

Spojení rozšířené reality a umělé inteligence pro podporu kontroly kvality svařování

Kristýna Havlíková

Západočeská univerzita v Plzni, Fakulta strojní, Katedra průmyslového inženýrství a managementu
Univerzitní 8, 306 14, Plzeň, Česká republika
khavliko@kpv.zcu.cz

Anotace: Rozšířená realita i umělá inteligence patří mezi hlavní dynamicky se rozvíjející technologie čtvrté průmyslové revoluce. Kontrolní operace jsou klíčové operace v průmyslovém prostředí, které vyžadují vysokou míru koncentrace a představují velkou psychickou zátěž na pracovníka. Na základě rešerše dosavadních přístupů byl vytvořen nový efektivní asistenční systém AR, který je schopen rozpoznat kontrolovaný díl, interaktivně podpořit proces kontroly a tím efektivně zvýšit výkonnost pracovníků a zároveň snížit kognitivní i fyzickou zátěž na pracovníka. V textu jsou představena teoretická východiska projektu a konkrétní návrh aplikace v prostředí Unity. Cílem dalšího projektu je provedení testování aplikace na vzorku uživatelů a vyhodnocení využitelnosti navrženého přístupu.

1 Úvod

Průmyslová odvětví dnes čelí nedostatku kvalifikované pracovní síly a zároveň stárnutí zkušených odborných pracovníků. Tento trend může vést až ke ztrátě znalostí. Technologie rozšířené reality však může propojit pracovníky ve výrobě přímo se zkušenými experty nebo jim interaktivně zprostředkovat důležité znalosti k vytváření rozhodnutí. Další výhodou je fakt, že informace získané pomocí technologie AR je možné v budoucnu využít jako nashromážděné znalosti, které usnadňují rozhodování v podnikových procesech. Díky AR mohou zaměstnanci získávat zkušenosti a dovednosti mnohem rychleji.

AR může sloužit jako efektivní nástroj ke snížení nákladů a zvýšení efektivity během výrobních fází PLM. Jedná se o technologii s potenciálem snížení kognitivní zátěže na pracovníky, která jim ve správném čase může poskytnout správné informace ve správné podobě bez narušování pozornosti uživatele.

Velký potenciál má AR aplikace v oblasti kontroly kvality, konkrétně se tato práce zaměřuje na kontrolu operace svařování. Za účelem zkrácení kontrolního času a snížení chybovosti při kontrole kvality na svařovně je představen inteligentní systém složený z instrukcí a kontrolního checklistu v prostředí rozšířené reality s podporou principů deep learning pro detekci kontrolovaných dílů. AR aplikace je navržena tak, aby poskytovala důležité

informace inspektorovi nebo operátorovi na svařovacím pracovišti. Datová sada je generována pomocí CAD modelů.

Na základě dostupných přístupů byl vytvořen nový asistenční systém AR, který je schopen rozpoznat kontrolovaný díl, interaktivně podpořit proces kontroly a tím efektivně zvýšit výkonnost pracovníků.

2 Aplikace AR a AI v průmyslovém prostředí

Přestože realita nemůže být nijak upravena, její vnímání může být do určité míry doplněno nebo vylepšeno. AR je rozhraní mezi realitou a vnímáním reality. Jako nástroj, který překrývá digitální informace do reálného světa tak zprostředkovává spojení mezi reálným a virtuálním světem. AR umožňuje přenos informací a jejich asimilaci s lidským operátorem. Pokud je správně implementována, AR se prokázala jako nedocenitelný interaktivní prostředek, který může sloužit k redukci kognitivní zátěže na pracovníky vyplněním mezery mezi aktuálním úkonem na pracovišti a potřebnými relevantními informacemi zobrazením těchto informací do zorného pole uživatele bez přerušení jeho pozornosti. AR použití je velmi užitečné ve výrobním prostředí, kde je třeba co nejefektivněji provádět různorodé úkoly, jako je montáž nebo údržba.

Rozšířená realita kombinuje vizuální obraz reálného světa s vizuálními objekty. K dosažení realistických výsledků musí být řešeny složité “computer vision” úkoly jako jsou detekce a tracking reálných 3D objektů a odhadování světelných podmínek dané scény. Jedním ze způsobů, jak tento úkol řešit s relativně vysokou přesností a spolehlivostí je například metoda umělé inteligence Deep Learning.

