



SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Ing. Marek Trebuľa
Autoreferát dizertačnej práce

Zvýšenie efektivity a kvality procesu robotického zvárania pomocou nástrojov AI

na získanie akademického titulu
„doktor“ („philosophiae doctor“, v skratke „PhD.“)

v doktorandskom študijnom programe:	robotika a kybernetika
v študijnom odbore:	9.2.7. kybernetika
Forma štúdia:	denná
Miesto a dátum:	Bratislava, 2025



Dizertačná práca bola vypracovaná na
Ústave robotiky a kybernetiky FEI STU v Bratislave.

Predkladateľ: Ing. Marek Trebuľa
Slovenská technická univerzita v Bratislave
Fakulta elektrotechniky a informatiky
Ústav robotiky a kybernetiky FEI STU
Ilkovičova 2961/3, 841 04 Bratislava

Školiteľ: prof. Ing. František Duchoň, PhD.
Slovenská technická univerzita v Bratislave
Fakulta elektrotechniky a informatiky
Ústav robotiky a kybernetiky FEI STU
Ilkovičova 2961/3, 841 04 Bratislava

Oponenti doc. Ing. Martin Gulan, PhD.
Slovenská technická univerzita v Bratislave
Strojnícka fakulta
Ústav automatizácie, informatizácie a merania
Námestie slobody 17, 812 31 Bratislava

prof. Ing. Rastislav Pirník, PhD.
Žilinská univerzita v Žiline
Fakulta elektrotechniky a informačných technológií
Katedra riadiacich a informačných systémov
Univerzitná 8215/1, 010 26 Žilina

Autoreferát bol rozoslaný dňa:

Obhajoba dizertačnej práce sa bude konať dňa: **31.10.2025** o **10:30** na Fakulte elektrotechniky
a informatiky STU, Ilkovičova 2961/3 841 04 Bratislava

.....
prof. Ing. Vladimír Kutíš, PhD.
dekan FEI STU

Abstrakt

Dizertačná práca sa zameriava na vývoj inteligentného systému adaptívnej kontroly kvality pre proces TIG robotického zvarovania v podmienkach malosériovej výroby. Hlavným cieľom je identifikácia kritických fáz a parametrov zvarovania s najväčším potenciálom na optimalizáciu a návrh AI nástrojov pre ich automatizovanú detekciu a analýzu. V rámci prvej tézy je navrhnutý systém fúzie dát z viacerých senzorov inteligentného zvaracieho pracoviska, ako sú robotické manipulátory, laserové 2D skenery, silovo-momentové snímače a zvaracie zdroje. Dôraz sa kladie na presnú časovú synchronizáciu týchto údajov a ich vizualizáciu prostredníctvom grafického používateľského rozhrania. Kľúčovým prínosom je návrh AI algoritmu na korekciu časového posunu medzi polohou robota a profilovými dátami z laserového skenera, čím sa umožní kvalitná rekonštrukcia mračien bodov pre analýzu zvarov. Druhá téza sa zaoberá návrhom architektúry umelej inteligencie pre systém kontroly kvality zvarov. Vytvorené neurónové siete analyzujú dáta z laserového skenera a poskytujú odporúčania na korekcie parametrov zvarovania (prúd, rýchlosť, napätie a pod.). Samostatný AI modul je venovaný diagnostike stavu volfrámovej elektródy, pričom systém automaticky signalizuje potrebu jej údržby, čím sa minimalizujú prestoje a zabezpečuje kvalita procesu. Tretia téza sa sústreďuje na overenie a zovšeobecnenie vyvinutého systému adaptívnej kontroly kvality. Merania z testovania v reálnych priemyselných podmienkach vo firme VÚEZ a.s. boli využité na vytvorenie metodického rámca a odporúčaní pre rôzne typy zvaracích úloh. Navrhované riešenia prispievajú k zvýšeniu presnosti, efektivity a stability robotického zvarovania, znižujú závislosť od vysoko kvalifikovanej pracovnej sily a predstavujú krok smerom k inteligentnej a adaptívnej výrobe.

Kľúčové slová

inšpekcia zvarov, parametre zvarovania, robotické zvarovanie, umelá inteligencia, 2D laser

Obsah

Abstrakt	i
Úvod	1
1 Ciele práce	2
2 Fúzia dostupných dát	3
2.1 Navrhnuté riešenie	3
3 Fúzia 2D laserového skenera a polohy robotického manipulátora	7
3.1 Navrhnuté riešenie	8
3.2 Testovanie a zhrnutie	11
4 Korekcia parametrov zvarovania pomocou neurónových sietí	14
4.1 Navrhnuté riešenie	14
4.2 Testovanie a zhrnutie	17
5 Určenie stavu hrotu volfrámovej zvaracej elektródy pomocou NS	19
5.1 Navrhnuté riešenie	19
5.2 Testovanie a zhrnutie	23
6 Zovšeobecnenie navrhnutého systému	25
6.1 Fúzia polôh robotického manipulátora a laserových 2D skenov	25
6.2 Korekcia parametrov robotického zvarovania	26
6.3 Automatické určenie stavu hrotu volfrámovej elektródy	28
Záver	30
Literatúra	31
Autorove publikácie	37

Úvod

Autoreferát sumarizuje výsledky dizertačnej práce zameranej na návrh, vývoj a experimentálne overenie inteligentného systému adaptívnej kontroly kvality pre proces TIG robotického zvarania v podmienkach malosériovej výroby. Motiváciou je rastúci tlak na stabilnú kvalitu, skracovanie nastavovacích časov a znižovanie závislosti od vysoko kvalifikovanej obsluhy v prostredí, kde tradičné postupy riadenia kvality a parametrizácie často nedokážu pružne reagovať na procesné odchýlky.

Práca sa opiera o integráciu viacerých zdrojov dát (polohové informácie robotického manipulátora, profilové merania 2D laserového skenera, technologické signály zvarania a obrazové záznamy) a o využitie metód umelej inteligencie v troch kľúčových moduloch:

1. AI synchronizácia senzorických tokov – neurónová sieť na odhad a korekciu časového posunu medzi polohou robota a profilmi 2D skenera na účely presnej rekonštrukcie mračien bodov.
2. Odporúčanie úprav procesných parametrov zvarania.
3. Diagnostika stavu volfrámovej elektródy z jediného skenovacieho cyklu.

Riešenia boli navrhnuté s dôrazom na modularitu, prenositeľnosť a jednoduchú integráciu do existujúceho pracoviska.

Autoreferát stručne predstavuje ciele a vedecké tézy práce, opisuje použitú metodiku vrátane dátového toku a architektúr modelov a následne sumarizuje hlavné experimentálne výsledky dosiahnuté na reálnych dátach z priemyselného prostredia. Dôraz je kladený na preukázanie prínosu navrhovaných metód pre kvalitu a efektivitu procesu, na ich prenositeľnosť medzi rôznymi zvaracími úlohami a na metodické odporúčania pre praktické nasadenie v inteligentných zvaracích pracoviskách. Celkovo autoreferát dokumentuje ucelený prístup, ktorý spája presnú fúziu s AI nástrojmi a poskytuje konkrétne a overené kroky smerom k adaptívnej a spoľahlivej výrobe v oblasti robotického TIG zvarania.

1 Ciele práce

Hlavným cieľom dizertačnej práce je navrhnuť, implementovať a overiť inteligentný systém adaptívnej kontroly kvality pre proces TIG robotického zvarovania v podmienkach malosériovej výroby. Systém má identifikovať kritické parametre procesu, zabezpečiť ich spoľahlivé snímanie a fúziu, umožniť automatizovanú analýzu odchýlok a poskytovať odporúčania na korekcie nastavení zvarovania. Dôraz sa kladie na prenositeľnosť riešenia, modularitu, reprodukovateľnosť spracovania dát. Témy dizertačnej práce sú definované nasledovne:

1. Návrh fúzie dát z dostupných snímačov inteligentného robotického zvaracieho pracoviska pre malosériovú výrobu
2. Navrhnuť architektúru nástrojov umelej inteligencie pre systém kontroly kvality zvarovaných výrobkov s funkciou návrhu korekcie parametrov zvarovania a návrhu operátorských zásahov
3. Vytvoriť, verifikovať a zovšeobecniť navrhnutý systém adaptívnej kontroly kvality zvarovaných výrobkov

Pre prvú tézu sme podúlohy formulovali nasledovne. Najprv bola vykonaná inventarizácia a analýza zdrojov dát s dôrazom na údaje z robotických manipulátorov, 2D laserových skenerov, silovo-momentových snímačov a zvaracích zdrojov, pričom sme identifikovali kľúčové parametre ovplyvňujúce kvalitu a efektivitu zvarovania. Následne bol navrhnutý kontinuálny zber dát počas aj po zvaraní s ich systematickým ukladaním a prípravou na následnú analýzu. Pre odhad a korekciu časového offsetu medzi polohou robota a profilovými dátami 2D skenera bola vypracovaná synchronizačná procedúra na báze neurónovej siete. Časovo zosúladené dáta sme integrovali do presných mračien bodov a odvodených digitálnych reprezentácií vhodných na hodnotenie kvality zvarov. Súčasťou riešenia je grafické používateľské rozhranie, ktoré umožňuje časovo-priestorovú synchronizáciu, paralelnú vizualizáciu 3D mračien, technologických signálov a obrazu, podporuje anotáciu a generovanie datasetov pre tréning neurónových sietí vrátane exportu do formátu HDF5.

Pre druhú tézu sme definovali dve oblasti. Vyvinuli sme modely strojového učenia pracujúce s laserovými skenmi, ktoré generujú konkrétne odporúčania na úpravu prúdu, rýchlosti zvarovania a rýchlosti prísunu prídavného materiálu so zameraním na minimalizáciu defektov. Napokon sme vytvorili modul AI monitoringu volfrámovej elektródy na detekciu kontaminácie a hodnotenie opotrebenia, ktorý podporuje včasnú údržbu a znižuje prestoje.

Pre tretiu tézu sme najprv zostavili funkčné systémy a experimentálne ich overili na dátach z reálneho pracoviska so zameraním na kvantifikáciu úspešnosti a presnosti. Následne sme metódy zovšeobecniť do modulárnych postupov a rozhraní prenositeľných medzi rôznymi robotmi, snímačmi a typmi zvarov pri minimálnych úpravách konfigurácie.

2 Fúzia dostupných dát


V rámci prvej tézy sme vyvinuli nástroj na fúziu zozbieraných dát o zvaroch z pracoviska IZVAR s dátami robotickej inšpekcie kvality.

Na pracovisku IZVAR boli polohy robotických manipulátorov, laserové skeny a procesné veličiny časovo značkované a ku každej polohe boli priradené najbližšie hodnoty prúdu a napätia. Po ukončení zvárania bolo vykonané reverzné skenovanie od konca k začiatku a skenované body boli mapované na čas zvárania. Pri vzorkovaní prúdu a napätia 200 Hz a rýchlosti 2 mm/s vzniklo približne 100 meraní na milimeter, pričom laserové skeny dosahovali približne 6 snímok na milimeter. Systém robotickej inšpekcie zbieral polohové údaje z laserového skenera a RGB kamery v samostatných cykloch. Synchronizácia bola realizovaná cez spoločné polohové informácie, smer záznamu bol zhodný so smerom zvárania a začiatok bol fixovaný v tom istom bode. Hustota bola približne 6 snímok na milimeter (kamera) a 11–12 skenov na milimeter (skener). Keďže ide o nezávislé systémy s odlišnými zdrojmi dát a pri kruhových zvaroch často chýba jednoznačný začiatok, bol navrhnutý postup zarovnania na základe identifikácie referenčných bodov a odhadu časovo-priestorového posunu, čím bola dosiahnutá konzistentná vizualizácia parametrov priradených k laserovým skenom pozdĺž zvaru.

