parente/understanding-big-data-through-the-5-vs-b87750275fca>
 - 12) DFROBOT, “Gravity: Analog High Temperature Sensor (PT100),” 2025. [Online]. Dostupné z: <https://www.dfrobot.com/product-1474.html>
 - 13) DFRobot, “Gravity: Analog Temperature Sensor,” 2020. [Online]. Dostupné z: <https://www.dfrobot.com/product-1090.html>
 - 14) DFROBOT, “Gravity: Laser PM2.5 Air Quality Sensor For Arduino,” 2025. [Online]. Dostupné z: <https://www.dfrobot.com/product-1474.html>
 - 15) DFROBOT, “Gravity: Multi-function Environmental Module (ENS160 + BME280),” 2025. [Online]. Dostupné z: <https://www.dfrobot.com/product-2064.html>
 - 16) DFROBOT, “Gravity: SCD41 CO2 Sensor,” 2025. [Online]. Dostupné z: <https://www.dfrobot.com/product-2439.html>
 - 17) Energie Portál. Kotly na drevné pelety. Najekologickejšie vykurovanie pri nízkych nákladoch. Cit.: Apr. 23, 2023. [Online]. Dostupné z: <https://www.energie-portal.sk/Dokument/kotly-na-drevne-pelety-najekologickejsie-vykurovanie-pri-nizkych-nakladoch-103569.aspx>
 - 18) European Commission, “European Climate Law: net-zero greenhouse gas emissions by 2050 and a 55% emissions cut by 2030,” 2021. [Online]. Dostupné z: https://climate.ec.europa.eu/eu-action/european-climate-law_en
 - 19) European Commission, “Fit for 55 package: legislative measures to reach 55% emissions reduction by 2030,” 2021. [Online]. Dostupné z: https://ec.europa.eu/commission/presscorner/detail/en/IP_21_3541
 - 20) European Environment Agency (EEA), “Air pollution caused 400 000 premature deaths in EU in 2014,” 2015. [Online]. Dostupné z: <https://www.geotab.com/blog/air-quality/>
 - 21) European Environment Agency (EEA), “Air quality monitoring sites in Europe: approximately 5,000 urban and 800 regional stations in 29 countries,” 2016. [Online]. Dostupné z: <https://www.eea.europa.eu/publications/92-9167-058-8/page010.html>
 - 22) European Environment Agency (EEA), “Many Europeans still exposed to harmful air pollution in 2015,” 2015. [Online]. Dostupné z: <https://www.geotab.com/blog/air-quality/>
 - 23) Európska komisia, “Nariadenie Komisie (EÚ) 2015/1189 z 28. apríla 2015, ktorým sa vykonáva smernica 2009/125/ES o požiadavkách na ekodizajn kotlov na tuhé palivá,” 2015. [Online]. Dostupné z: <https://eur-lex.europa.eu/legal-content/SK/TXT/?uri=CELEX%3A32015R1189>



- 24) Eurosensor, "ABB AO2020 - URAS 26 Analyzer (CO + O₂)," 2025. [Online]. Dostupné z: https://www.eurosensor.com/en/product/abb-analyzers-ao2020-uras-26-2-channels-co-plus-o2?utm_source=chatgpt.com
- 25) F. Morilla, "Benchmark for PID control based on the Boiler Control Problem," IFAC Proceedings Volumes, vol. 45, no. 3, pp. 346–351, 2012, doi: 10.3182/20120328-3-IT-3014.00059.
- 26) G. K. Alitasb and A. O. Salau, "Multiple-input multiple-output Radial Basis Function Neural Network modeling and model predictive control of a biomass boiler," Energy Reports, vol. 11, pp. 442–451, Jun. 2024, doi: 10.1016/j.egy.2023.11.063.