V první části textu je stručně představena problematika rozšířené reality a potenciál jejího spojení s umělou inteligencí pro využití v průmyslových aplikacích.

2.1 AR jako nástroj pro podporu kvality

Vývoj průmyslu 4.0 vedl k rozvoji nových průmyslových technologií a také k fyzické přeměně průmyslového prostředí díky integraci nových nástrojů a technik pro podporu výrobní efektivity, zlepšování kvality a snižování výrobních nákladů.[1] Tato technologická transformace bude mít pravděpodobně znatelný dopad na způsob provedení pracovní činnosti v průmyslovém prostředí, jelikož budou vnikat nové interakce mezi člověkem a strojem a zároveň mezi digitálním a reálným světem. Romero [2] shrnuje, že v tomto kontextu je pracovník chápán jako kvalifikovaný a zkušený operátor, jehož fyzické, smyslové a kognitivní schopnosti jsou podpořeny a vylepšeny s použitím nových systémů, strojů nebo nástrojů založených na pokročilých interaktivních technologiích člověk-stroj.[2]

Mezi tyto rozvíjející se technologie patří právě rozšířená realita, která nabízí možnost přenosu informace z digitálního do reálného světa k operátorovi. AR

umožňuje podporu pracovníků přímo na pracovišti během vykonávání pracovního úkolu díky možnosti propojení virtuální informace přímo do zorného pole operátora. Díky tomu je možné snížit riziko lidské chyby, omezit závislost na paměti pracovníka nebo na pracovních návodkách a nutnosti interpretovat složitou technickou dokumentaci kvalifikovaným technikem. [2]

AR je možné definovat jako technologii interakce člověk – počítač, která interaktivně registruje 3D reálné a virtuální objekty v reálném čase [3]. Ačkoliv termín „Rozšířená realita“ byl poprvé použit Thomasem a Davidem v roce 1992, první aplikace AR technologie je možné vysledovat až do roku 1968, kdy byl poprvé použit Head-mounted Display (HMD). [4]

Na základě rešerše dostupných projektů je možné shrnout, že během posledních několika let bylo publikována řada různých systémů využívajících rozšířenou realitu jako nástroj pro podporu pracovníků v průmyslovém prostředí. Zejména se jedná o odvětví montáž, školení, údržba a kontrola.

Kontrolní aktivity zpravidla představují sérii kontrolních úkonů, které musejí být provedeny na reálném produktu s cílem identifikovat odchylku reálného stavu od návrhu. Jedná se proto o jednu z nejzásadnějších aktivit v rámci strojírenské výroby. Kontrolní operace vyžadují vysokou míru koncentrace a představují velkou psychickou zátěž na pracovníka. Ten musí svou pozornost dělit mezi reálný produkt a konstrukční a technické podklady, podle kterých díl kontroluje a posuzuje. Zpravidla je tento úkol prováděn manuálně operátorem s pomocí klasické tištěné papírové technické dokumentace. Kontrolní operace provádějí běžně především kvalifikovaní pracovníci, výsledné posouzení je značně subjektivní a závislé na zkušenostech a znalostech pracovníka. [5]

S ohledem na uvedené charakteristiky má navrhovaný AR nástroj podporovat operátory přímo na pracovním stanovišti během kontrolních operací pro snazší identifikaci chyby a zároveň snížit kognitivní i fyzickou zátěž na pracovníka. Díky použití 3D modelu a nadefinování technických informací k němu může být s pomocí rozšířené reality jednodušší najít případnou chybu a kontrolní operaci tak mohou provádět i pracovníci s méně zkušenostmi a bez nutnosti velmi dobré znalosti technických podkladů. Touto problematikou se zabývali například Barbieri a Marino [6].

Přestože je rozšířená realita označovaná za rozvíjející se technologii, která má zatím řadu ergonomických a technických překážek pro širší využití v praxi, její veliký potenciál je uznávaný už řadu let, jak popisují například Egger a Masood [7]. AR popisují autoři jako metodu vhodnou k podpoře operátorů během vykonávání vnitropodnikových aktivit díky přenosu odborných znalostí k operátorům a tím zvyšování produktivity, snižování chybovosti bez odvádění pozornosti. Rozvinutá podpora a sledování výrobních procesů tak může dlouhodobě zvyšovat kvalitu výroby, lépe odhalovat poruchy strojů a zařízení a obecně tak dlouhodobě snižovat náklady a šetřit čas výrobních a podpůrných operací. Barreiro a kol. [8] v tomto kontextu popsali užitečnost AR vizualizace při sledování stavu zařízení poskytováním relevantních informací uživatelům s HMD systémy. Kranzer a kol. [9] navrhli inteligentní systém

plánování údržby založený na AR technologii, který má podporovat pracovníka během proces provádění údržby.