2.1 Navrhnuté riešenie

Bolo navrhnuté grafické používateľské rozhranie, ktoré integruje načítanie použitých dátových formátov, interaktívnu vizualizáciu časových priebehov a priestorových skenov, synchronizáciu záznamov medzi pracoviskom IZVAR a systémom robotickej inšpekcie a anotáciu dát pre potreby neurónových sietí. Aplikácia umožňuje import priebehov zváracieho prúdu a napätia a laserových skenov, ich paralelné zobrazenie v grafoch a 3D modeli, zarovnanie časových osí a označovanie relevantných segmentov priamo v GUI. Rozhranie je implementované ako WinForms aplikácia v C++, čo zabezpečuje vysoký výkon pri spracovaní veľkého objemu dát a jednoduchú rozšíriteľnosť na ďalšie typy zvarov a zdroje dát (Obr. 1).

Pri načítaní dát sa predpokladá adresárová konvencia, v ktorej je každý priečinok pomenovaný podľa čísla zvaru a obsahuje trajektórie robotických manipulátorov oboch systémov, laserové skeny z pracoviska IZVAR, dáta zo systému robotickej inšpekcie kvality zvarov, videozáznam a časové priebehy zváracieho prúdu a napätia. Po spustení aplikácie sa nastaví cesta ku kmeňovému adresáru so zvarmi. V ľavom paneli sa zobrazí zoznam dostupných priečinkov. Výber konkrétneho čísla zvaru automaticky načíta všetky príslušné súbory a sprístupní ich analyzačným modulom. Predpokladá sa, že názvy a formáty súborov, generované počas zberu, neboli manuálne zmenené. Odchýlky od konvencie môžu viesť k zlyhaniu alebo nesprávnemu importu, preto je potrebné zachovať pôvodné mená a prípony.



Obr. 1 Grafické rozhranie na fúziu dát.

Po úspešnom načítaní sa v hlavnej časti okna zobrazí 3D mračno bodov z robotickej inšpekcie. Pod ním sú grafy časových priebehov prúdu a napätia. V pravom dolnom rohu je snímka z videozáznamu, ktorá dopĺňa priestorovú a parametrickú vizualizáciu o reálny obraz. Rozhranie umožňuje prepínanie medzi viacerými režimami zobrazenia podľa potreby.

Rozhranie poskytuje viacero režimov zobrazenia. Projekcia zvaru do roviny vizualizuje prevýšenie a kontúru spoja pre orientáciu v geometrii a využíva mračno bodov zo systému robotickej inšpekcie. Projekcia do roviny IZVAR zobrazuje tie isté veličiny na základe dát z pracoviska IZVAR. Vybrané 2D laserové skeny z oboch systémov je možné zvoliť a porovnať v nad sebou usporiadaných grafoch. Snímky z videozáznamu je možné prehliadať krokovo alebo synchronizovať s grafmi procesných parametrov. Priebehy zväracieho prúdu a napätia sú zobrazené v interaktívnych grafoch a poskytujú detailný pohľad na dynamiku procesu.

V ľavom dolnom rohu je umiestnený posuvník, ktorým sa používateľ pohybuje pozdĺž dĺžky zvaru. Po každom posune sa vo všetkých zobrazeniach farebne zvýrazní príslušný laserový sken zo systému robotickej inšpekcie. V grafoch prúdu a napätia sa súčasne zobrazia hodnoty parametrov pre daný bod a v okne s videozáznamom sa automaticky načíta zodpovedajúca snímka. Posuvník tak vytvára okamžité prepojenie priestorových, parametrických a obrazových dát a zrýchľuje identifikáciu kritických úsekov zvaru.

Bol navrhnutý a otestovaný algoritmus na automatické určenie časového posunu medzi dátami z pracoviska IZVAR a systémom robotickej inšpekcie. Východiskom je zarovnanie mračien bodov reprezentujúcich ten istý zvar z rôznych skenerov. Najprv sa homogenizuje hustota bodov vytvorením voxelovej mriežky s krokom $100 \times 100 \times 100 \mu\text{m}$ tak, aby každý voxel

obsahoval najviac jeden reprezentatívny bod. Pre voxel $V_{i,j,k}$, s množinu bodov $\{p_1, p_2, \dots, p_n\}$ kde $p_l = (x_l, y_l, z_l)$, sa určí centroid:

$$c_{i,j,k} = \frac{1}{n} \sum_{l=1}^n p_l = \left(\frac{1}{n} \sum_{l=1}^n x_l, \frac{1}{n} \sum_{l=1}^n y_l, \frac{1}{n} \sum_{l=1}^n z_l \right) \quad (2.1)$$

V prvej verzii bol z robotickej inšpekcie zvolený jediný sken s najvýraznejšou kontúrou. V druhej verzii bola definovaná oblasť s dĺžkou 1 cm okolo charakteristického miesta. Referenčný sken alebo oblasť sa zarovnávali na začiatok mračna bodov z IZVAR. Pozdĺž osi zvaru sa v krokoch po 0,1 mm iteratívne hodnotila miera zhody metódou najmenších štvorcov. Zistené posunutie v milimetroch sa prevádzalo na indexy skenov podľa aktuálnej hustoty laserových snímkov. Riešenie bolo spoľahlivé pri zvaroch s jediným dominantným prevýšením alebo depresiou. Pri viacerých podobných útvaroch alebo homogénnych zvaroch nebolo možné posun určiť jednoznačne. Z dôvodu flexibility bola pridaná možnosť manuálnej korekcie posunu číselným vstupom pod posuvníkom. Nejednoznačnosť začiatku a konca zvaru na oceľových rúrkach zvyšuje význam manuálnej korekcie. Nastavený posun sa premieta do činnosti posuvníka a zabezpečuje, že v 3D zobrazení, grafoch prúdu a napätia aj vo video snímkach sú zvýraznené údaje zhodné s tým istým miestom zvaru.

Poslednou funkcionalitou je anotácia skenov v mračnách bodov zo systému robotickej inšpekcie. V režime anotácie možno mračno deliť na ľubovoľné intervaly. Aktuálny interval je vizuálne označený, prvý sken je modrý a posledný červený (Obr. 2). V pravom paneli sa zvolia upravované parametre a smer zmeny. Po stlačení „Process“ sa spracujú všetky skeny v intervale, dáta sa normalizujú a uložia do súboru HDF5. Následným výberom ďalšieho intervalu a opakovaním postupu vzniká iteratívny proces tvorby anotovaných tréningových dát. Anotácia prebiehala v spolupráci so zväracím technologom VÚEZ, a. s.

Pri spracovaní a ukladaní dát do HDF5 boli aplikované normalizačné transformácie tak, aby mali vstupy pre neurónové siete jednotný rozsah a tvar. Súradnice z pracovného rozsahu skenera ScanCONTROL 3000-25/BL boli škálované na interval $[0,1]$. Konkrétne sa použili vzťahy:


$$x_{norm} = \frac{x_{skener} + 13,5}{27,0} \quad (2.2)$$

$$y_{norm} = \frac{y_{skener} - 77,0}{18,0} \quad (2.3)$$

Farebný odtieň bodu v priestore HSV bol normalizovaný do intervalu $[-1,1]$ od modrej po červenú. Želané úpravy procesných parametrov ($\pm$ prúd, $\pm$ rýchlosť robota, $\pm$ prídavný materiál) boli kódované šiestimi binárnymi premennými. Na zabezpečenie konštantného tvaru vstupu bol každý laserový sken rozdelený na tri nezávislé okná s dĺžkou 1024 bodov z ľavej, strednej a pravej časti. Každé okno sa spracovalo uvedenými krokmi a uložilo ako samostatný záznam v HDF5. Výsledná štruktúra jedného záznamu mala tvar:

$$[x_0, x_1, \dots, x_{1023}, y_0, y_1, \dots, y_{1023}, c_0, c_1, \dots, c_{1023}, p_0, p_1, \dots, p_5] \quad (2.4)$$

kde prvých 2048 položiek predstavuje normalizované X a Y súradnice, nasleduje 1024 hodnôt farebného odtieňa a záver tvorí šesť binárnych indikátorov požadovaných úprav zväracích parametrov. Každý anotovaný záznam obsahoval 3078 hodnôt.



Obr. 2: Fúzia dát - GUI - anotácia skenov mračna bodov.


Navrhnuté grafické rozhranie integruje fúziu dát z pracoviska IZVAR a zo systému robotickéj inšpekcie do jednotného prostredia. Synchronizované časové značky umožňujú paralelné zobrazenie 3D mračien bodov, priebehov zväracieho prúdu a napätia aj videozáznamu tak, aby bola každá poloha zvaru doplnená o relevantné parametre. Interaktívne režimy od 3D pohľadu a rovinných projekcií po porovnanie 2D skenov so synchronizovanými snímkami videa podporujú detailnú analýzu geometrie a kvality spoja. Posuvník s farebným zvýraznením aktuálneho skenu zrýchľuje prehliadanie a koreláciu priestorových, obrazových a parametrických dát.

Anotácia skenov prebieha výberom intervalov s vizuálnym označením prvého a posledného skenu. V pravom paneli sa definujú potrebné úpravy procesných parametrov. Po spracovaní sa normalizované laserové dáta ukladajú do súboru HDF5. Súradnice X a Y sú škálované do intervalu 0 až 1 a farebný odtieň do intervalu -1 až 1. Z každého skenu vznikajú tri okná s dĺžkou 1024 bodov z ľavej, strednej a pravej časti, čo zabezpečuje konštantný tvar vstupu pre neurónové siete. Implementácia vo WinForms v C++ poskytuje vysoký výkon pri práci so stovkami mračien bodov a otvorená architektúra umožňuje jednoduché rozšírenie o ďalšie zdroje dát, vizualizačné režimy a analytické moduly.

3 Fúzia 2D laserového skenera a polohy robotického manipulátora


Táto kapitola v rámci prvej tézy rieši časovú synchronizáciu dát o polohe robotického manipulátora a snímok z 2D laserového skenera upevneného na jeho ramene. V praxi bol identifikovaný významný priestor na zlepšenie presnosti záznamu. Synchronizácia je nevyhnutná pre určenie absolútnej polohy zvaru alebo defektu v súradnicovom priestore robota a pre kvalitu vstupov do neurónových sietí určených na inšpekciu a optimalizáciu parametrov zvarovania.

V súčasnom systéme je 2D skener prevádzkovaný v kontajnerovom režime. Pred meraním sa konfiguruje počet snímok a frekvencia záznamu. Spustenie je možné len softvérovým triggerom. Súbežné hardvérové spustenie pohybu manipulátora a snímania nie je možné a presná časová synchronizácia je preto komplikovaná. Riadiaci počítač odosiela príkazy cez TCP/IP súčasne skeneru aj robotu, pričom variabilné sieťové a spracovacie oneskorenia spôsobujú, že časový rozdiel Δt medzi začiatkom skenovania a začiatkom pohybu je pri každom spustení iný (Obr. 3). Každé zariadenie zároveň používa vlastnú lokálnu časovú značku, takže čas $t=0$ nie je globálne zhodný. V ideálnom stave $\Delta t=0$ by bolo možné jednoznačne priradovať skenom postupne zaznamenané polohy robota.