- 27) Hanwei Electronics Co. Ltd., "MQ-7 Carbon Monoxide Gas Sensor Technical Datasheet," 2008. [Online]. Dostupné z: <https://www.winsensor.com/d/files/semiconductor-gas-sensor/mq-7.pdf>
- 28) Christopher Zemann and Markus Göllés, "Model- based control strategy for biomass steam boilers," 2020. Cit.: Jan. 22, 2024. [Online]. Dostupné z: <https://task32.ieabioenergy.com/wp-content/uploads/sites/2/2019/03/Developing-advanced-control-strategies.pdf>
- 29) INVT Electric Co. Ltd., "Goodrive20-EU User Manual: GD20-0R7G-4-B Variable Frequency Drive," 2023, Shenzhen, China. [Online]. Dostupné z: [https://www.invt.com/Upload/202303/Goodrive20%20User%20Manual%20\(T hree%20Phase%20Series\).pdf](https://www.invt.com/Upload/202303/Goodrive20%20User%20Manual%20(T hree%20Phase%20Series).pdf)
- 30) J. He et al., "Optimizing the Controlling Parameters of a Biomass Boiler Based on Big Data," Energies (Basel), vol. 16, no. 23, p. 7783, Nov. 2023, doi: 10.3390/en16237783.
- 31) J. Mižáková, J. Pitel', A. Hošovský, I. Pavlenko, M. Ochowiak, and S. Khovanskyi, "Biomass Combustion Control in Small and Medium-Scale Boilers Based on Low Cost Sensing the Trend of Carbon Monoxide Emissions," Processes, vol. 9, no. 11, p. 2030, Nov. 2021, doi: 10.3390/pr9112030.
- 32) J. Speight, "Combustion of Hydrocarbons," Nature, vol. 130, no. 3281, pp. 355–393, Jan. 2011, doi: 10.1016/B978-0-7506-8632-7.10010-6.
- 33) Juraj Vaculík, Od telemetrie k internetu vecí I, vol. ISBN 9788055415215. Žilina: EDIS, 2019.
- 34) K. Foot, "A Brief History of the Internet of Things," Dataversity. Cit.: Jun. 14, 2025. [Online]. Dostupné z: <https://www.dataversity.net/brief-history-internet-things/>
- 35) K. Wang, "Wood Pellet Boiler Heating System Evaluation and Optimization," Clarkson University, 2017. [Online]. Dostupné z: <https://www.proquest.com/openview/2dc4c58f7bf1ff86c3cabe25d31f9bd1/1?c bl=18750&diss=y&pq-origsite=gscholar>
- 36) Keu Wang, "Wood Pellet Boiler Heating System Evaluation and Optimization," Dissertation, Clarkson University, New York, 2017.
- 37) L. Böhler, M. Fallmann, G. Görtler, J. Krail, F. Schittl, and M. Kozek, "Emission limited model predictive control of a small-scale biomass furnace," Appl Energy, vol. 285, p. 116414, Mar. 2021, doi: 10.1016/j.apenergy.2020.116414.
- 38) L. Han et al., "Optimization of Circulating Fluidized Bed Boiler Combustion Key Control Parameters Based on Machine Learning," Energies (Basel), vol. 16, no. 15, p. 5674, Jul. 2023, doi: 10.3390/en16155674.



- 39) L. M. Romeo and R. Garetá, "Hybrid System for fouling control in biomass boilers," *Eng Appl Artif Intell*, vol. 19, no. 8, pp. 915–925, Dec. 2006, doi: 10.1016/j.engappai.2006.01.019.
- 40) L. Varga and M. Lieskovský, "Palivová drewna biomasa a jej využitie," *Energie portál*. Cit.: Jun. 23, 2023. [Online]. Dostupné z: <https://www.energieportal.sk/Dokument/palivova-drevna-biomasa-a-jej-vyuzitie-102460.aspx>
- 41) M. A. Nemitallah et al., "Artificial intelligence for control and optimization of boilers' performance and emissions: A review," *J Clean Prod*, vol. 417, p. 138109, Sep. 2023, doi: 10.1016/j.jclepro.2023.138109.