Jednou z oblastí, která začíná stále více odhalovat možnosti rozšířené reality jsou právě kontrolní aktivity. Leutert and Schilling [10] popisovali systém vzdáleného monitorování a kontroly průmyslových robotů. Sauer a kol. [11] zkoumali možnosti při podpoře montáže a kontroly smontovaných strojních komponent. Jayaweera a kol. [12] se zabývali údržbou strojů a s ní spojenými kontrolními úkony zobrazováním historických a současných dat kontrolovaných strojů. Antonelli a Astanin [13] navrhli nástroj pro kontrolu bodového svařování strojních součástí s pomocí tabletu namontovaného na svařovací pistolí pro vizualizaci užitečných informací ke správnému provedení dané operace. Podobně Ashish a kol. [14] využili AR principy k zobrazení virtuálních informací na automobilové součástky zvýrazňující oblasti bodového svařování.

Z hlediska porovnávání reálného produktu a požadovaného stavu může být jako jedna z prvních prací uvedena studie Georgel a kol.[15], kteří představili systém rozšířené reality, který měl podpořit operátora při provádění kontrolní operace. Podstatou bylo vytvoření snímků reálného prostředí, jejich import do AR a následně jejich porovnání s 3D CAD modelem. Tento systém byl však omezený na posuzování je na 2D úrovni.

Wasenmüller a kol.[16] vyvinuli systém kontroly neshod mezi reálným dílem a virtuální předlohou s pomocí RGB-D kamery. Tento systém je schopen rekonstruovat 3D objekt v reálném čase a umožňuje okamžitou kontrolu. Použití optického sledovacího systému k odhadu polohy kamery však není pro průmyslové použití vhodné, zejména proto, že je nutná kalibrační fáze a specifické pracovní podmínky. Obecně je možné tvrdit, že tyto systémy jsou velmi přesné v detekci neshod, ale mají zároveň určitá omezení. Není například umožněna efektivní vizualizace rozšířené reality, je vyžadováno specializované a drahé hardwarové vybavení, jako například optical tracking system nebo speciální kamery. Není možné tyto systémy využívat přímo na pracovišti, neboť nejsou použita žádná přenosná zařízení. Pro používání těchto technologií je také vyžadována vysoce kvalifikovaná obsluha.

S ohledem na některá uvedená omezení byly představeny další projekty a studie, které zdůrazňují důležitost možnosti přímé vizualizace digitální informace na obrazovku zařízení, díky čemuž může uživatel věnovat více pozornosti jak promítané vizuální informaci, tak kontrolní aktivitě. Pro tento účel je většinou použit tablet nebo chytrý telefon, jejichž další výhodou je také zkušenost uživatelů s nimi. V těchto případech je možné dosáhnout dobré využitelnosti, navržený systém zároveň může využít i pracovník, který nemá rozsáhlé odborné znalosti v oblasti rozšířené reality. Jedním z těchto příkladů je studie Lee a kol. [17], která sloužila ke kontrole potrubí a zvýšení bezpečnosti. Jejich systém přenáší aktuální informace k pracovníkům, 3D modely jsou zobrazovány na reálné systémy a zároveň jsou poskytovány informace o stavu produktu, jako je teplota nebo hodnota tlaku. Testování,

kteřé proběhlo v laboratorních podmínkách, potvrdilo velký potenciál této aplikace.


Další řešení představili Ramakrishna a kol.[18]. Důležité informace jsou poskytovány uživateli během kontrolních aktivit, pokyny jsou zobrazovány na obrazovku zařízení a provádějí pracovníka řadou úkolů. K využití rozpoznání objektů jsou využity QR kódy přiložené k objektům. Systém však funguje jen na principu zobrazení instrukcí, neumožňuje vizuálně porovnat virtuální model s reálným produktem.

