

# VYUŽITÍ NEURONOVÉ SÍTĚ PRO IDENTIFIKACI POLOHY OBJEKTU V PROSTORU

Kolář Martin

Sekce – STROJÍRENSTVÍ

Fakulta strojní, 2. ročník

Magisterský studijní program – APLIKOVANÁ MECHANIKA

**Abstrakt:** Přenos pohybových dovedností zkušeného svářeče na průmyslového robota vyžaduje spolehlivý záznam polohy a orientace svařovací pistole při reálném svařovacím procesu. Optický motion capture, HSV segmentace barevných markerů i inerciální senzory selhávají v prostředí aktivního oblouku MIG/MAG. Navrhujeme systém tří průmyslových kamer detekujících barevné markery na pistoli pomocí neuronové sítě U-Net s heatmapovou regresí, trénované na synteticky generovaných datech s reálnými svařovacími pozadími. Finální model dosáhl střední chyby detekce  $\bar{d} = 0,43$  px (98,7 % predikcí pod 1,5 px) a na reálných snímcích z aktivního oblouku průměrné jistoty  $\bar{\kappa} = 0,969$  bez jediného výpadku. Prostorová poloha pistole je rekonstruována trojkamerovou triangulací s následnou filtrací Savitzky-Golay. Linearita rekonstruované trajektorie dosahuje  $R^2 = 1,000$  s RMS residuem  $r_{\text{RMS}} = 0,14$  až 0,46 mm.

**Klíčová slova:** svařovací pistole, sledování polohy, U-Net, heatmapová regrese, syntetická trénovací data, trojkamerová triangulace, MIG/MAG

## 1 Motivace a cíl práce

Kvalita obloukového svaru závisí na kinematických parametrech, jimiž svářeč vede pistoli: vzdálenosti kontaktní špičky od základního materiálu (CTWD), příčném a podélném úhlu pistole vůči svařovacímu spoji a rychlosti pohybu podél svaru [1]. Zkušený svářeč tyto parametry průběžně přizpůsobuje na základě vizuální zpětné vazby ze svařovací lázně, přičemž velká část jeho pohybové strategie je implicitní a verbálně nepopsatelná. Přenos dovedností přímo ze záznamu pohybů zkušeného svářeče na průmyslového robota (koncept *Programming by Demonstration*) [2] tento problém obchází, vyžaduje však spolehlivé zachycení polohy a orientace pistole po celou dobu svařovacího procesu.

Dostupné metody tuto podmínku při reálném svařování nespĺňují. Průmyslové systémy optického motion capture jsou přesycovány zářením oblouku, klasická segmentace barevných markerů v prostoru HSV selhává při dramatických změnách světelných podmínek v okolí svarové lázně [3] a inerciální senzory trpí kumulativním driftem a elektromagnetickým rušením oblouku. Systémy hardwarovou koncepcí nejbližší navrhovanému řešení provádějí záznam výhradně bez přítomnosti aktivního oblouku [4], čímž nezachycují reaktivní složku pohybové strategie podmíněnou zpětnou vazbou z chování svařovací lázně.

Tato práce popisuje systém umožňující sledování svařovací pistole při reálném procesu MIG/MAG. Systém kombinuje trojici průmyslových kamer, detekci barevných markerů neuronovou sítí U-Net [5] a geometrickou triangulaci pro 3D rekonstrukci polohy a orientace pistole. Příspěvek popisuje princip detekce markerů, postup generování trénovacích dat, vývoj detekční sítě a výsledky prostorové rekonstrukce.