Obr. 3: Časový rozdiel medzi začiatkom skenovania a pohybu robota.

Nesprávne priradovanie polohy ku skenom sa pri lineárnom pohybe po jednej osi prejaví ako posunutie mračna bodov v globálnom súradnicovom systéme. Pri zložitejších trajektóriách vo viacerých osiach vzniká deformácia mračna, ktorá výrazne znižuje jeho použiteľnosť. Overovacie meranie vertikálnym pohybom +Z/-Z nad známou rovinou stola ukázalo odchýlky bodov približne do 1 mm od roviny, na ktorej sa nachádzal skenovaný povrch (Obr. 4).



Obr. 4: Vplyv nepresnej synchronizácie polohy robota s laserovými skenmi.


Cieľom navrhovanej metódy je presne určiť časový posun medzi polohovými údajmi manipulátora a príslušnými laserovými skenmi. Počas experimentu je vykonaný vopred definovaný pohyb nad známou plochou a oba dátové toky sú kontinuálne zaznamenané. Pomocou neurónovej siete je odhadnutý korekčný časový posun Δt , ktorý minimalizuje nesúlad medzi oboma zdrojmi dát. Presná korekcia Δt zvyšuje kvalitu výsledných mračien bodov a poskytuje presnejšie digitálne reprezentácie zvarových spojov.

3.1 Navrhnuté riešenie


Na odhad časového posunu bol zvolený pohyb v jednej osi, aby bol zreteľný v dátach robota aj skenera. Synchronizačný pohyb prebieha vertikálne v osi Z smerom nahor a nadol. Obr. 5 ilustruje nástroj robotického inšpekcie pri osvetlení rovného povrchu.

Počas zberu dát bola v každej sekvencii vykonaná päťnásobná zmena výšky v osi Z. Pri šiestom zdvihu sa manipulátor vrátil do stredovej polohy a na niekoľko sekúnd zastavil, kým sa neukončil kontajnerový záznam skenera. Pri spracovaní dát sme sa sústredili na časový priebeh súradnice Z príruby robota a na vzdialenosť medzi skenerom a skenovaným povrchom.

Pri extrakcii súradnice Z bolo potrebné interpolovať polohu robotického manipulátora, keďže vzorkovanie polôh prebiehalo na 125 Hz a skener meral na 150 Hz. Priamo priradovať polohy ku skenom nebolo možné, preto bola použitá lineárna interpolácia medzi dvoma najbližšími vzorkami polohy podľa časovej značky v laserových dátach. Na Obr. 6 je viditeľný časový rozdiel medzi zdrojmi dát, keď meranie polôh začalo neskôr ako meranie skenerom. Cieľom bolo, aby neurónová sieť vedela z takto zarovnaných priebehov odhadnúť vzájomné posunutie Δt . Časový sklz medzi signálmi bol pre všetky merania určený manuálne v pomocnom programe, ktorý k laserovým dátam pridával časové posuny. Správna hodnota sa identifikovala vtedy, keď bolo výsledné mračno bodov najužšie, t. j. keď súčet vzdialeností bodov od referenčnej priamky v strede mračna dosiahol minimum. Takto určené Δt boli použité pri augmentácii a tvorbe tréningového a testovacieho datasetu. Pri 15 meraniach bola priemerná hodnota $-34,35$ ms, najväčší sklz $-47,44$ ms a najmenší $-27,53$ ms. Zistené hodnoty nekorelovali so zrýchleniami manipulátora ani s nastavenou presnosťou ukončenia pohybu a pri každom meraní sa líšili.



Obr. 5: Ukážka synchronizačného pohybu.




Obr. 6: Časový priebeh meranej vzdialenosti laserom a polohy robota v Z súradnici.

Pri augmentácii datasetu sme aplikovali tri techniky: umelé časové posuny medzi signálmi, pridanie šumu a výber dát posuvným oknom. Ku každému meraniu sme pridali náhodné posunutie v intervale -30 ms až $+70$ ms, čo po sčítaní s pôvodným sklzom vytvára rozsah -60 ms až $+50$ ms a pokrýva aj situácie, keď polohové dáta predbiehajú skeny. Pre každú sekvenciu bolo vygenerovaných 200 nezávislých posunutí. Šum s amplitúdou do 2 % maximálneho zdvihu sme aplikovali osobitne len na polohové dáta, len na laserové dáta, na oba signály aj na žiadny z nich, čím vznikli štyri varianty vstupov. Z každej vygenerovanej dvojice signálov sme náhodne vybrali päť okien s dĺžkou 256 vzoriek. Pri frekvencii 150 Hz ide o približne 1,7 s a aspoň jednu plnú periódu pohybu, čo zvyšuje odolnosť voči nepravidelnostiam a čiastočne poškodeným sekvenciám.

Vstupné signály boli normalizované z intervalu $(-10, 10)$ do $(0, 1)$ a výstupné časové sklzy z intervalu $(-60, 50)$ do $(0, 1)$. Dáta sme ukladali do HDF5 v riadkoch dĺžky 513 prvkov podľa (2.5). Prvých 256 hodnôt predstavuje normalizované vzdialenosti medzi skenerom a podložkou. Nasledujúcich 256 hodnôt tvorí normalizovaná polohová sekvencia robota. Posledná hodnota je normalizovaný časový posun medzi oboma dátovými tokmi. Takto pripravený dataset obsahoval 60 300 trénovacích vzoriek.


$$[l_0, l_1, \dots, l_{255}, r_0, r_1, \dots, r_{255}, \Delta t] \quad (2.5)$$

Výstupom použitej NS je jeden kontinuálny odhad normalizovaného časového posunu v intervale 0 až 1 so sigmoidnou aktiváciou vo výstupnej vrstve. Sieť s najlepšimi výsledkami je tvorená tromi konvolučnými vrstvami s postupne rastúcim počtom filtrov 32, 64 a 128. Každú z nich nasleduje MaxPooling. Extrahované príznaky sa následne sploštia a spracujú v plne prepojenej vrstve so 64 neurónmi. Záver tvorí výstupná sigmoidná jednotka. Schéma architektúry je na (Obr. 7).



Obr. 7: Architektúra 1D CNN.

Tréning prebiehal na znormalizovanom datasete s 60 300 vzorkami. Dáta boli rozdelené v pomere 60 % na tréning, 20 % na validáciu a 20 % na test. Použitý bol optimalizér Adam a stratová funkcia mean squared error. Trénovali sme 20 epoch s veľkosťou dávky 16. Priebehy stratovej funkcie logované po dávkach potvrdili najnižšiu hodnotu straty a najstabilnejšiu konvergenciu práve pri 1D CNN. LSTM vykazovala stagnáciu bez zlepšenia, ostatné MLP varianty dosiahli horšie výsledky. Z uvedených dôvodov bola na ďalšie vyhodnocovanie a nasadenie zvolená 1D konvolučná sieť. Tréningový priebeh je zobrazený na (Obr. 8).



Obr. 8: Trénovací proces NS.


3.2 Testovanie a zhrnutie

Testovanie prebehlo na samostatnej množine 12 060 vzoriek vyčlenenej pred tréningom. Zo štyroch skúšaných architektúr (1D CNN, LSTM, MLP, MLP2) sa ďalej sústreďíme na 1D konvolučnú sieť, ktorá dosiahla najnižšiu chybu. Ostatné modely dosiahli výrazne vyššie MSE a nepreukázali porovnateľnú presnosť (viď Tabuľka 1).

Tabuľka 1: Výsledky stratových funkcií NS na testovacích dátach

Typ NS	Hodnota stratovej funkcie
1D CNN	0,000377
LSTM	0,047481
MLP	0,004093
MLP 2	0,028611

Konvolučná 1D sieť vykázala na testovacích dátach MSE=0,000377 a jej predikcie sa tesne zhlukovali okolo diagonály $y=x$ v rozsahu -60 ms až $+50$ ms. Bias bol zanedbateľný a väčšina odchýlok neprekročila jednotky milisekúnd. Ojedinelé väčšie odklony pripisujeme extrémnemu šumu alebo atypickým segmentom trajektórií. Výsledok je zobrazený na Obr. 9.



Obr. 9: Porovnanie reálnych a predikovaných časových posunov medzi tokmi dát - CNN.


Pre porovnanie sme použili krížovú koreláciu definovanú:

$$r_{xy}[k] = \sum_{n=0}^{N-1} x[n] \cdot y[n+k] \quad (2.6)$$

pričom posun zodpovedá $\text{argmax } r_{xy}[k]$. Pri pôvodnej perióde vzorkovania vznikali diskkrétne skoky v odhadoch. Preto sme dáta prevzorkovali lineárnou interpoláciou:


$$y(t) = y_1 + \frac{t - t_1}{t_2 - t_1} \cdot (y_2 - y_1) \quad (2.7)$$

čo zvýšilo rozlíšenie, no rozptýl predikcií okolo diagonály zostal výrazný. Krížová korelácia teda zachytila len hrubý trend a nedosiahla presnosť ani robustnosť 1D CNN (Obr. 10 – vľavo bez interpolácie a vpravo s interpoláciou).



Obr. 10: Výsledky hľadania posunov s krížovou koreláciou.

Skener pracuje v kontajnerovom režime so softvérovým triggerom, čo znemožňuje simultánne hardvérové spustenie pohybu a merania a pri zložitejších trajektoriách spôsobuje deformácie mračien. Krížová korelácia identifikovala len približný časový posun a aj po prevzorkovaní a lineárnej interpolácii zostávali odchýlky. Preto boli implementované štyri neurónové architektúry: jednoduchý MLP, komplexný MLP s normalizáciou dávok a dropoutom, LSTM a 1D CNN. Testovanie na 12 060 vzorkách potvrdilo, že 1D CNN dosahuje najnižšiu chybu a najvyššiu presnosť, kým oba MLP modely vykazovali vyšší rozptyl chýb a sklon k zhľukovaniu predikcií okolo stredných hodnôt a LSTM v zvolenom nastavení zlyhávala v detekcii odchýlok. Praktický prínos korekcie sa prejavil vo finálnom mračne bodov (Obr. 11): vzdialenosť bodov v osi Z sa po aplikácii časového posunu zmenšila z 1,96 mm na 0,12 mm, čo predstavuje zlepšenie o 93,88 % v porovnaní s nesynchronizovaným stavom (Obr. 4). Tento výsledok potvrdzuje, že korekcia časového posunu je kľúčová pre kvalitatívne validné mračná bodov a radí 1D CNN medzi najefektívnejšie riešenia danej úlohy.




Obr. 11: Vplyv spresnenia časovej synchronizácie dát robota a laserového 2D skenera.

4 Korekcia parametrov zvarania pomocou neurónových sietí

V druhej téze navrhujeme systém korekcie parametrov robotického TIG zvarania založený na neurónových sieťach. Vstupom sú 2D laserové skeny profilov zvaraných dielcov, z ktorých predikujeme úpravy prúdu, rýchlosti pohybu zvaracej hlavy a prívodu prídavného materiálu. Proces je závislý od manuálneho doladovania, citlivý na zmeny geometrie a materiálu a trpí nedostatkom kvalifikovaných operátorov, pričom chýba spätná väzba po dokončení zvaru. Súčasné regulácie zasahujú len počas zvarania a neprepájajú meranú geometriu so systémovými odporúčaniami, čím zostáva potenciál 2D skenov nevyužitý. Cieľom je navrhnúť a implementovať neurónovú sieť, ktorá zo skenov povrchu zvaru identifikuje odchýlky od požadovanej kvality a vygeneruje odporúčania parametrov pre nasledujúci zvar (prúd, rýchlosť posuvu, prívod prídavného materiálu). Tým sa skráti čas expertného doladovania, zníži riziko opakovaných chýb a zvýši spoľahlivosť aj produktivita procesu.