Podobně He a kol. [19] navrhli AR systém pro podporu kontrolních úkolů. Umožňuje promítnout 3D modely na reálné objekty a možnost skenování modelu, který není dostupný v databázi. Zároveň operátor může díky zobrazení virtuálního obsahu na reálný objekt provádět kontrolní operaci a dle potřeby může přidat komentář o detekované chybě. Systém funguje na principu markerless, kdy rozpoznává reálné objekty. V rámci této studie nejsou dostupné žádné testy na uživateli k ohodnocení využitelnosti v průmyslových aplikacích.

Marino a kol. [20] prezentovali nástroj vyvinutý za účelem asistence operátorů během kontrolních aktivit potrubních systémů. Cílem je usnadnit provedení kontrolních úkonů a rychlejší odhalení chyby. Vzhledem k charakteru a rozměrům kontrolovaných objektů pracuje aplikace s detekcí 2D markerů připevněných na různých částech potrubí, na které po rozpoznání promítá 3D model pro posouzení případné odchylky. Aplikace je určena pro tablety, případně chytré telefony.

2.2 AI v průmyslovém prostředí

Umělá inteligence přitahuje v posledních letech stále více pozornosti. Pokroky v aplikacích jako self-driving cars nebo virtuální asistenti stále více přibližují tento fenomén koncovým uživateli. Následující schéma zobrazuje vztah mezi AI, Machine Learning a Deep Learning.



Obrázek 1 - Vztah AI, ML, DL

AI může být definována jako schopnost počítače nebo počítačem kontrolovaného robota vykonávat úkony běžně typické pro inteligentní bytosti.

Machine Learning popisuje situace, kdy je program trénován, ne explicitně programován. Program Machine Learning je zpravidla naplněn velkým množstvím dat a výsledků. Během fáze trénování se program učí propojit specifická data s danými výsledky a na základě toho poté klasifikovat reálné objekty.

Deep learning je podmnožina machine learning, ve které má trénovaný model více než jednu vrstvu mezi vstupem a výstupem. Množství vrstev určuje hloubku modelu. Většinou se množství vrstev pohybuje mezi desítkami až stovkami. K vytvoření deep learning modelu jsou zpravidla využívány neural networks.

2.2.1 Computer vision a deep learning

Úkolem rozšířené reality je spojovat obsah reálného světa (jako jsou fotky, obrazy nebo videonahrávky) s virtuálními předměty. AI představuje zajímavé řešení ke zvýšení adaptability AR systémů. Potenciál implementace umělé inteligence v oblasti rozšířené reality je zřejmý z dosažených úspěchů spojení AI a zpracování snímků a souvisejících aplikací.

Možnosti aplikací AI v průmyslovém prostředí již shrnul například Liu [21], potenciální nasazení AI do dalších průmyslových odvětví jako je kontrola s pomocí "convolutional neural network" popisoval Zhang [22].

Většina AR využití se dnes zaměřuje na překrývání fyzického světa s určitou informací. Pozornost zákazníků a uživatelů si získalo například využití AR při používání map a her. V průmyslovém prostředí se příležitosti využití AR zaměřují na vizualizace, instrukce a pracovní instrukce. Jako příklady lze uvést následující:

- Virtuální pracovní návodky pro pracovní postupy
- Servisní údržba, která nabízí digitalizované informace k dispozici v reálném prostředí pro reálný úkol přímo na pracovišti
- Asistence na dálku, díky které mohou externí experti nebo specialisté pracující na zkrácený úvazek výrazně snadněji a interaktivně podporovat méně zkušené pracovníky na pracovišti.

Důležité pro dosažení realistického výsledku při propojování virtuálního a reálného obsahu je podmínka, aby virtuální objekty splňovaly a sdílely stejné vlastnosti a charakteristiky jako reálný objekt v reálném prostředí. Pokud je například virtuální předmět uložen na ploše, musí zůstat v neměnné poloze na této ploše bez ohledu na pozici uživatele a jeho úhlu pohledu. Pokud se daná plocha, na které je virtuální předmět uložen, začne hýbat, musí virtuální objekt tuto plochu následovat.

Následující oblasti zahrnují řešení tří náročných problémů v rámci Computer Vision:

- Camera Localization,
- Object tracking
- Illumination estimation

Zatímco pro první z nich bylo vyvinuta vyvinuta již velmi spolehlivá řešení, další dva jsou stále otevřenou otázkou pro výzkum. Jednou z podpůrných technologií pro tyto dva body může být právě Deep Learning.