- 42) M. Holubčík and J. Jandačka, "Produkcia emisií pri spaľovaní dreva v závislosti na jeho vlhkosti," *tzbinfo*, Apr. 2018, Cit.: Jun. 15, 2025. [Online]. Dostupné z: <https://vytapieni.tzb-info.cz/vytapime-pevnymi-palivy/17230-produkcia-emisi-pri-spalovani-dreva-v-zavislosti-na-jeho-vlhkosti>
- 43) M. Holubčík, Nosek Radovan, and Nemec Patrik, *Inovatívne riešenia pre zdroje tepla*. EQUILIBRIA, s.r.o., 2022.
- 44) M. Szubel, K. Papis-Frączek, and S. Podlasek, "Impact of the air supply system configuration on the straw combustion in small scale batch-boiler - experimental and numerical studies," *Renew Energy*, vol. 220, p. 119540, Jan. 2024, doi: 10.1016/J.RENENE.2023.119540.
- 45) N. Čajová Kantová, M. Holubčík, A. Čaja, J. Trnka, and J. Jandačka, "Analyses of Pellets Produced from Spruce Sawdust, Spruce Bark, and Pine Cones in Different Proportions," *Energies (Basel)*, vol. 15, no. 8, p. 2725, Apr. 2022, doi: 10.3390/en15082725.
- 46) N. Čajová Kantová, R. Cibula, A. Szlek, A. Čaja, R. Nosek, and P. Belany, "The energy assessment of COVID-19 medical waste as a potential fuel," *Energy Reports*, vol. 9, pp. 4995–5003, Dec. 2023, doi: 10.1016/J.EGYR.2023.04.018.
- 47) Our World in Data, "CO₂ emissions per capita," 2023. [Online]. Dostupné z: <https://ourworldindata.org/grapher/co-emissions-per-capita>
- 48) Petr Kuběsa and Jiří Horák, "Proces hoření kusového dřeva," *TZB-info*. Cit.: Jan. 22, 2023. [Online]. Dostupné z: <https://energetika.tzb-info.cz/8716-proces-horeni-kusoveho-dreva>
- 49) Plantower Technology, "PMS5003 Laser PM_{2.5} Particulate Matter Sensor Datasheet," 2016. [Online]. Dostupné z: https://cdn-shop.adafruit.com/product-files/3686/PMS5003+Series+Data+Manua_English_V2.3.pdf
- 50) R. Mougalias, "Big Data," 2005. [Online]. Dostupné z: https://www.oreilly.com/pub/a/oreilly/ask_tim/2005/big-data.html
- 51) RLX Components, "Industrial USB to 4CH RS485 Converter – Multi Protection Circuits, Multi Systems Support, Aluminium Case," 2025. [Online]. Dostupné z: <https://rlx.sk/sk/usb-spi-i2c-rs232-485-can-lin/9307-industrial-usb-to-4ch-rs485-converter-multi-protection-circuits-multi-systems-support-aluminium-case-ws-25219.html>
- 52) S. Afzal, M. Jamil, A. Waris, S. I. Butt, and G. Mufti, "Fuzzy Logic Controller for Boiler Temperature Control using LabVIEW and Matlab," *International Journal of Control and Automation*, vol. 9, no. 9, pp. 89–104, Sep. 2016, doi: 10.14257/ijca.2016.9.9.10.
- 53) S. F. Mujiyanti, T. Soehartanto, D. A. Christanto, and I. P. E. W. Pratama, "The control design optimization of boiler mini plant in the workshop laboratory scale based on ratio control," 2023, p. 040013. doi: 10.1063/5.0122323.



- 54) S. F. Mujiyanti, T. Soehartanto, D. A. Christanto, and I. P. E. W. Pratama, "The control design optimization of boiler mini plant in the workshop laboratory scale based on ratio control," 2023, p. 040013. doi: 10.1063/5.0122323.