4.1 Navrhnuté riešenie

Z 2D laserových skenov vytvárame mračno bodov, ktoré predspracujeme a následne použijeme na určenie operátorského zásahu. Postup zahŕňa zber dát, ich spracovanie, návrh architektúry, tréning a testovanie modelu. Využívame na to dáta z robotického inšpekčného systému kvality zvarov s 2D laserovým skenerom scanCONTROL 3000-25/BL (Micro-Epsilon). Robot sleduje trajektóriu pozdĺž spoja, pričom skener sníma profil povrchu s rozlíšením do 12 μm . Získaná sekvencia 2D profilov je zlúčená do mračna bodov Obr. 12.




Obr. 12: Príklad mračna bodov z robotického inšpekčného systému.

Pre tvorbu tréningového datasetu bol použitý interaktívny GUI nástroj (kapitola 2.1), ktorý umožňuje anotovať 2D laserové skeny v podobe mračien bodov. Na zabezpečenie konštantného tvaru vstupu sa z každého skenu vyberú tri okná po 1024 bodoch (ľavé, stredné, pravé). Každé okno sa uloží ako samostatný záznam s 3078 hodnotami (2×1024 súradníc, 1024 farebných

odtieňov a 6 binárnych parametrov). Výstupný vektor má šesť binárnych hodnôt v poradí prúd mínus/plus, rýchlosť robota mínus/plus, prísun materiálu mínus/plus:

$$[zp-, zp+, rr-, rr+, rm-, rm+] \quad (2.8)$$

a kóduje úpravy zväracieho prúdu (zp), rýchlosti robota (rr) a rýchlosti prídavného materiálu (rm). Ak úprava nie je potrebná, vektor obsahuje samé nuly. Pri potrebe zvýšiť prúd má napríklad tvar $[0,1,0,0,0,0]$. Zvarové nedostatky sa líšia veľkosťou, hĺbkou a tvarom, preto si spoľahlivé natrénovanie siete vyžaduje rozsiahly súbor skenov. Vytvorený dataset obsahoval 1 552 017 vzoriek. Jeho štruktúru ilustruje Obr. 13. Najpočetnejšiu triedu tvoria skeny spĺňajúce požadované parametre („OK“) s viac než 500 000 príkladmi. V podobnom rozsahu sa vyskytujú prípady so zvýšením prúdu (ZP+), zvýšením rýchlosti prídavného materiálu (RM+) a znížením rýchlosti robota (RR-). Menej početné triedy tvoria približne 50 000 vzoriek každá (napr. ZP-, RR+, RM-), čo vnáša do dát nerovnováhu. Pred tréňovaním bolo 20 % vzoriek vyčlenených na samostatné testovanie natrénovaných modelov.




Obr. 13: Zloženie datasetu pre optimalizáciu zväracích parametrov.

Vstupom NS je sekvencia 1 024 bodov s dvoma kanálmi X a Y. Výstup tvorí šesť nezávislých binárnych rozhodnutí pre úpravu prúdu, rýchlosti robota a prísunu materiálu, preto má výstupná vrstva sigmoidnú aktiváciu. Architektúra 1D-CNN (Obr. 14) spracúva vstup v tvare $(1024, 2)$. Nasledujú dve konvolučné vrstvy s 32 a 64 filtrami s ReLU aktiváciou. Potom je použitý Dropout a tretia konvolučná vrstva so 64 filtrami. Dimenzia sa zredukuje pomocou GlobalMaxPooling1D. Za ňou je hustá vrstva so 128 neurónmi a záverečná vrstva so šiestimi sigmoidnými jednotkami. Modely boli optimalizované algoritmom Adam s $\text{learning_rate } 1 \times 10^{-4}$ a stratovou funkciou binárnej krížovej entropie podľa vzorca (2.9). Tréning prebiehal počas 20 epoch s dávkou 32 a


rozdelením dát 60 % tréning, 20 % validácia a 20 % test. Priebehy straty a binárnej presnosti potvrdili plynulú konvergenciu všetkých architektúr. Konečné porovnanie na odloženej testovacej sade však ukázalo, že 1D-CNN poskytuje najlepšiu generalizáciu, preto bola zvolená ako výsledné riešenie.

$$L = -\frac{1}{N} \sum_{i=1}^N [y_i \cdot \log(\hat{y}_i) + (1 - y_i) \cdot \log(1 - \hat{y}_i)] \quad (2.9)$$



Obr. 14: Architektúra 1D CNN.


Výsledky logovania binárnej presnosti (Obr. 15) trénovaných neurónových sietí po každej iterácii sú zobrazené na nasledujúcom grafe. Je vidieť, že model 1D-ResNet dosiahol najvyššiu binárnu presnosť. Zároveň všetky testované architektúry (MLP, 1D-CNN aj 1D-ResNet) vykázali stabilný priebeh znižovania straty aj rastu presnosti bez výrazných fluktuácií, či problémov s divergenciou. V nasledujúcej podkapitole sú prezentované výsledky hodnotenia na odloženej testovacej sade.



Obr. 15: Priebeh presnosti NS počas tréovania.


4.2 Testovanie a zhrnutie

V experimentoch sme otestovali tri architektúry neurónových sietí: MLP, 1D-CNN a 1D-ResNet. Ďalej sa sústreďíme na 1D-CNN, ktorá na odloženej testovacej sade dosiahla najlepšie výsledky. Testovanie prebehlo na 310 404 skenoch. Keďže každý sken má šesť nezávislých binárnych rozhodnutí, spolu bolo vyhodnotených 1 862 424 klasifikácií. Kombinovaná konfúzna matica 1D-CNN (Obr. 16) ukazuje celkovú presnosť 96,1 % s 80,8 % správne negatívnych a 15,3 % správne pozitívnych prípadov. Falošné pozitíva dosiahli 1,8 % a falošné negatíva 2,1 % (Obr. 17). Model najspoľahlivejšie rozpoznal potrebu znížiť prúd s presnosťou 96,3 % a potrebu zvýšiť prívod materiálu s presnosťou 93,1 %. Najnižšiu úspešnosť dosiahol pri detekcii požiadavky na zvýšenie rýchlosti robota so 77,9 % správnych rozhodnutí.



Obr. 16: Kombinovaná konfúzna matica pre CNN model z testovacieho datasetu.

Pre úplnosť uvádzame, že MLP dosiahla celkovú presnosť 95,9 % s 80,5 % negatívnych a 15,4 % pozitívnych prípadov a mierne vyšším podielom falošne pozitívnych a negatívnych rozhodnutí. 1D-ResNet, hoci počas tréningu vykazoval najnižšiu stratu, na testovacej sade dosiahol 94,9 % s 79,2 % negatívnych a 15,7 % pozitívnych prípadov. Na základe týchto výsledkov považujeme 1D-CNN za najvhodnejší model na odporúčanie úprav zväracích parametrov.



Obr. 17: Podrobná konfúzna matica pre CNN model z testovacieho datasetu.

Úpravy zväracích parametrov dnes vo veľkej miere stoja na intuícii skúseného personálu, pričom pri vizuálne podobných zvaroch sa odporúčania technologov môžu líšiť. Ak je sieť natrénovaná na anotáciách jedného odborníka, naučí sa jeho štýl a mimo neho generalizuje slabšie. Pre univerzálnejšie a robustnejšie riešenie je vhodné zapojiť do anotovania viacerých technologov a zvaračov, aby sa dataset obohatil o rozdielne prístupy a intuitívne stratégie.

Na odloženej testovacej sade sa ako najefektívnejšia ukázala 1D-CNN, a to z hľadiska rýchlosti učenia aj presnosti. Priestor na zlepšenie vidíme v lepšom vyvážení datasetu, najmä pri zriedkavých scenároch, ako je potreba zvýšiť rýchlosť robota a v predĺžení tréningu na 30 až 50 epoch s cieľom ešte stabilnejšej konvergencie.

Navrhnuté riešenie pracuje dávkovo: po dokončení každého zvaru spracuje 2D skeny a vygeneruje odporúčania pre prúd, rýchlosť pohybu a prívod materiálu. Znižuje závislosť od prítomnosti experta, prináša konzistentné, opakovateľné doladenie procesu, pričom odporúčania možno archivovať pre potreby kontroly kvality. Napriek obmedzeniam sme naplnili hlavný cieľ druhej tézy: vytvorili sme AI nástroj, ktorý na základe 2D laserových skenov generuje odporúčania na úpravu kľúčových zväracích parametrov.

5 Určenie stavu hrotu volfrámovej zvaracej elektródy pomocou NS

Na základe predchádzajúcej analýzy, ktorá potvrdila význam stavu volfrámovej elektródy pre kvalitu a stabilitu zvarania, rozpracúvame pokročilejšiu metódu diagnostiky založenú na neurónových sieťach. Stav volfrámovej elektródy zásadne ovplyvňuje stabilitu oblúka, kvalitu zvaru a efektivitu procesu. Aj mierne opotrebenie hrotu zvyšuje výskyt defektov a frekvenciu prerušení. Posúvame sa preto k inteligentnej diagnostike, v ktorej systém automaticky identifikuje opotrebenie z laserových skenov a umožní rýchlu preventívnu údržbu bez manuálnej kontroly.


Na ilustráciu používame príklady hrotov elektródy. Príklad nového, čistého hrotu kontrastuje s hrubšou elektródou so zaoblením a kvapôčkami naneseného materiálu a s typickým vejárovitým znečistením po dlhšom používaní (Obr. 18). Na týchto prípadoch demonštrujeme spracovanie a vyhodnotenie dát, z ktorých zostavíme tréningový dataset pre neurónové siete. Cieľom je bez zásahu operátora identifikovať mieru opotrebenia alebo znečistenia na základe laserových dát.



Obr. 18 Príklady hrotov volfrámových zvaracích elektród.

5.1 Navrhnuté riešenie

Vstup systému tvoria skeny hrotov získané 2D skenerom scanCONTROL 3000-25BL integrovaným do pracoviska. Po ukončení zvaracieho cyklu bola elektróda robotom presunutá do snímacej polohy s hrotom orientovaným nadol a riadiaci počítač softvérovo spustil zber. Manipulátor vykonal vertikálny pohyb nahor tak, aby hrot prechádzal skenovacou rovinou. Z profilov boli zostavené mračná bodov podľa postupu opísaného v [45]. Ofset medzi po sebe idúcimi skenmi bol určený z rýchlosti a frekvencie snímania. Pri rýchlosti 2 mm/s, frekvencii 100 Hz a zdvihu 10 mm vznikol profil s krokom 20 μm pozdĺž osi Z. Tento ofset bol aplikovaný pri skladaní profilov do 3D mračna (Obr. 19).



Obr. 19: Mračná bodov zachytávajúce hroty volfrámových zvaracích elektród.