## 2 Návrh a implementace systému

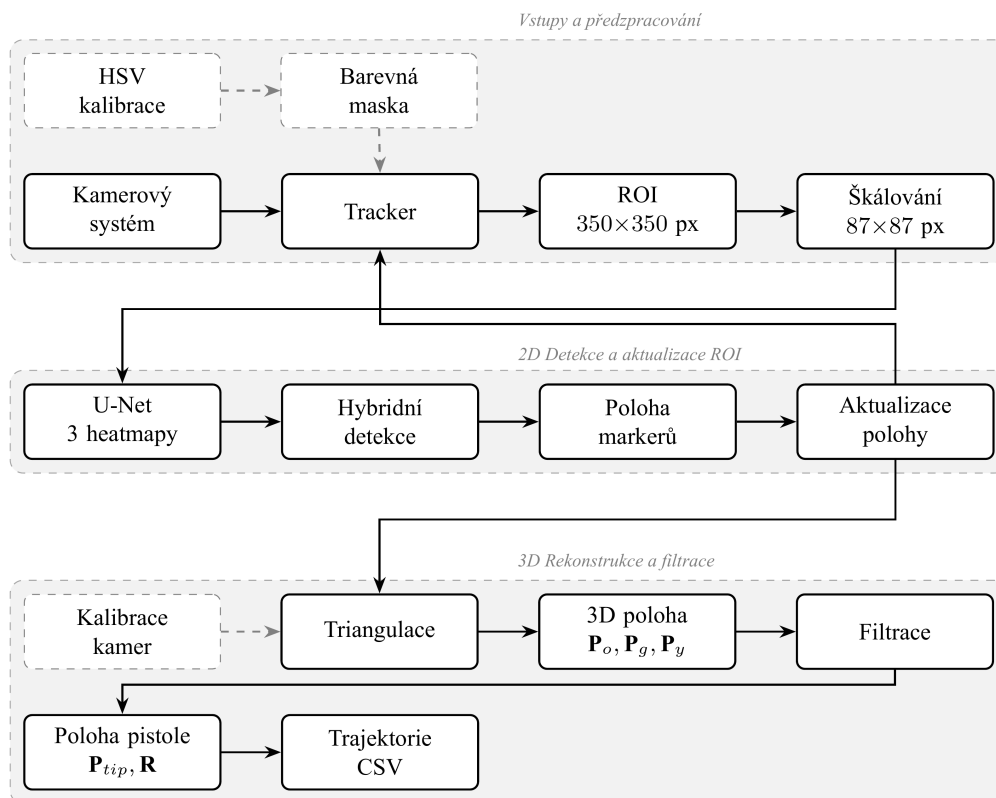
### 2.1 Přehled architektury systému

Navržený systém sestává ze tří funkčních bloků znázorněných na obr. 1.

První blok zajišťuje sběr a předzpracování obrazových dat. Trojice průmyslových kamer snímá pracovní prostor svařovacího stolu. Modul Tracker průběžně udržuje oblast zájmu (ROI) o velikosti  $350 \times 350$  px vystředěnou na sestavu pistole s markery. Inicializace polohy ROI vychází z HSV kalibrace, která poskytuje hrubou barevnou masku pro první lokalizaci markerů. Výřez ROI je před vstupem do neuronové sítě převzorkován na  $87 \times 87$  px.

Druhý blok realizuje 2D detekci markerů. Síť U-Net produkuje tři heatmaps odpovídající markerům O, G a Y, z nichž hybridní detektor extrahuje souřadnice markerů s sub-pixelovou přesností a jistotou  $\kappa_k$ . Výstupní polohy jsou zpětnou vazbou předány modulu Tracker k aktualizaci polohy ROI pro následující snímek.


Třetí blok provádí 3D rekonstrukci a filtraci trajektorie. Kalibrovaný trojkamerový systém trianguluje prostorové polohy markerů  $\mathbf{P}_O$ ,  $\mathbf{P}_G$ ,  $\mathbf{P}_Y$ , filtruje výslednou trajektorii Savitzky-Golay filtrem a z filtrovaných poloh odvozuje úplnou prostorovou polohu pistole: polohu špičky elektrody  $\mathbf{P}_{tip}$  a orientační matici  $\mathbf{R} \in SO(3)$ . Výstupem systému je soubor CSV s časovou řadou poloh pistole určenou pro přenos trajektorie do řídicího systému průmyslového robota.