Ke spuštění AR aplikací dochází po rozpoznání definovaných markerů, geometrie CAD modelu, QR nebo bar kódu nebo jiných vstupních senzorů.

Druhou možností je situace, kdy má uživatel k dispozici neidentifikovatelný stroj nebo součástku, ke které se nevztahuje žádná konkrétní informace, identifikace nebo instrukce, jak s daným dílem nakládat z hlediska výrobních montážních, kontrolních operací, nebo servisního úkonu.

Řešení v tomto případě nabízí právě Artificial Intelligence (AI). AI a zejména její podmnožina Deep Learning přináší možnost inovace do problematiky Computer Vision (CV) a AR. Schopnost vnímat a rozlišovat řadu prostředí může v budoucnu přispět k rozšíření využitelnosti AR v dalších aplikacích a dále podpořit pracovníky přímo na pracovišti více než dosud.

Chápání rozdílu mezi klasickým (tradičním) a učitím se přístupem k CV je zásadní pro rozvoj dalších aplikací dnes a v blízké budoucnosti.

2.2.2 Tradiční (klasický) přístup

Průmyslové prostředí je extrémně komplexní a plné složitých postupů, které mají za úkol udržovat kritické systémy a procesy v nepřerušném stavu. Zajištění správných informací pro operátory kvality vyžaduje komplexní, rozsáhlé, a přesto plynulé a bezproblémové přenosy digitálních informací, kdy AR může dodávat potřebné informace pro danou situaci ve správném čase, přesném stavu a spolehlivým způsobem. Vzhledem k současnému extrémnímu tlaku na konkurenceschopnost výrobních podniků z hlediska efektivity, nákladů a flexibility je případné přerušení procesu nebo riziko nekvalitních výrobků prakticky nepřijatelné.

U tradičního přístupu se v podstatě jedná o návrh vlastního algoritmu Computer Vision v kódovaném a designovém prostředí. Tvůrce tak může mapovat vlastní vstupy senzorů jako jsou kamery, GPS, 3D geometrie a umožnit rozpoznání algoritmu CV pro konkrétní případy použití.

Tvůrce AR aplikace může pro tento CV algoritmus a daný případ využití propojit geometrie, body, prvky a měření a vytvořit tak konečnou aplikaci.

Díky jeho uživatelské nastavitelnosti je tato možnost tradičního CV oblíbená například v těžkém průmyslu, kde je vyžadováno zachování vysoké přesnosti obsahu. Přestože se tato situace i v aplikacích s AI zlepšuje, je často obtížné přesně měřit hloubku v obraze v zachycených zobrazeních s použitím DL přístupů. Proto je vhodnější volba klasické CV, jelikož je přirozeně

kompatibilnější pro rozpoznání složitých 3D struktur díky návrhu algoritmu a výběru senzoru.

2.2.3 Deep Learning

Další varianta při řešení CV je využití AI, konkrétně DL zabudované do AR aplikace. Poslední dobou se začíná potenciál využití umělé inteligence ve spojení s AR stále více zkoumat a rozvíjet. Průzkumy na toto téma zaměřovali například Park a kol. [23] Deep learning (DL) představuje podmnožinu umělé inteligence. AI aplikovaná na AR může snížit nutnost modifikace k prostředí, DL může zlepšit přesnost a spolehlivost pro oblasti calibration, detection, tracking, camera pose estimation a registration. DL také může být využita při určování dat, která se mají uživateli zobrazovat a jakým způsobem. DL umožňuje object recognition, bez nutnosti využívat target markery nebo čárové kódy. Mohou být také využita CAD data dílu k trénování neural networks v cloudu. Během tohoto procesu je do systému vkládáno velké množství příkladů vstupního dílu, výsledek je AI model, který může být využit v AR aplikaci.

Tato training data mohou být uměle vytvářena renderováním 3D CAD modelu v různých pozicích a orientacích k získání souboru pro naplnění neural network.

Důležitost vstupních tréninkových dat je běžná pro každé průmyslové odvětví. Pro vytváření AR aplikace využívající DL se kvalita získaného modelu odvíjí od kvality vstupních dat vložených pro trénování modelu.