Na filtráciu bolo použité zhľukovanie podľa priestorovej vzdialenosti. Za odľahlý bol považovaný bod bez suseda v okruhu 0,3 mm. Zo všetkých klastrov sme ponechali len dva najväčšie, ktoré spravidla reprezentujú hrot elektródy a okraj dýzy. Zachovali sme iba zhľuky s viac ako 10 000 bodmi. Vybrané zhľuky sa zlúčili do jedného mračna. Týmto postupom sa odstránili malé a nesúvisiace šumové štruktúry. Príklady odstránených bodov sú na Obr. 21 vyznačené červenou. Takto očistené dáta tvoria základ pre výpočet kružníc, ktoré následne vstupujú do trénovania neurónovej siete. Jadrom metódy je aproximácia každého profilového rezu kružnicou a sledovanie priebehu jej priemeru pozdĺž hrotu. Východiskom je rovnica kružnice:

$$(x - a)^2 + (y - b)^2 = r^2 \quad (2.10)$$

ktorú prepíšeme do kvadratického tvaru:

$$x^2 + y^2 + Ax + By + C = 0 \quad (2.11)$$

Hľadáme parametre A , B , C metódou najmenších štvorcov. Zostavíme maticu $X \in \mathbb{R}^{n \times 3}$, kde s riadkami $[x_i, y_i, 1]$, a vektor $Y = -(x_i^2 + y_i^2)$. Riešime rovnice:

$$X^T X \cdot \theta = X^T Y \quad (2.12)$$

kde $\theta = [A, B, C]^T$. Stred kružnice je:

$$(x_0, y_0) = \left(-\frac{A}{2}, -\frac{B}{2}\right) \quad (2.13)$$

Polomer kružnice:


$$r = \sqrt{x_0^2 + y_0^2 - C} \quad (2.14)$$

Pravidelnosť tvaru hodnotíme smerodajnou odchýlkou:

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (\|(x_i, y_i) - (x_0, y_0)\| - r)^2} \quad (2.15)$$

Nižšia σ znamená väčšiu blízkosť ideálnej kružnici. Aproximovaný povrch hrotu tvorený sledom kružníc je ilustrovaný na Obr. 20. Tento deskriptívny profil priemeru a pravidelnosti používame

ako vstup pre neurónové siete hodnotiace opotrebenie a znečistenie elektródy. Pri znečistenom hrote štandardná odchýlka lokálne narastá, čo potvrdzuje diagnostickú hodnotu týchto dát. Takto pripravené sekvencie polomeru a štandardnej odchýlky používame ako vstup do neurónových sietí. Príklady vzoriek sú na Obr. 21.




Obr. 20: Aproximované mračná bodov kružnicami.

Pre tréovanie a testovanie siete bol vytvorený dataset pokrývajúci rôzne stupne opotrebenia volfrámovej elektródy aj reálne situácie pri snímaní. Oskenovaných bolo 19 elektród, každá 181-krát po pootočení o 1° . Takto vzniklo pre jednu elektródu 181 priebehov polomerov pozdĺž osi, ktoré sa vplyvom odlišných uhlov dopadu lúča a jemných nerovností povrchu prirodzene líšili.


Okrem prirodzenej variability bola použitá cieľená augmentácia. Z každého skenu sa extrahovalo okno s dĺžkou 256 bodov a náhodne sa posunulo o 1 až 10 bodov v smere od hrotu k dýze. Tým sme simulovali posuny začiatku snímania a zabezpečili, aby model nebol citlivý na presné zarovnanie minima priemeru, ale hodnotil stav hrotu ako celok. Výsledkom bol dataset s 6892 vzorkami. Každá vzorka obsahovala 256 polomerov, 256 štandardných odchýlok aproximácie a cieľové hodnotenie udelené technológom v rozsahu 0,0 až 1,0 po kroku 0,05. Pred tréningom prebehla normalizácia, oddelenie testovacej množiny a ukladanie do HDF5. Polomery boli orezané na maximum 2,0 mm, následne škálované lineárne do intervalu 0–1. Štandardné odchýlky boli orezané na 0,8 mm a škálované do 0–1 podľa intervalu 0–0,8 mm.

Využili sme štyri architektúry neurónových sietí: 1D CNN, LSTM, jednoduché MLP a komplexnejšie MLP2. Najúspešnejší model bol 1D CNN. Architektúra pozostáva z troch konvolučných vrstiev s počtami filtrov 32, 64 a 128, medzi ktorými je MaxPooling. Za konvolučnou časťou nasleduje plne prepojená vrstva so 64 neurónmi a výstupná sigmoidná jednotka. Tréovanie prebehlo na znormalizovanom datasete s 6892 vzorkami, rozdelenom v pomere 60 % tréning, 20 % validácia a 20 % test. Učili sme 60 epoch s dávkou 16, pričom sme po dávkach logovali hodnoty MSE. Z priebehov straty vyplynulo (Obr. 22), že 1D CNN dosiahla

najnižšiu chybu a najstabilnejšiu konvergenciu. LSTM a jednoduché MLP konvergovali na vyššiu chybu a MLP2 vykazovala stagnáciu. Na ďalšie vyhodnotenie a nasadenie bol zvolený model 1D CNN.




Obr. 21: Príklady vzoriek dát predspracovaných na vstup do neurónových sietí.



Obr. 22: Proces tréningu NS na hodnotenie stavu hrotu volfrámovej elektródy.

5.2 Testovanie a zhrnutie

Testovanie prebehlo na samostatnej množine 1 379 vzoriek vyčlenenej pred tréningom a nepoužitej počas učenia. Porovnali sme štyri architektúry (1D CNN, LSTM, MLP, MLP2), pričom najnižšiu chybu dosiahla 1D CNN s $MSE=0,000109$. LSTM dosiahla 0,0005660, jednoduché MLP 0,0006990 a MLP2 0,0146770. Rozptyl predikovaných hodnotení voči referenciám sa pri 1D CNN tesne zhlukoval okolo diagonály $y=x$ v celom rozsahu, čo indikuje vysokú presnosť a minimálny bias (Obr. 23). Pozorované medzery okolo hodnôt 0,3 a 0,7 odrážajú rozdelenie anotácií v datasete a diskretný krok 0,05 spôsobuje zhlukovanie bodov na vertikálnych a horizontálnych úrovniach. LSTM a MLP vykázali väčší rozptyl okolo diagonály, avšak správali sa konzervatívne a nenadhodnocovali stav zhoršených elektród. MLP2 síce dobre zachytávala kategóriu dobrých elektród, no pri úplne poškodených prípadoch a najmä okolo hodnotenia 0,4 vykazovala neprijateľné nadhodnotenia až k $\sim 0,85$. Výsledky potvrdzujú, že 1D CNN najlepšie generalizuje a je pre danú úlohu najvhodnejšia ako presný a stabilný prediktor stavu volfrámovej elektródy.



Obr. 23: Graf predikcie stavu hrotu volfrámových zvracích elektród - CNN.

Pôvodný prístup vyžadoval minimálne štyri merania s otáčaním elektródy a úplnú 3D rekonštrukciu hrotu. Navrhnuté riešenie pracuje s jediným meraním, čím sa čas zberu dát skrátil približne o 75 %. Systém je tak vhodný na rýchlu kontrolu v prestojoch. Rizikom zostáva možnosť

prehliadnuť asymetrické poškodenie viditeľné len z jednej strany, takýto prípad však počas experimentov nenastal.

Pri tvorbe datasetu bola identifikovaná nevyváženosť v rozložení vzoriek. Väčšina dát patrila do troch oblastí hodnotenia: výrazne opotrebované hroty, stredné opotrebenie a nové elektródy. Tomu zodpovedajú medzery okolo hodnôt 0,3 a 0,7 a klastrovanie spôsobené diskretným krokom anotácie 0,05. Na testovacej množine 1 379 vzoriek boli porovnané štyri architektúry neurónových sietí. Najlepšiu generalizáciu a najnižšiu chybu dosiahla 1D konvolučná sieť, ktorá vykázala aj najmenší rozptyl predikcií okolo referenčných hodnôt.

Výsledný systém umožňuje nastaviť prah opotrebenia, pri ktorom sa automaticky odporučí výmena alebo brúsenie hrotu. Riešenie je tým flexibilné a prispôsobiteľné konkrétnej technológii i požiadavkám kvality a je pripravené na integráciu do širšieho rámca autonómneho riadenia kvality v inteligentnom robotickom pracovisku.

6 Zovšeobecnenie navrhnutého systému

V predchádzajúcich podkapitolách boli prezentované a verifikované tri samostatné riešenia, ktoré prostredníctvom umelej inteligencie zvyšujú efektivitu a spoľahlivosť robotického zvárania:

1. **Fúzia dát robota a 2D laserových skenov.** Synchronizácia polôh a profilov pre korektné mračná bodov.
2. **Korekcia parametrov zvárania.** Odporúčanie úprav prúdu, rýchlosti robota a prísunu materiálu z laserových profilov.
3. **Automatická diagnostika hrotu elektródy.** Odhad opotrebenia zo skenov a spúšťanie preventívnej údržby.

Cieľom tejto kapitoly a zadaním tretej tézy dizertačnej práce je tieto tri riešenia zovšeobecniť a popísať tak, aby bolo možné ich jednoducho adaptovať na rôzne typy zváracích pracovísk.


6.1 Fúzia polôh robotického manipulátora a laserových 2D skenov

Na Obr. 24 je znázornený všeobecný postup fungovania synchronizačného nástroja, ktorý slúži na korekciu časových posunov medzi polohovými dátami robotického ramena a laserovými skenmi.

Proces sa skladá z nasledovných krokov:

1. **Konfigurácia zdrojov dát.** Nastavíme komunikáciu robot - PC a skener - PC. Určíme parametre kontajnerového režimu skenera.
2. **Zber dát.** Softvérový trigger spustí súbežný záznam laserových profilov a polôh. Po meraní sú dáta archivované.
3. **Extrakcia synchronizačného pohybu.** Z trajektórie vyrežeme vertikálny segment v osi Z ako referenčný úsek.
4. **Predspracovanie.** Získame Z-trajektóriu a vzdialenosti skenera. Polohy prevzorkujeme na hustotu skenera, vyberieme okno 256 vzoriek a normalizujeme.
5. **Rozhodnutie o dotrénovaní.** Áno (A): manuálne anotujeme Δt , rozšírime dataset a model dotrénujeme. Nie (N): pokračujeme s existujúcim modelom.
6. **Načítanie parametrov neurónovej siete.** Pripravíme natrénovanú neurónovú sieť s uloženými parametrami.
7. **Určenie časového posunu Δt .** Model vráti hodnotu v intervale $[0,1]$, ktorú spätne škálujeme na interval $[-60, 50]$ ms.
8. **Aplikácia korekcie na mračno bodov.** Pri skladaní profilov do mračna bodov uplatníme Δt . Eliminujeme posuny a deformácie. Výsledok sa archivuje.
9. **Výstup do ďalších procesov.** Korigované mračná odovzdáme modulom inšpekcie zvarov, lokalizácie medzery a generovania trajektórií.

Tento modulárny postup je prenosný naprieč platformami a senzormi. Stačí prispôbiť konfiguráciu rozhraní a podľa potreby doplniť dataset.



Obr. 24: Zovšeobecnený diagram AI systému na synchronizáciu polôh robota a laserových dát.


6.2 Korekcia parametrov robotického zvárania

Na Obr. 25 je znázornený všeobecný postup pre korekciu parametrov zvárania, ktorý spracováva 2D laserové skeny a generuje odporúčania na úpravu parametrov zvárania. Celý postup pokrýva zber a synchronizáciu dát, ich anotáciu, pedspracovanie, tréovanie neurónových sietí až po zobrazenie výsledkov. Proces sa skladá z nasledovných krokov:

1. **Konfigurácia zdrojov dát.** Pripojíme 2D skener, polohové dáta robota (príp. ďalšie senzory) a nastavíme komunikačné rozhrania.
2. **Zber dát a synchronizácia.** Po každom zvare automaticky zaznamenáme profil a metadáta, zosúladiť skener s robotom a mračno bodov archivujeme.