Obrázek 1: Schéma architektury sledovacího systému. Horní blok (vstupy a předzpracování) zajišťuje sběr obrazu a správu ROI. Střední blok (2D detekce) realizuje lokalizaci markerů sítí U-Net s hybridním detektorem a zpětnou aktualizací ROI. Dolní blok (3D rekonstrukce a filtrace) provádí triangulaci, filtraci trajektorie a výpočet prostorové polohy pistole ( $\mathbf{P}_{tip}$ ,  $\mathbf{R}$ ).

## 2.2 Hardwarová konfigurace a markery


Sledovací stanice (obr. 2) tvoří trojice průmyslových kamer (C1, C2, C3) rozmístěných nad pracovním prostorem tak, aby každá kamera snímala sestavu pistole z odlišného úhlu. Kamery jsou doplněny LED osvětlením o výkonu 200 W pro stabilizaci expozice při proměnlivé záři oblouku. Globální souřadnicový systém je definován rohovou polohou referenčního ArUco markeru na kalibrační desce (podkapitola 4.1). Na svařovací pistoli je pevně uchycen rigidní držák se třemi barevnými markery: oranžovým (O), zeleným (G) a žlutým (Y). Barvy byly zvoleny pro maximální kontrast vůči záření svařovacího oblouku. Modrý marker byl při ověřování na reálných datech vyřazen jako nedostatečně kontrastní.



Obrázek 2: Sledovací stanice s trojicí průmyslových kamer (C1, C2, C3), LED osvětlením a svařovacím agregátem. Detail vlevo nahoře: kamerová sestava s LED světlem. Detail vlevo dole: sestava pistole s barevnými markery O, G, Y uchycenými na držáku. Detail vpravo: elektrorozvaděč a ovládací panel.


### 2.3 Detekce markerů: heatmapová regrese U-Net

Z každé kamery je vyříznut výřez oblasti zájmu o rozměrech  $350 \times 350$  px, který je převzorkován na vstupní rozlišení  $87 \times 87$  px. Poloha každého markeru je zakódována jako dvourozměrná heatmapa  $G(u, v)$ : Gaussovo rozdělení se středem v pozici markeru a rozptylem  $\sigma = 3,0$  px (obr. 3). Výsledné souřadnice markeru jsou extrahovány jako těžiště heatmapy (hybridní detekce), čímž je dosaženo sub-pixelové přesnosti bez explicitní regrese souřadnic.



Obrázek 3: Příklad cílové heatmapy  $G(u, v)$  generované jako 2D Gaussovo rozdělení se středem v poloze detekovaného markeru. Barevná škála přechází od černé (hodnota 0) přes červenou k bílé (hodnota 1). Marginální průřezy  $G(u)$  (dole) a  $G(v)$  (vlevo) ilustrují symetrický Gaussův profil v obou osách.

Výřez je předán neuronové síti architektury U-Net [5] (obr. 4), která na výstupu generuje tři heatmapy odpovídající markerům O, G a Y. Jistota detekce  $\kappa_k$  je definována jako maximální hodnota normalizované výstupní heatmapy markeru  $k$  a slouží k identifikaci snímků s nízkou spolehlivostí detekce.



Obrázek 4: Schéma architektury U-Net pro detekci barevných markerů. Kontrakční cesta (encoder, vlevo) sestává ze tří úrovní konvolučních bloků s max poolingem, počet příznaků se s každou úrovní zdvojuje ( $N_f \rightarrow 2N_f \rightarrow 4N_f$ ). Bottleneck (střed) dosahuje maximální sémantické hloubky při nejmenším prostorovém rozlišení ( $8N_f$ ). Expandující cesta (decoder, vpravo) obnovuje rozlišení bilineárním upsamplingem se skip connections z encoderu (modré šipky). Výstupní vrstva produkuje tři heatmapy  $87 \times 87$  px.