Relativně velká pozornost je DL a učícím se algoritmům věnována například u autonomních self-driving vozů, které jsou trénovány z milionů mil obrázků a nahrávek. Použití se dá také nalézt v medicínském výzkumu, kde jsou sítě plněny miliony dat o pacientech, které mají za cíl včas a co nejspolehlivěji diagnostikovat nemoci. [23]

Využití těchto principů a postupů v průmyslovém prostředí může mít velmi výrazný přínos. Například při servisní údržbě by technik vybavený nástrojem založeným na AI trénované databázi mohl být schopný okamžitě identifikovat každou součástku a spolu s přesnými instrukcemi k její kontrole, opravě nebo výměně. Takový pokrok by mohl celosvětově znatelně zlepšit kvalitu oblasti služeb.

Kontrola a zajištění kvality mohou být také významně podpořeny s použitím AI v AR například k rozpoznávání defektů v průmyslových produktech, sestavách nebo celých výrobních linkách ať se jedná o viditelné defekty nebo defekty, které jsou lidským okem nepostřehnutelné. DL má například také značný potenciál zvýšit bezpečnost výrobních provozů vybavením pracovníků AR nástrojem, který může předvídat případné nebezpečné situace.

Volba vhodné CV metody je závislá na konkrétním případě použití a účelu AR aplikace. DL algoritmus v AR by byl vhodnější k identifikaci objektu, zatímco klasický model může přesněji trackovat, detekovat a měřit.

K zapojení takových inovativních AR aplikací do běžné praxe bude v blízké budoucnosti potřeba vhodná integrace s ostatními technologiemi. Vhodné propojení s IoT by například umožnilo AR nástroji přístup k provozním datům rozpoznávaného objektu nebo propojení jiné relevantní obchodní systémové informace jako jsou úroveň zásoby, informace o dodavateli nebo odběrateli nebo obchodní podmínky prodeje a platnost záruky.

Rozvojem těchto metod může být zprostředkováno intenzivnější propojení fyzického a digitálního světa.

2.2.4 Průmyslová výroba s AI podporou

Čtvrtá průmyslová revoluce je založená na technologickém rozvoji, který má za cíl podpořit rychlost a efektivitu neautomatizované části výroby, která zůstává závislá na znalostech a dovednostech operátorů, a zavést moderní inteligentní řešení do již automatizované infrastruktury pro podporu autonomních robotických systémů, která budou schopná dělat jednoduchá rozhodnutí na základě dostupných dat.

S rozvojem automatizace v průmyslové výrobě byly do výrobních provozů zavedeny senzory a roboty. Využívání senzorů tak vedlo k velkému množství dat dostupných z výrobního procesu (Big Data). Schopnost vytvářet rozhodnutí na základě dostupných dat a zvýšení nezávislosti robotů při vytváření vlastních rozhodnutí patří mezi cíle Průmyslu 4.0. [24] Zapojování autonomních robotů a analýza Big Data vedly k rozsáhlému využívání AI. Technologie umělé inteligence představují možnosti, jak spravovat a využívat Big Data. AI strategie se zavedly do celé řady výrobního procesu i v rámci dodavatelských řetězců v designu, operativním managementu, výrobě, údržbě a montáží.[22]

Data ze senzorů v reálném čase mohou být podkladem pro rozhodování ve výrobním procesu. Tato data mohou výrobním systémům umožnit reagovat v reálném čase na měnící se požadavky a podmínky v celém PLM s ohledem na odvětví, dodavatelskou síť a potřeby zákazníků. [25]

Smart manufacturing si klade za cíl dokázat využít velké množství dat shromážděných z celého PLM výrobku do výrobního systému s cílem zlepšit každý aspekt procesu [26]. Hlavním cílem, který stojí za využitím velkých dat, je dosažení bezchybných nebo bezporuchových procesů.

AI může být mimo jiné využita pro kontrolu kvality. Yacob a kol. [27] navrhli Skin Model Shapes, který má být schopný generovat digitální dvojče vyráběného dílu. Ve spojení s metodami Machine Learning má být tento model schopen odhalit anomálie a neznámé změny na výrobku ve srovnání s předlohou k zajištění kvality dílu.