3. **Predspracovanie.** Vyberieme pevné okno 1024 bodov a dáta normalizujeme.
4. **Rozhodnutie o dotrénovaní.** Ak treba, v GUI anotujeme nové vzorky (interval a požadované zmeny), rozšírime dataset a model dotrénujeme, inak pokračujeme.
5. **Načítanie modelu a parametrov NS.** Načítanie architektúry a váh NS pre predikciu.
6. **Určenie korekcie.** Model vráti 6 binárnych rozhodnutí ($\pm$ prúd, $\pm$ rýchlosť robota, $\pm$ prívod materiálu). Uložíme nové skeny, anotácie a prípadne aktualizované váhy.
7. **Operátorské HMI.** Zobrazíme odporúčania a operátor ich aplikuje pred zváraním.

Vďaka modulárnemu postupu sa celý systém dá nasaadiť na rôzne robotické platformy i typy laserových snímačov do procesu robotického zvárania. Je potrebné len upraviť konfiguračný krok (zdroje dát, komunikačné rozhrania) a prípadne rozšíriť dataset o nové vzorky.




Obr. 25: Zovšeobecnený diagram AI systému na optimalizáciu parametrov robotického zvárania.

6.3 Automatické určenie stavu hrotu volfrámovej elektródy

V tejto podkapitole je predstavený zovšeobecnený postup integrácie AI systému na hodnotenie stavu zváracieho nástroja. Diagram na Obr. 26 zobrazuje jednotlivé kroky procesu – od zberu dát až po realizáciu servisných zásahov na základe výstupu neurónovej siete. Proces sa skladá z nasledovných krokov:

1. **Konfigurácia zdrojov dát.** Nastavenie snímačov a zariadení. Voľba frekvencie, expozície, komunikačných rozhraní a polohy inšpekčného skenera.
2. **Zber dát.** Skenovanie hrotu volfrámovej elektródy. Ukladanie do centrálného úložiska.
3. **Predspracovanie.** Čistenie a filtrovanie bodov. Aproximácia kružnicami. Výpočet polomerov a štandardných odchýlok. Extrakcia hrotu a výber posledných 256 bodov.
4. **Rozhodnutie o dotrénovaní.** Ak treba, anotácia stavu technológom a dotrénovanie modelu. Inak sa použijú uložené parametre existujúcej siete.
5. **Načítanie modelu.** Načítanie architektúry a váh NS pripraveného pre predikciu.
6. **Ohodnotenie stavu.** Predikcia numerického skóre opotrebenia zo vstupných sekvencií.
7. **Riadiace CPU.** Porovnanie skóre s prahmi nastavenými technológom. Rozhodnutie o servisnom zásahu.
8. **Servisný úkon** - Výmena alebo údržba nástroja. Pokračovanie vo zváraní.

Navrhnutý postup predstavuje adaptovateľnú metodiku, ktorá umožňuje zavedenie umelej inteligencie do procesov kontroly kvality nástrojov v automatizovanom zváraní. Jeho výhodou je modularita a možnosť prispôsobenia konkrétnym technickým podmienkam na pracovisku. Systém je navrhnutý tak, aby umožňoval dotrénovanie na nových dátach a zároveň podporoval spätnú väzbu do výrobného procesu.



Obr. 26: Zovšeobecnený diagram AI systému na kontrolu stavu zváracieho nástroja.

Záver

Práca poskytuje ucelený rámec využitia umelej inteligencie na podporu kvality a efektivity TIG robotického zvarovania v prostredí inteligentného pracoviska. Teoretická časť identifikovala metódy vhodné pre obrazy, sekvenčné signály a 3D mračná bodov a poskytla metodické východisko pre návrh praktických riešení. Naprieč úlohami sa ako kľúčové ukázali 1D konvolučné siete, ktoré pri sekvenčných laserových dátach spoľahlivo extrahujú lokálne časovo-priestorové črty a prekonávajú LSTM aj husté MLP alternatívy.

V prvej téze sme adresovali základný problém nesúbežného štartu meraní a variabilných latencií medzi polohovým záznamom robota a profilmi z 2D skenera. Navrhnutá metodika pokrýva celý reťazec činností od zberu a augmentácie dát cez návrh a tréning siete až po korekciu časového posunu pri skladaní mračna bodov. Výsledky preukázali, že 1D CNN dokáže zlepšiť zarovnanie v osi Z až o 94 %, čo priamo zvyšuje presnosť následnej inšpekcie a spoľahlivosť rozhodovania.

Druhá téza obsahuje adaptívny odporúčací systém, ktorý priamo z 2D laserových skenov generuje návrhy úprav prúdu, rýchlosti pohybu a prívodu prídavného materiálu. Tréning na rozsiahlej databáze príkladov viedol k presnosti 96,1 % pri 1D CNN, čím sa výrazne redukuje závislosť od doladovania technológov. Tiež sme transformovali pôvodnú 3D diagnostiku stavu volfrámovej elektródy na postup s jedným skenovacím cyklom a 1D CNN. Proces sa zrýchlil približne o 75 % pri zachovaní vysokej spoľahlivosti bez tendencie k nadhodnocovaniu stavu. Zohľadnili sme, že jednoskenové hodnotenie nemusí zachytiť čisto asymetrické poškodenia. Experimentálne sa neprejavili, avšak metodika je pripravená na rozšírenie o rotačné vzorkovanie tam, kde to bude potrebné z hľadiska rizika.

Tretia téza priniesla zovšeobecnenie do modulárnej architektúry so spoločnou dátovou správou a prenositeľnými rozhraniami. Metodiky sú navrhnuté tak, aby vyžadovali len minimálne zásahy pri zmene robotickej platformy či snímača, pričom zachovávajú možnosť dotrénovania modelov na nových dátach.

Z praktického hľadiska výsledky prinášajú merateľné prínosy: presnejšie a menej deformované mračná bodov zlepšujú následnú kontrolu, odporúčania parametrov skracujú čas nastavovania a znižujú odpad, a priebežná diagnostika nástroja podporuje prediktívnu údržbu.

Priestor pre ďalší rozvoj vidíme v skrátení a adaptácii synchronizačných pohybov podľa aktuálnej kvality dát, v zapojení viacerých expertných anotácií a mechanizmov dohody medzi anotátormi, v online adaptácii modelov s riadenou spätnou väzbou z výroby a v multimodálnej fúzii ďalších signálov (prúd, napätie, sily, teplota). Tieto kroky môžu posilniť robustnosť a autonómiu systémov a otvárajú cestu k plne integrovaným, dátovo-riadeným zvaracím pracoviskám, ktoré konzistentne dosahujú požadovanú kvalitu aj v podmienkach obmedzenej dostupnosti kvalifikovaného personálu.

Literatúra

- [1] LIU, J. - JIANG, F. - TASHIRO, S. – CHEN, S. – TANAKA, M. 2025. A physics-informed and data-driven framework for robotic welding in manufacturing. In *Nat Commun* 16, 4807 (2025). Dostupné online: <https://doi.org/10.1038/s41467-025-60164-y>
- [2] ALI, R. - EL-BETAR, A. - MAGDY, M. 2024. A review on optimization of autonomous welding parameters for robotics applications. In *Int J Adv Manuf Technol* 134, 5065–5086 (2024). Dostupné online: <https://doi.org/10.1007/s00170-024-14396-9>
- [3] HRIVŇÁK, I. 2013. Zváranie a zvariteľnosť materiálov. 2. nezm. vyd. Bratislava: Citadella, 2013. 486 s. ISBN 978-80-89628-18-6.
- [4] GUAN, T. 2023. Research on the application of robot welding technology in modern architecture. In *Int J Syst Assur Eng Manag* 14, 681–690 (2023). Dostupné online: <https://doi.org/10.1007/s13198-021-01473-5>
- [5] HAMZAH, H. 2023. Development of Welding Technology in the Future: Analysis of Trends and Impacts on Industry and the Environment. In *Collaborate Engineering Daily Book Series, I(1)*, 100–106 (2023). Dostupné online: <https://doi.org/10.62012/collaborate.v1i1.6>
- [6] NURULLAH, Y. - HÜSEYİN, R. B. – HÜSEYİN, K. S. – OLCAY, E. C. 2023. Review of artificial intelligence applications in engineering design perspective. In *Engineering Applications of Artificial Intelligence* 118, (2023). Dostupné online: <https://doi.org/10.1016/j.engappai.2022.105697>
- [7] EREN, B. - DEMİR, M.H. - MISTIKOĞLU, S. 2023. Recent developments in computer vision and artificial intelligence aided intelligent robotic welding applications. In *Int J Adv Manuf Technol* 126,(2023). Online: <https://doi.org/10.1007/s00170-023-11456-4>
- [8] RISHIKESH, M. R. – AVINAASH, J. – LAKSHMI, P. – ASHUTOSH, S. – SENTHIL, K. S. 2021. Intelligent welding by using machine learning techniques. In *Materials Today: Proceedings* 48, (2021). Dostupné online: <https://doi.org/10.1016/j.matpr.2020.12.1149>
- [9] SCHMIDGALL, S. - ACHTERBERG, J. - MICONI, T. – KIRSCH, L. – ZIAEI, R. – HAJISEYEDRAZI, S. P. – ESHRAGHIAN, J. 2023. Brain-inspired learning in artificial neural networks: a review. In *Neural and Evolutionary Computing* (2023). Dostupné online: <https://doi.org/10.48550/arXiv.2305.11252>
- [10] NÁVRAT, P. a kol. 2015. Umelá inteligencia. Nakladateľstvo STU v Bratislave, 2013. 437 s. ISBN 978-80-227-4344-0.