## 2.4 Generování syntetických trénovacích dat

Ruční anotace heatmap je časově náročná a při aktivním oblouku prakticky nerealizovatelná. Trénovací data proto generujeme procedurálním kompozitováním: fotografie reálných markerů (O, G, Y) vyříznuté ze svařovacích záznamů jsou alfa-blendingem vkládány na náhodné pozice do snímků zachycujících reálné pracovní prostředí s aktivním obloukem (obr. 5). Pozice markerů jsou generovány v trojúhelníkovém uspořádání odpovídajícím fyzickému držáku na pistoli s náhodnou variací vzdáleností a úhlů. Augmentace zahrnuje škálování, rotaci a multiplikativní úpravu jasu markerů.

Klíčovým aspektem návrhu je minimalizace domain gapu, tedy rozdílu mezi distribucí syntetických trénovacích dat a snímků pořízených při reálném svařování [6]. Protože pozadí každého trénovacího snímku pochází přímo ze svařovacích záznamů, obsahuje záři oblouku, rozstřík a kouř typické pro provozní podmínky. Sít tak získává zkušenost s reálnými optickými podmínkami bez nutnosti ruční anotace a zároveň je ground truth poloha každého markeru známa s přesností na pixel. Celkem bylo vygenerováno 170 000 snímků:  $N_{\text{train}} = 100\,000$ ,  $N_{\text{val}} = 60\,000$ ,  $N_{\text{test}} = 10\,000$ .



Obrázek 5: Ukázky synteticky generovaných trénovacích snímků ( $350 \times 350$  px). Markery jsou kompozitovány na reálné pozadí se svařovacím obloukem.

## 2.5 Výpočet prostorové polohy pistole

Z triangulovaných poloh tří markerů  $\mathbf{P}_O$ ,  $\mathbf{P}_G$ ,  $\mathbf{P}_Y$  sestavujeme lokální souřadnicový systém pevně spojený s pistolí (obr. 6). Počátek souřadnicového systému  $\mathbf{O}$  leží ve středu úsečky mezi oranžovým a zeleným markerem. Osy lokálního systému jsou definovány:

$$\mathbf{e}_x = \frac{\mathbf{P}_G - \mathbf{P}_O}{\|\mathbf{P}_G - \mathbf{P}_O\|}, \quad (1)$$

$$\mathbf{e}_z = \frac{\mathbf{e}_x \times (\mathbf{P}_Y - \mathbf{O})}{\|\mathbf{e}_x \times (\mathbf{P}_Y - \mathbf{O})\|}, \quad (2)$$

$$\mathbf{e}_y = \mathbf{e}_z \times \mathbf{e}_x. \quad (3)$$


Rotační matice orientace pistole vůči globálnímu souřadnicovému systému je tvořena sloupcovým seskupením tří os [7]:

$$\mathbf{R} = [\mathbf{e}_x \mid \mathbf{e}_y \mid \mathbf{e}_z] \in SO(3). \quad (4)$$

Poloha špičky elektrody  $\mathbf{P}_{\text{tip}}$  (TCP) je vypočítána transformací geometrického vektoru  $\mathbf{t}_{\text{lok}} = [0, L_{\text{tip}}, -H_{\text{drop}}]^T$  do globálního souřadnicového systému:

$$\mathbf{P}_{\text{tip}} = \mathbf{O} + \mathbf{R} \mathbf{t}_{\text{lok}}, \quad (5)$$

kde  $L_{\text{tip}}$  je vzdálenost špičky od počátku podél osy pistole a  $H_{\text{drop}}$  svislý pokles špičky od roviny držáku. Orientaci  $\mathbf{R}$  lze exportovat jako Eulerovy úhly, kvaternion nebo rotační vektor podle formátu řídicího systému cílového robota.