- 55) SAP, "Čo je internet vecí (IoT)?" Cit.: Jun. 14, 2025. [Online]. Dostupné z: <https://www.sap.com/sk/products/technology-platform/what-is-iot.html>
- 56) SAZP, "Vykurovanie v domácnostiach trochu inak," Enviroportal. Cit.: Jun. 15, 2025. [Online]. Dostupné z: <https://vykurovanie.enviroportal.sk/kotol>
- 57) Sensirion AG, "SCD41 Miniaturized CO₂ Sensor Datasheet," 2021. [Online]. Dostupné z: https://www.sensirion.com/file/datasheet_scd41
- 58) Slovenská agentúra životného prostredia (SAŽP), "Environmentálna regionalizácia Slovenskej republiky," 2016. [Online]. Dostupné z: <https://www.sazp.sk/zivotne-prostredie/starostlivost-o-zivotne-prostredie/environmentalna-regionalizacia-sr>
- 59) Slovenská agentúra životného prostredia, "Správa o stave životného prostredia SR za rok 2019," 2020. [Online]. Dostupné z: <https://www.enviroportal.sk/uploads/report/11782.pdf>
- 60) Slovenský hydrometeorologický ústav (SHMÚ), "Výročná správa o kvalite ovzdušia v Slovenskej republike za rok 2023," 2023. [Online]. Dostupné z: https://www.shmu.sk/File/o_shmu/vs/VS2023_FINAL.pdf
- 61) Stanislav Vrána, Viktor Pláček, Cyril Oswald, Cyril Oswald, and Petr Neuman, "Neural Network Evaluation of Combustion Process for Continuous Control of Small Scale Biomass Fired Boilers," The International Federation of Automatic Control, 2014.
- 62) Svetex BM, "Inteligentná domácnosť SOMFY - ." Cit.: Jun. 14, 2025. [Online]. Dostupné z: <https://svetexbm.sk/produkty/inteligentna-domacnost-somfy/>
- 63) Štatistický úrad Slovenskej republiky, "Hrubý domáci produkt Slovenskej republiky v roku 2022," 2022. [Online]. Dostupné z: <https://slovak.statistics.sk/wps/portal/ext/home>
- 64) Štatistický úrad SR, "Spotreba palív a technické vybavenie domácností – 2021," 2021. [Online]. Dostupné z: https://ssad.statistics.sk/SSaD/?dl_id=294
- 65) T. Mori, Y. Iwama, H. Hayama, and E. Mushtaha, "Optimization of a Wood Pellet Boiler System Combined with CO₂HPs in a Cold Climate Area in Japan," *Energies* (Basel), vol. 13, no. 21, p. 5531, Oct. 2020, doi: 10.3390/en13215531.
- 66) T. Rashid, *Make Your Own Neural Network*. CreateSpace Independent Publishing Platform, 2016.
- 67) T. Wang, J. Tang, H. Xia, C. Yang, W. Yu, and J. Qiao, "Data-driven multi-objective intelligent optimal control of municipal solid waste incineration process," *Eng Appl Artif Intell*, vol. 137, p. 109157, Nov. 2024, doi: 10.1016/J.ENGAPPAI.2024.109157.
- 68) T. Ye, M. Dong, J. Long, Y. Zheng, Y. Liang, and J. Lu, "Multi-objective modeling of boiler combustion based on feature fusion and Bayesian optimization," *Comput Chem Eng*, vol. 165, p. 107913, Sep. 2022, doi: 10.1016/J.COMPCHENG.2022.107913.