- [11] EIBEN, A.E. – SMITH, J.E. 2015. Introduction to Evolutionary Computing. In *Springer*, 2015. 294 s. ISBN 978-3-662-44874-8.
- [12] THAKUR, A. – ARCHIT, K. 2021. Fundamentals of neural networks. In *International Journal for Research in Applied Science and Engineering Technology*. 407-426 (2021). Dostupné online: https://www.researchgate.net/publication/353827517_Fundamentals_of_Neural_Networks
- [13] GOODFELLOW, I. – BENGIO, Y. – COURVILLE, A. 2016. Deep Learning. In *MIT Press*, (2016). 800 s. ISBN: 9780262035613
- [14] WHANG, S.E. - ROH, Y. - SONG, H. – LEE, J.G. 2023. Data collection and quality challenges in deep learning: a data-centric AI perspective. *The VLDB Journal* 32, 791–813 (2023). Dostupné online: <https://doi.org/10.1007/s00778-022-00775-9>
- [15] MAHMOUDI, K. R. - Daniel, S. - Giguère, P. 2023. Data Preparation Impact on Semantic Segmentation of 3D Mobile LiDAR Point Clouds Using Deep Neural Networks. *Remote Sens.*, 15, 982 (2023). Dostupné online: <https://doi.org/10.3390/rs15040982>
- [16] YANG, P. a kol. 2020. Weld Surface Imperfection Detection by 3D Reconstruction of Laser Displacement Sensing. In *ICMCCE* (2020). Dostupné online: <https://ieeexplore.ieee.org/abstract/document/9421751>
- [17] SPRUCK, A. a kol. 2020. Quality Assurance of Weld Seams Using Laser Triangulation Imaging and Deep Neural Networks. In *2020 IEEE International Workshop on Metrology for Industry 4.0 & IoT* (2020). Dostupné online: <https://ieeexplore.ieee.org/document/9138205>
- [18] BOLOGNA, F. – TANNOUS, M. – ROMANO, D. – STEFANINI, C. 2022. Automatic welding imperfections detection in a smart factory via 2-D laser scanner. In *Journal of Manufacturing Processes* (2022). Dostupné online: <https://www.sciencedirect.com/science/article/pii/S1526612521007787>
- [19] MIAO, R. a kol. 2022. Real-time defect identification of narrow overlap welds and application based on convolutional neural networks. In *Journal of Manufacturing Systems* (2022). Dostupné online: <https://www.sciencedirect.com/science/article/pii/S0278612521000121>
- [20] ZHANG, Z. – WEN, G. – CHEN, S. 2019. Weld image deep learning-based on-line defects detection using convolutional neural networks for Al alloy in robotic arc welding. In *Journal of Manufacturing Systems* (2019). Dostupné online: <https://www.sciencedirect.com/science/article/pii/S1526612519301860>

- [21] GONZÁLVEZ, R. P. – MARTÍN, M. R. 2019. Weld Bead Detection Based on 3D Geometric Features and Machine Learning Approaches. In *IEEE Access* (2019). Dostupné online: <https://ieeexplore.ieee.org/abstract/document/8604036>
- [22] PAIGWAR, A. – ERKENT, O. – WOLF, CH. – LAUGIER, CH. 2019. Attentional pointnet for 3d-object detection in point clouds. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops* (2019). Dostupné online: https://openaccess.thecvf.com/content_CVPRW_2019/papers/WAD/Paigwar_Attentional_PointNet_for_3D-bjct_Detection_in_Point_Clouds_CVPRW_2019_paper.pdf
- [23] DESAI, N. – SCHUMANN, T. – ALSHEAKHALI, M. 2020. A Review of PointPillars Architecture for Object Detection from Point Clouds. In *2020 IEEE International Conference on Consumer Electronics - Taiwan (ICCE-Taiwan)* (2020). Dostupné online: <https://ieeexplore.ieee.org/abstract/document/9258147>
- [24] ALABA, S.Y. – BALL, J.E. 2022. A Survey on Deep-Learning-Based LiDAR 3D Object Detection for Autonomous Driving. *Sensors* (Basel). (2022). doi: 10.3390/s22249577.
- [25] LI, Y. – MA, L. - ZHONG, Z. – LIU, F. - CAO, D. – LI, J. - Chapman, A. M. 2020. Deep Learning for LiDAR Point Clouds in Autonomous Driving: A Review (2020). Dostupné online: <https://doi.org/10.48550/arXiv.2005.09830>
- [26] LANG, H. A. a kol. 2019. Pointpillars: Fast encoders for object detection from point clouds. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (2019). Dostupné online: https://openaccess.thecvf.com/content_CVPR_2019/papers/Lang_PointPillars_Fast_Encoders_for_Object_Detection_From_Point_Clouds_CVPR_2019_paper.pdf
- [27] QI, CH. – SU, H. – MO, K. – GUIBAS, J. 2017. PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation (2017). Dostupné online: <http://stanford.edu/~rqi/pointnet/>
- [28] MOHAMAD, H. T. – ABBASI, A. – KIM, E. – NATARAJ, C. 2021. Application of Deep CNN-LSTM Network to Gear Fault Diagnostics (2021). Dostupné online: <https://ieeexplore.ieee.org/abstract/document/9486591>
- [29] CHOW, J. K. a kol. 2020. Anomaly detection of defects on concrete structures with the convolutional autoencoder. In *Advanced Engeneering Informatics* (2020). Dostupné online: <https://www.sciencedirect.com/science/article/pii/S1474034620300744>
- [30] MICHELUCCI, U. 2022. An introduction to autoencoders. In *arXiv preprint arXiv:2201.03898* (2022). Dostupné online: <https://doi.org/10.48550/arXiv.2201.03898>

- [31] PINTELAS, E. – LIVIERIS, I.E. – PINTELAS, P.E. 2021. A Convolutional Autoencoder Topology for Classification. In *High-Dimensional Noisy Image Datasets. Sensors*. (2021). Dostupné online: <https://doi.org/10.3390/s21227731>
- [32] BUCKLEY, J. J. - ESLAMI, E. 2002. An Introduction to Fuzzy Logic and Fuzzy Sets (2002) doi:10.1007/978-3-7908-1799-7
- [33] STN EN ISO 17659:2005: Zváranie. Viacjazyčné termíny pre zvarové spoje s obrázkami
- [34] KOLEŇÁK, R. – ULRICH, K. – PROVAZNÍK, M. 2011. Zváracie procesy a zariadenia. Bratislava: Slovenská technická univerzita, (2011). 272 s. ISBN 978-80-227-3575-9
- [35] TNI CEN/TR 14599 (05 0007):2008: Termíny a definície pre zváranie vo vzťahu k EN 1792
- [36] SEJČ, P. 2013. TECHNOLOGIA I: Zváranie. Bratislava: Slovenská technická univerzita, 2013. 98 s. ISBN 978-80-227-4099-9
- [37] STN EN ISO 4063:2009: Zváranie a príbuzné procesy. Zoznam spôsobov zvárania a ich číselné označovanie
- [38] STN EN 14610:2005: Zváranie a príbuzné procesy. Definície spôsobov zvárania
- [39] STN EN ISO 6520-1:2008: Zváranie a príbuzné procesy. Zatriedenie chýb zvarových spojov kovových materiálov. Časť 1: Tavné zváranie
- [40] ČSN EN ISO 5817:2014: Svařování – Svarové spoje oceli, niklu, titanu a jejich slitin zhotovené tavným svařováním (kromně elektronového a laserového svařování) – Určování stupňů kvality
- [41] KOVARIKOVA, Z. – DUCHON, F. – TREBULA, M. – NAGY, F. – DEKAN, M. - LABAT, D. – BABINEC, A. 2023. Prototyping an intelligent robotic welding workplace by a cyber-physic tool. In *International Journal of Advanced Manufacturing Technology*, 125 (9-10), (2023). DOI: 10.1007/s00170-023-10986-1
- [42] KOVARIKOVA, Z. a kol. Robotický systém na adaptívne spájanie súčastí: Úžitkový vzor č. 9381, Dátum o zápise ÚV : 24. 11. 2021, Vestník ÚPV SR č. 22/2021 Dostupné online: <https://wbr.indprop.gov.sk/WebRegistre/UzitkovyVzor/Detail/51-2021>
- [43] GÉRER, A. 2022. Špičkové pracovisko robotického zvárania (1). In *ATP Journal* (2022). Dostupné online: https://www.atpjournalsk/rubriky/aplikacie/spickove-pracovisko-robotickeho-zvarania-1.html?page_id=34239
- [44] GÉRER, A. 2022. Špičkové pracovisko robotického zvárania (2). In *ATP Journal* (2022). Dostupné online: https://www.atpjournalsk/rubriky/aplikacie/spickove-pracovisko-robotickeho-zvarania-2.html?page_id=34422

- [45] TREBUĽA, M. - ČIERNY, L. - DEKAN, M. - KOVARIKOVA, Z. – PRIŠTIAK, J. – NAGY, F. – DUCHON, F. 2025. Automated inspection of the tip condition of a welding tungsten electrode. In *International Journal of Advanced Manufacturing Technology* 136, 1773–1790 (2025). <https://doi.org/10.1007/s00170-024-14911-y>
- [46] TREBUĽA, M. - ČIERNY, L. - DEKAN, M. - KOVARIKOVA, Z. – PRIŠTIAK, J. – NAGY, F. – DUCHON, F. 2024. Spôsob kontroly stavu hrotu zváraciej elektródy a systém na jeho realizáciu: Úžitkový vzor č. 10120, prihláška úžitkového vzoru č. 192-2023, dátum zápisu: 14.08.2024, dátum oznámenia o sprístupnení dokumentu: 28. 8. 2024, Vestník ÚPV SR č.: 16/2024 Dostupné online: <https://wbr.indprop.gov.sk/WebRegistre/UzitkovyVzor/Detail/192-2023>
- [47] TREBUĽA, M. 2024. Inovatívna metóda na detekciu kontaminácie zváracích elektród v robotickom zváraní. In *ATP Journal*. Dostupné online: https://www.atpjournal.sk/buxus/docs/casopisy_cele/ATP%20Journal%209%202024.pdf#page=20
- [48] MICRO-EPSILON: Operating Instructions scanCONTROL 29xx
- [49] MICRO-EPSILON: Operating Instructions scanCONTROL 30xx <https://www.micro-epsilon.com/download/manuals/man--scanCONTROL-30xx--en.pdf>
- [50] KUKA: KR30, 60-3; KR 30 L16-2 with KR C4 Assembly Instructions
- [51] KUKA: KR QUANTEC pro Návod k provozu
- [52] SCHUNK: FTM-Omega-160 SI-1500-240 P https://schunk.com/sk/sk/automatizacna-technika/snimace-sily/momentu/ft/ftn-omega-160-si-1500-240/p/EPIM_ID-30899
- [53] HBM: QuantumX MX440B Data Sheet <https://www.hbm.com/fileadmin/mediapool/hbmdoc/technical/B03890.pdf>
- [54] ATI NET F/T https://www.ati-ia.com/products/ft/ft_NetFT.aspx
- [55] KAJAN, S. – TREBUĽA, M. – DUCHOŇ, F. – KOVARÍKOVÁ, Z. – ŠVOLÍK, M. – ŠVEC, D., 2024. Robotic Vision Inspection of Weld Quality Using Convolutional Neural Networks, *2024 25th International Carpathian Control Conference (ICCC)*, Krynica Zdrój, Poland, (2024). doi: 10.1109/ICCC62069.2024.10569157
- [56] KAJAN, S. – TREBUĽA, M. – DUCHOŇ, F. – KOVARÍKOVÁ, Z. - KOVÁČ, M. - PAVLOVIČOVÁ, J. 2025. Weld Defect Recognition and Detection from Video Using Deep Learning Methods, *2025 Cybernetics & Informatics (K&I)*, (2025). doi: 10.1109/KI64036.2025.10916449.

- [57] ARAVINTH, P. - SUBRAMANIAN, S. P. - VISHNU, S. G. - VIGNESH, P. 2012. Process failure mode and effect analysis on TIG welding process-a criticality study. In *International Journal of Advances in Engineering & Technology*, 3(2), 746. (2012). Dostupné online: <https://www.proquest.com/docview/1412313010?pq-origsite=gscholar&fromopenview=true&sourcetype=Scholarly%20Journals>
- [58] HONG, T.S. - GHOBAKHLOO, M. - KHAKSAR, W. 2014. Robotic welding technology. In *Comprehensive materials processing*, 77-99 (2014).
- [59] WANG, X., et al. 2021. A survey of welding robot intelligent path optimization. In *Journal of Manufacturing Processes*, 63: 14-23 (2021).
- [60] TANAKA, K. - SHIGETA, M. - KOMEN, H. - TANAKA, M. 2021. Electrode contamination caused by metal vapour transport during tungsten inert gas welding. *Science and Technology of Welding and Joining*, 26(3), 258-263 (2021). <https://doi.org/10.1080/13621718.2021.1893024>
- [61] ESTELLERS, V. - SCOTT, M. - TEW, K. - SOATTO, S. 2015. Robust Poisson Surface Reconstruction. In *Scale Space and Variational Methods in Computer Vision*. SSVM 2015. Lecture Notes in Computer Science, vol 9087. Springer, Cham. (2015). Dostupné online: https://doi.org/10.1007/978-3-319-18461-6_42
- [62] ZHANG, C. - CHEN, T. 2001. Efficient feature extraction for 2d/3d objects in mesh representation. In *Proceedings 2001 International Conference on Image Processing*, vol. 3, pp. 935–938 (2001).