Obrázek 6: Vlevo: lokální souřadnicový systém pistole s počátkem  $\mathbf{O}$  ve středu úsečky O-G a osami  $\mathbf{e}_x$ ,  $\mathbf{e}_y$ ,  $\mathbf{e}_z$  sestavenými z prostorových poloh tří markerů. Vpravo: geometrie vektoru  $\mathbf{t}_{\text{lok}} = [0, L_{\text{tip}}, -H_{\text{drop}}]^T$  popisujícího polohu špičky elektrody v lokálním souřadnicovém systému.

### 3 Vývoj detekční sítě

#### 3.1 Evoluce architektury

Vývoj detekční sítě probíhal ve čtyřech fázích shrnutých v tabulce 1. Výchozím bodem byla plně propojená síť (Dense NN) s přímou regresí souřadnic šesti výstupními neurony, která na syntetických datech dosáhla  $e_{\text{abs}} \approx 502$  px. Nahrazení hustých vrstev konvolučními bloky s batch normalizací přineslo řádové zlepšení: nejlepší konvoluční model (ID<sub>C</sub> 05, dataset Panda3D s reálnými svařovacími pozadími) dosáhl  $\bar{d}_p = 5,24$  px. Přidání residuálních spojení a zmenšení vstupního rozlišení na  $87 \times 87$  px snížilo chybu na  $\bar{d} = 4,27$  px, přičemž výsledek zůstal výrazně nad cílovou přesností 2,0 px.

Analýza selhání přímé regrese souřadnic ukázala, že globálním průměrovým poolingem dochází k nenávratné ztrátě prostorové informace: síť při překrytí dvou markerů nemá k dispozici informaci o jejich vzájemné poloze. Přejít na heatmapovou regresi tento problém odstraňuje. Síť U-Net [5] generuje pro každý marker samostatnou dvourozměrnou heatmapu, z níž je poloha extrahována jako těžiště s sub-pixelovou přesností [8]. Finální model (ID<sub>S</sub> 06,  $8N_f$  základních filtrů,  $N_{\text{train}} = 100\,000$ ) dosáhl střední chyby  $\bar{d} = 0,43$  px s 98,7 % predikcí pod prahem 1,5 px.

Tabulka 1: Srovnání vývoje architektur detekční sítě. Fáze 1 je hodnocena průměrnou absolutní chybou souřadnic  $e_{\text{abs}}$ , fáze 2–4 průměrnou euklidovskou vzdáleností detekované a referenční polohy markeru  $\bar{d}$  na testovací sadě  $n = 10\,000$  snímků (fáze 2:  $n = 6\,000$ ). Markery O, G, B (fáze 1–2a). O, G, Y a dataset Panda3D + reálné svařování (fáze 2b–4).


Fáze	Architektura	Výstup	Vstup [px]	Přesnost [px]	$\bar{d} < 1,5$ px [%]
1	Dense NN	souřadnice	$350 \times 350$	$e_{\text{abs}} \approx 502^\dagger$	—
2	CNN (ID <sub>C</sub> 05)	souřadnice	$350 \times 350$	$\bar{d} = 5,24$	— <sup>‡</sup>
3	CNN + residuální bloky	souřadnice	$87 \times 87$	$\bar{d} = 4,27$	—
4	U-Net (ID <sub>S</sub> 06)	heatmapy	$87 \times 87$	$\bar{d} = 0,43$	98,7

<sup>†</sup> Metrika  $e_{\text{abs}}$  (střední absolutní chyba souřadnic) není srovnatelná s euklidovskou vzdáleností  $\bar{d}$  používanou ve fázích 2–4.

<sup>‡</sup> CNN hodnocena prahem  $\bar{d}_p < 10$  px: 95,2 % predikcí pod prahem.

### 3.2 Distribuce chyby predikce finálního modelu


Distribuce chyby detekce na testovací sadě ( $n = 10\,000$  snímků) je zobrazena na obr. 7. Medián chyby činí 0,20 px a 95. percentil nepřesahuje 1,5 px. Zbývajících 1,3 % predikcí s chybou nad 1,5 px odpovídá výhradně snímkům se vzájemným překrytím markerů, při němž je přímá detekce zakrytého markeru principiálně znemožněna.