- 69) Techfun.sk, "DFRobot Gravity senzor kyslíka (0–25%)," 2025. [Online]. Dostupné z: <https://techfun.sk/produkt/dfrobot-gravity-senzor-kyslika-0-25/>
- 70) Techfun.sk, "Prevodník USB na RS485 (FT232RL klon)," 2025. [Online]. Dostupné z: https://techfun.sk/produkt/prevodik-usb-na-rs485/?attribute_pa_prevodnik-na-doske=ft232rl-klon¤cy=EUR



- 71) Techfun.sk, "Senzory plynov MQ-X – typ MQ-7," 2025. [Online]. Dostupné z: https://techfun.sk/produkt/senzory-plynov-mq-x/?attribute_pa_typ-mq=mq-7
- 72) Tomáš Paleček, "Controlling a heating system using deep reinforcement learning," Dissertation, Czech Technical University in Prague, Prague, 2018.
- 73) ÚNMS SR, "STN EN 806: Kotly na pevné palivá – Výpočet tepelných strát a účinnosti," 2010.
- 74) V. Prabhu and D. Chaudhary, "Machine Learning enabled Condition Monitoring Models for Predictive Maintenance of Boilers," in 2021 4th International Conference on Recent Developments in Control, Automation & Power Engineering (RDCAPE), IEEE, Oct. 2021, pp. 426–430. doi: 10.1109/RDCAPE52977.2021.9633534.
- 75) V. Prabhu and D. Chaudhary, "Machine Learning enabled Condition Monitoring Models for Predictive Maintenance of Boilers," in 2021 4th International Conference on Recent Developments in Control, Automation & Power Engineering (RDCAPE), IEEE, Oct. 2021, pp. 426–430. doi: 10.1109/RDCAPE52977.2021.9633534.
- 76) W. Wang et al., "Dynamic adaptive control of boiler combustion based on improved GNG algorithm," Measurement: Sensors, vol. 31, p. 101004, Feb. 2024, doi: 10.1016/J.MEASEN.2023.101004.
- 77) W. Xu et al., "A new online optimization method for boiler combustion system based on the data-driven technique and the case-based reasoning principle," Energy, vol. 263, p. 125508, Jan. 2023, doi: 10.1016/J.ENERGY.2022.125508.
- 78) WIKA USA, "Pt100 Resistance Thermometers up to 600 °C," Jan. 2025. [Online]. Dostupné z: https://www.wika.com/en-us/lp_pt100_pt1000.WIKA
- 79) X. Wu, H. Zhang, H. Chen, S. Wang, and L. Gong, "Combustion optimization study of pulverized coal boiler based on proximal policy optimization algorithm," Appl Therm Eng, vol. 254, p. 123857, Oct. 2024, doi: 10.1016/J.APPLTHERMALENG.2024.123857.
- 80) Y. Ma, H. Wang, X. Zhang, L. Hou, and J. Song, "Three-objective optimization of boiler combustion process based on multi-objective teaching–learning based optimization algorithm and ameliorated extreme learning machine," Machine Learning with Applications, vol. 5, p. 100082, Sep. 2021, doi: 10.1016/J.MLWA.2021.100082.
- 81) Y. Xu et al., "Unit load prediction method based on weighted just-in-time learning with spatio-temporal characteristics for gas boiler power generation process," Control Eng Pract, vol. 160, p. 106325, Jul. 2025, doi: 10.1016/J.CONENGPRAC.2025.106325.
- 82) Yokogawa Electric Corporation, "ADMAG AXG Flowmeter: General Specification (GS 01E20D01-01EN)," 2021. [Online]. Dostupné z: <https://web-material3.yokogawa.com/GS01E20D01-01EN.pdf>
- 83) Z. Wang et al., "BoilerNet: Deep reinforcement learning-based combustion optimization network for pulverized coal boiler," Energy, vol. 318, p. 134804, Mar. 2025, doi: 10.1016/J.ENERGY.2025.134804.
- 84) Z.-H. Zheng et al., "Progress in the Application of Machine Learning in Combustion Studies," ES Energy & Environment, 2020, doi: 10.30919/eseec8c795./matecconf/202134500002.