Použitie nástrojov umelej inteligencie

OpenAI (2025), ChatGPT 4o, kontrola gramatiky a štylistiky.

OpenAI (2025), ChatGPT 5, kontrola gramatiky a štylistiky.

Autorove publikácie

V2 Vedecký výstup publikačnej činnosti ako časť editovanej knihy alebo zborníka

KAJAN, Slavomír - TREBUĽA, Marek - DUCHOŇ, František - KOVARÍKOVÁ, Zuzana - ŠVOLÍK, Michal - ŠVEC, Denis. Robotic Vision Inspection of Weld Quality Using Convolutional Neural Networks. In *ICCC 2024 : 25th International Carpathian Control Conference*. Krynica Zdrój, Poland. May 22-24, 2024. Danvers : IEEE, 2024, [5] s. ISBN 979-8-3503-5070-8. V databáze: DOI: 10.1109/ICCC62069.2024.10569157 ; IEEE: 10569157 ; SCOPUS: 2-s2.0-85198560206; WOS: 001268679000002.

KAJAN, Slavomír - TREBUĽA, Marek - DUCHOŇ, František - KOVARÍKOVÁ, Zuzana KOVÁČ, Michal - PAVLOVIČOVÁ, Jarmila. Weld Defect Recognition and Detection from Video Using Deep Learning Methods. In *Cybernetics & Informatics (K&I) 2025 : 32nd International IEEE conference*. Mikulov, Czech Republic. February 2-5, 2025. 1. vyd. Danvers : IEEE, 2025, S. 79-83. ISSN 2767-875X. ISBN 979-8-3315-4181-1. V databáze: DOI: 10.1109/KI64036.2025.10916449 ; SCOPUS: 2-s2.0-105011825506 ; IEEE: 10916449.

LUČAN, Martin - DEKAN, Martin - TREBUĽA, Marek - DUCHOŇ, František. Simulator-Based Distance Learning of Mobile Robotics. In *Robotics in Education : RiE 2023 : 14th International Conference on Robotics in Education*. Limassol, Cyprus. April 19-21, 2023. 1. ed. Cham : Springer, 2023, S. 315-323. ISSN 2367-3370. ISBN 978-3-031-38453-0 (2023: 0.171 - SJR, Q4 - SJR Best Q). V databáze: DOI: 10.1007/978-3-031-38454-7_26 ; SCOPUS: 2-s2.0-85174436891 ; WOS: 001344258000026.

TREBUĽA, Marek - DEKAN, Martin - DUCHOŇ, František - BABINEC, Andrej - NAGY, František - KOVARÍKOVÁ, Zuzana - LABÁT, Dušan. Automatizované meranie geometrie zvarovej medzery pomocou 2D laserového skenera. In *ŠVOČ 2021 [elektronický zdroj] : Zborník vybraných prác*. 21. apríl 2021. Bratislava : Vydavateľstvo Spektrum STU, 2021, S. 154-159. ISBN 978-80-227-51 04-9.

TREBUĽA, Marek - DEKAN, Martin - KOVARÍKOVÁ, Zuzana - BABINEC, Andrej - NAGY, František - DUCHOŇ, František - LABÁT, Dušan. Robotic measurement of the weld gap geometry using a 2D laser scanner. In *ICMERR 2022 : 7th International Conference on Mechanical Engineering and Robotics Research*. Krakow, Poland. December 9-11, 2022. Piscataway : IEEE, 2022, S. 94-101. ISBN 978-1-6654-9051-1. V databáze: DOI: 10.1109/ICMERR56497.2022.10097796 ; WOS: 000986705500017 ; IEEE: 10097796 ; SCOPUS: 2-s2.0-85156185717.

V3 Vedecký výstup publikačnej činnosti z časopisu

KOVARÍKOVÁ, Zuzana - DUCHOŇ, František - TREBUĽA, Marek - NAGY, František - DEKAN, Martin - LABAT, Dušan - BABINEC, Andrej. Prototyping an intelligent robotic welding workplace by a cyber-physic tool. In *International Journal of Advanced Manufacturing Technology*. Vol. 125, iss. 9-10 (2023), s. 4855-4882. ISSN 0268-3768 (2023: 2.9 - JIF, Q2 - JIF Best Q, 0.696 - SJR, Q2 - SJR Best Q, 0.493 - AIS, Q3 - AIS Best Q). V databáze: DOI: 10.1007/s00170-023-10986-1 ; WOS: 000933965300005 ; SCOPUS: 2-s2.0-85147656500.

KOVARÍKOVÁ, Zuzana - DUCHOŇ, František - PORUBSKÝ, Martin - TREBUĽA, Marek - CHOVANEC, Ľuboš - SALÁT, Eva - RAKYTA, Miroslav. Robotic Ultrasound Diagnostic System for Non-Destructive Testing in Highly Variable Production. In *Electronics*. Vol. 14, iss.

10 (2025), Art. no. 2063 [35] s. ISSN 2079-9292 (2024: 2.6 - JIF, Q2 - JIF Best Q, 0.615 - SJR, Q2 - SJR Best Q, 0.429 - AIS, Q3 - AIS Best Q). V databáze: DOI: 10.3390/electronics14102063 ; SCOPUS: 2-s2.0-105006648982 ; WOS: 001495996000001 ; CC: 001495996000001.

TREBUĽA, Marek - ČIERNY, Lukáš - DEKAN, Martin - KOVARÍKOVÁ, Zuzana - PRIŠTIAK, Ján - NAGY, František - DUCHOŇ, František. Automated inspection of the tip condition of a welding tungsten electrode. In *International Journal of Advanced Manufacturing Technology*. Vol. 136, iss. 3-4 (2025), s. 1773-1790. ISSN 0268-3768 (2024: 3.1 - JIF, Q2 - JIF Best Q, 0.706 - SJR, Q1 - SJR Best Q, 0.517 - AIS, Q3 - AIS Best Q). V databáze: DOI: 10.1007/s00170-024-14911-y ; SCOPUS: 2-s2.0-85214022303 ; WOS: 001388210500001 ; CC: 001394409100008.

O2 Odborný výstup publikačnej činnosti ako časť knižnej publikácie alebo zborníka

TREBUĽA, Marek - KOVARÍKOVÁ, Zuzana - DEKAN, Martin. Robotic position correction of weld parts using a 2D laser scanner. In *ELITECH'22 [elektronický zdroj] : 24th Conference of Doctoral Students. Bratislava, Slovakia. June 1, 2022*. 1. ed. Bratislava : Vydavateľstvo Spektrum STU, 2022, [6] s. ISBN 978-80-227-5192-6.

O3 Odborný výstup publikačnej činnosti z časopisu

DUCHOŇ, František - ČORŇÁK, Marek - TÖLGYESSY, Michal - MRÁZ, Eduard - ŠTEC, Filip - TREBUĽA, Marek - CHOVANEC, Ľuboš. Automatica 2022 očami návštevníkov. In *ATP Journal*. Roč. 29, č. 9 (2022), s. 58-60. ISSN 1335-2237.

TREBUĽA, Marek. Inovatívna metóda na detekciu kontaminácie zvaracích elektród v robotickom zvaraní. In *ATP Journal*. Roč. 31, č. 9 (2024), s. 18-19. ISSN 1335-2237.

TREBUĽA, Marek - STUPENĚ, Tomáš. Virtuálna realita v službách bezpečnosti: Digitálne dvojča experimentálneho standu Viktoria Loop. In *ATP Journal*. Roč. 32, č. 3 (2025), s. 18-19. ISSN 1335-2237.

D1 Dokument práv duševného vlastníctva

KOVARÍKOVÁ, Zuzana - PORUBSKÝ, Martin - NAGY, František - LABÁT, Dušan - BACHORÍK, Oliver - PRIŠTIAK, Ján - MÄSIAR, Jozef - DUCHOŇ, František - BABINEC, Andrej - DEKAN, Martin - CHOVANEC, Ľuboš - TREBUĽA, Marek - KOHÚT, Miroslav - DOBIŠ, Michal. *Robotický systém na adaptívne spájanie súčastí : Úžitkový vzor č. 9381, Dátum o zápise ÚV : 24. 11. 2021, Vestník ÚPV SR č. 22/2021*. Banská Bystrica : Úrad priemyselného vlastníctva SR, 2021. 9 s. Dostupné na internete: <<https://wbr.indprop.gov.sk/WebRegistre/UzitkovyVzor/Detail/51-2021>>.

KOVARÍKOVÁ, Zuzana - PORUBSKÝ, Martin - NAGY, František - LABÁT, Dušan - BACHORÍK, Oliver - PRIŠTIAK, Ján - MÄSIAR, Jozef - DUCHOŇ, František - BABINEC, Andrej - DEKAN, Martin - CHOVANEC, Ľuboš - TREBUĽA, Marek - KOHÚT, Miroslav - DOBIŠ, Michal. *Robotický systém na adaptívne spájanie súčastí : Prihláška patentu č. 25-2021, Dátum o zápise : 28.7.2021, Vestník ÚPV SR č. 14/2021*. Banská Bystrica : Úrad priemyselného vlastníctva SR, 2021. 9 s. Dostupné na internete: <<https://wbr.indprop.gov.sk/WebRegistre/Patent/Detail/25-2021>>.

TREBUĽA, Marek - ČIERNY, Lukáš - DEKAN, Martin - DUCHOŇ, František - KOVARÍKOVÁ, Zuzana - NAGY, František - PRIŠTIAK, Ján. *Spôsob kontroly stavu hrotu zvaracej elektródy a systém na jeho realizáciu : prihláška úžitkového vzoru č. 192-2023, dátum podania prihlášky: 14.11.2023, dátum zverejnenia prihlášky: 09.05.2024, Vestník ÚPV SR č.: 9/2024*. Banská Bystrica : Úrad priemyselného vlastníctva SR, 2024. 7 s. Dostupné na internete:

<<https://wbr.indprop.gov.sk/WebRegistre/UzitkovyVzor/Detail/192-2023?csrt=5767094610932822981>>.

TREBUĽA, Marek - ČIERNY, Lukáš - DEKAN, Martin - DUCHOŇ, František - KOVARÍKOVÁ, Zuzana - NAGY, František - PRIŠTIAK, Ján. *Spôsob kontroly stavu hrotu zváracej elektródy a systém na jeho realizáciu : Úžitkový vzor č. 10120, prihláška úžitkového vzoru č. 192-2023, dátum zápisu: 14.08.2024, dátum oznámenia o sprístupnení dokumentu: 28. 8. 2024, Vestník ÚPV SR č.: 16/2024*. Banská Bystrica : Úrad priemyselného vlastníctva SR, 2024. 7 s. Dostupné na internete: <<https://wbr.indprop.gov.sk/WebRegistre/UzitkovyVzor/Detail/192-2023?csrt=5767094610932822981>>.