Obrázek 7: Distribuce průměrné euklidovské chyby detekce markeru finálního modelu U-Net (ID<sub>S</sub> 06) na testovací sadě ( $n = 10\,000$  snímků). Průměr  $\bar{d} = 0,43$  px, medián 0,20 px, 98,7 % predikcí pod 1,5 px.

### 3.3 Detekce na reálných datech ze svařování

Přenositelnost modelu na reálné podmínky jsme ověřili na dvou sadách snímků pořízených při aktivním svařovacím oblouku MIG/MAG bez přeučení sítě. Model byl trénován výhradně na syntetických datech. Jistota detekce  $\kappa_k$  zůstala na sadě 520 snímků u všech tří markerů nad hodnotou 0,93 po celou sekvenci bez jediného výpadku, průměrná jistota činila  $\bar{\kappa} = 0,969$ . Výstupní heatmapy finálního modelu pro reprezentativní snímky ze svařování jsou zobrazeny na obrázku 8.




Obrázek 8: Výstup U-Net modelu na reálných snímcích z aktivního svařovacího oblouku MIG/MAG: vstupní výřez  $87 \times 87$  px (vlevo), výstupní heatmapa (uprostřed) a překryv se vstupem (vpravo).

## 4 Kalibrace a 3D rekonstrukce trajektorie

### 4.1 Kalibrace kamerového systému

Přesnost prostorové rekonstrukce závisí na přesné znalosti geometrie kamerového systému. Kalibrace určuje pro každou kameru sedm parametrů: prostorovou polohu optického středu, tři korekce orientace optické osy a ohniskovou vzdálenost. Jako kalibrační terč jsme použili hliníkovou desku o rozměrech  $800 \times 600$  mm s 48 ArUco [9] markery uspořádanými do pravidelné mřížky s roztečí 100 mm (obr. 9). Kalibraci jsme provedli ve třech výškových rovinách ( $z_1 = 16,0$  mm,  $z_2 = 60,4$  mm,  $z_3 = 110,3$  mm), čímž jsme pro každou kameru získali až  $3 \times 48 = 144$  kalibračních bodů. Parametry kamerového modelu byly optimalizovány minimalizací reprojekční chyby metodou nelineárních nejmenších čtverců.



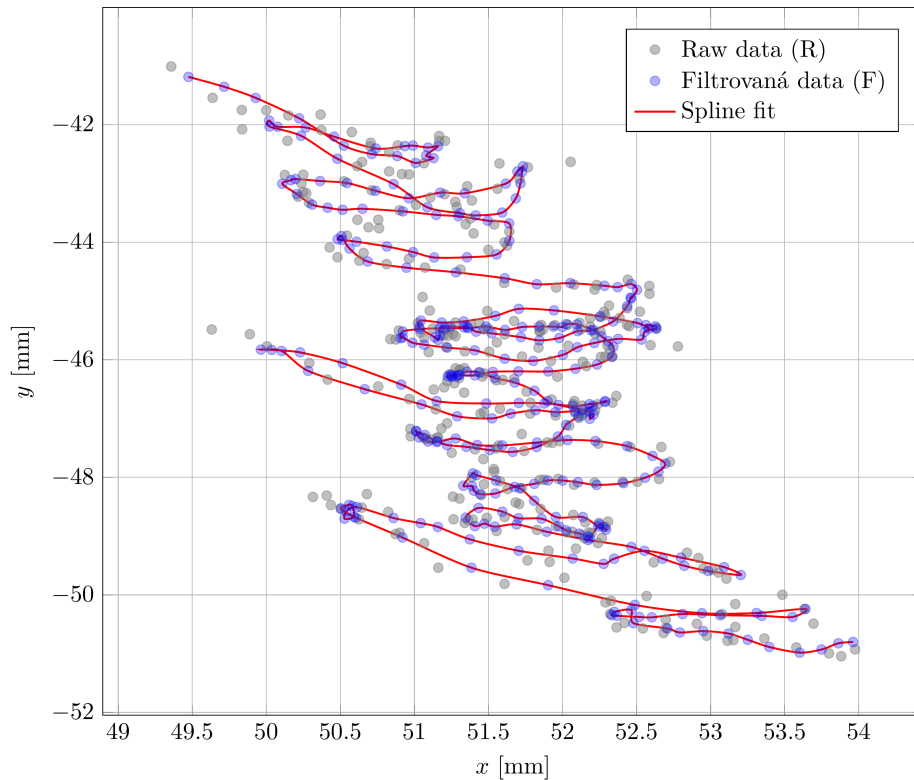
Obrázek 9: Kalibrační deska s ArUco markery umístěná na svařovacím stole. Vyznačeny jsou osy globálního souřadnicového systému ( $x$ ,  $y$ ,  $z$ ) s počátkem v rohu referenčního ArUco markeru.

### 4.2 Výsledky triangulace a filtrace trajektorie

Přesnost trojkamerové rekonstrukce jsme ověřili na sadě laboratorních záznamů zahrnujících tři typy pohybu: lineární přejezdy, periodický pohyb s obloukovým vzorem (housenky) a trojúhelníkový vzor. Záznamy byly pořízeny bez přítomnosti svařovacího oblouku za jinak totožných prostorových podmínek. Surová trajektorie byla filtrována Savitzky-Golay filtrem (polynom třetího řádu) [10].

Lineární přejezdy posloužily jako geometricky ověřitelný referenční scénář. Koeficient determinace linearity dosáhl  $R^2 = 1,000$  pro každý marker ve všech pěti záznamech. RMS residuum od nejlépe proložené přímky kleslo filtrace ( $L_w = 20$ ) na  $r_{\text{RMS}} = 0,14$  až  $0,46$  mm. Konzistence rigidního tělesa po filtraci dosáhla STD vzdáleností markerů  $0,14$  až  $0,47$  mm, přičemž filtrace snížila STD o 5 až 49 % v závislosti na záznamu a páru markerů.

Pro periodické pohyby jsme systematicky srovnali pět šířek okna  $L_w \in \{5, 9, 11, 13, 20\}$ . Okno  $L_w = 11$  představuje optimální kompromis: potlačení šumu v pásmu 4 až 10 Hz faktorem  $3,9$  až  $4,1 \times$  při zachování pohybového pásma 0 až 3 Hz v poměru  $1,00$  až  $1,01 \times$  a délky trajektorie záznamu housenky na 85 %. Vizualní výsledek filtrace je zobrazen na obr. 10. Ve všech analyzovaných záznamech nevykazoval žádný marker výpadky detekce (podíl NaN snímků 0,0 %).



Obrázek 10: Výřez 2D trajektorie držáku záznamu housenky v rovině  $xy$  před filtrací (R, světlé body) a po filtraci (F, modré body) s aproximací spline křivkou (červená čára),  $L_w = 11$ ,  $p_w = 3$ . Zobrazený úsek pokrývá oblast přibližně  $4,5 \times 10$  mm z celkové délky dráhy  $d_H^{\text{raw}} = 106,2$  mm.

## 5 Závěr

Navrhli jsme systém pro sledování svařovací pistole při reálném procesu MIG/MAG, který kombinuje trojici průmyslových kamer, detekci barevných markerů neuronovou sítí U-Net a trojkamerovou triangulaci. Systém pracuje za přítomnosti aktivního svařovacího oblouku bez speciálního filtrování nebo stínění, čímž překlenuje mezeru identifikovanou u dosavadních přístupů.

Finální model U-Net (ID<sub>S</sub> 06) dosáhl na testovací sadě 10 000 syntetických snímků střední chyby detekce  $\bar{d} = 0,43$  px s 98,7 % predikcí pod prahem 1,5 px. Na reálných snímcích z aktivního oblouku model pracoval bez přeučení s průměrnou jistotou  $\bar{\kappa} = 0,943$  a  $\bar{\kappa} = 0,969$  na dvou nezávislých sadách a bez jediného výpadku detekce. RMS residuum linearity rekonstruované trajektorie po filtraci Savitzky-Golay ( $L_w = 11$ ) nepřesáhlo  $r_{\text{RMS}} = 0,46$  mm ( $R^2 = 1,000$ ).

Z trojice prostorových poloh markerů systém odvozuje úplnou prostorovou polohu pistole: polohu špičky elektrody a orientaci ve formě rotační matice  $\mathbf{R} \in SO(3)$ , převoditelné do Eulerových úhlů nebo kvaternionů. Získaná data poskytují základ pro extrakci kinematických parametrů svařovacího procesu (CTWD, úhly pistole, rychlost pohybu) a jejich využití při programování průmyslových robotů metodou Programming by Demonstration v rámci projektu Weld Track.

## Literatura

- [1] YAO, Ping et al. Influence of Inclination of Welding Torch on Weld Bead during Pulsed-GMAW Process. *Materials*. 2020, **13**(11), 2652. ISSN 1996-1944. Dostupné z: <https://doi.org/10.3390/ma13112652>.
- [2] PAN, Zengxi et al. Recent progress on programming methods for industrial robots. *Robotics and Computer-Integrated Manufacturing*. 2012, **28**(2), 87–94. ISSN 0736-5845. Dostupné z: <https://doi.org/10.1016/j.rcim.2011.08.004>.
- [3] LI, Jiajun, Tianlun WANG a Wei WEI. YOLO–LaserGalvo: A Vision–Laser-Ranging System for High-Precision Welding Torch Localization. *Sensors*. 2025, **25**(20), 6279. ISSN 1424-8220. Dostupné z: <https://doi.org/10.3390/s25206279>.
- [4] DE SOUZA, René et al. Industrial robot programming by demonstration using stereoscopic vision and inertial sensing. *Industrial Robot*. 2022, **49**(1), 96–107. ISSN 0143-991X. Dostupné z: <https://doi.org/10.1108/IR-02-2021-0043>.
- [5] RONNEBERGER, Olaf, Philipp FISCHER a Thomas BROX. U-Net: Convolutional Networks for Biomedical Image Segmentation [online]. 2015 [cit. 2026-02-17]. Dostupné z: <https://doi.org/10.48550/arXiv.1505.04597>.
- [6] TOBIN, Josh et al. Domain Randomization for Transferring Deep Neural Networks from Simulation to the Real World [online]. 2017 [cit. 2026-04-04]. Dostupné z: <https://doi.org/10.48550/arXiv.1703.06907>.
- [7] CRAIG, John J. *Introduction to Robotics: Mechanics and Control*. 3rd ed. Upper Saddle River, N.J.: Pearson/Prentice Hall, 2005. ISBN 0-201-54361-3.
- [8] ZHANG, Feng et al. Distribution-Aware Coordinate Representation for Human Pose Estimation [online]. 2019 [cit. 2026-03-22]. Dostupné z: <https://doi.org/10.48550/arXiv.1910.06278>.
- [9] GARRIDO-JURADO, S. et al. Automatic generation and detection of highly reliable fiducial markers under occlusion. *Pattern Recognition*. 2014, **47**(6), 2280–2292. ISSN 0031-3203. Dostupné z: <https://doi.org/10.1016/j.patcog.2014.01.005>.
- [10] SAVITZKY, Abraham a Marcel J.E. GOLAY. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical Chemistry*. 1964, **36**(8), 1627–1639. ISSN 0003-2700. Dostupné z: <https://doi.org/10.1021/ac60214a047>.