2.2.5 Průmyslová výroba s podporou AI a AR

Výroba s podporou rozšířené reality i výroba řízená umělou inteligencí se vyvíjely nezávisle na sobě a každá se zapojila do průmyslových aplikací

odděleně. Mnoho dostupných výzkumných prací zkoumalo potenciál AR jako nástroje pro podporu průmyslové výroby. Mnoho z nich však trpí řadou nedostatků. Výpočetní strategie jsou například vysoce nákladné, a ne zcela spolehlivé v měnících se prostředích, dostupné strategie použité v AR systémech jsou pracné na implementaci a omezené na známá prostředí, specializovaná a různorodá konstrukce prvků pro detekci je nutná pro správné rozpoznání objektu a sledování, metody ukládání jsou rigidní a nepřizpůsobivé a virtuální objekty jsou v systému AR pevně zakódovány.

Jelikož může AR poskytovat nepřerušovaný přísun nebo výměnu informací bez nutnosti přerušení pozornosti operátora, může výrazně zvýšit rychlost a efektivitu vykonávání výrobních úkonů. Většina dostupných AR nástrojů a studií je koncentrována do oblastí montáže, údržby a tréninku. V rámci těchto oblastí musí pracovníci vykonávat specifické úkoly a procesy v daných sekvencích a postupech. Přímé zprostředkování těchto procesních informací k pracovníkovi je zásadní k minimalizaci kognitivní zátěže. Zároveň tak pozitivně ovlivňuje operativní náklady, efektivní procesy a rostoucí produktivitu. Při výrobních operacích s podporou AR operátor může provést úkol bez přerušení své pozornosti. Pracovníci mohou také lépe pracovat s díly nebo součástmi, se kterými dosud nemají tolik zkušeností nebo s nimi pracují poprvé. AR také snižuje tlak na pamatování výrobních postupů.

Některé z těchto nedostatků je možné odstranit použitím AI jako podpůrného nástroje v rámci AR.

Existuje mnoho výzev, které jsou předkládány při začleňování strategií umělé inteligence do výrobních aplikací s podporou rozšířené reality. Výrobní prostředí například nabízí omezenou variabilitu objektů pro podporu detekce a sledování. Rozlišování mezi různými objekty jako jsou matice nebo šrouby, které se odlišují jen ve velikosti, nebo objekty, které prošly stejným procesem obrábění, je velmi složité a představuje pro vytvoření obecné AI velkou výzvu. Trénování algoritmů umělé inteligence na rozpoznávání anomálií je nákladná záležitost, zejména vytváření dat, která zachycují anomálie je zpravidla velmi časově i nákladově náročné. Další výzvou je sběr a sdílení velkých dat z výrobních procesů do systému AR. Plynulý přenos relevantních dat do systémů AR je nezbytný k zachování aktuálnosti a správnosti kontextu.

Při ukládání průmyslových dat na cloudových platformách musí být také velmi pečlivě řešeny otázky soukromí a bezpečnosti. [28]

Další výzvou je skutečnost, že průmyslové procesy často obsahují časově proměnné nepřesnosti, které musejí být brány v úvahu při vytváření AI metod.

Integrace umělé inteligence do výroby s podporou rozšířené reality se sice bude potýkat s výše uvedenými technickými a manažerskými výzvami, výhody rozšířené reality řízené umělou inteligencí by však měly tyto nedostatky výrazně převážit. Díky AI se systémy AR stanou inteligentními jako autonomní roboty a senzory. Budou schopny bezchybně detekovat a sledovat určité objekty. Systémy AR řízené umělou inteligencí budou schopny autonomně pracovat ve výrobním prostředí s minimálním úsilím a vstupem

člověka. Umělá inteligence poskytne systémům AR schopnost efektivně a účinně pracovat jako jednotný celek s výrobním prostředím a s lidskou obsluhou.

2.3 Tracking technologies

Jedna z velkých výzev v rozvoji aplikací rozšířené reality je přesné sledování a registrace mezi digitálním modelem vytvořeným počítačem a reálným objektem. Při změně polohy uživatele nebo sledovaného objektu musí virtuální objekt nebo digitální informace zůstat zarovnané s reálným sledovaným objektem. Dvě základní možnosti trackingu jsou marker-based a markerless. Obě tyto metody patří pod systém vision based tracking, který využívá computer vision technologie k určení pozice kamery relativní vůči reálným objektům.

V případě marker-based trackingu jsou využity vizuální markery, které jsou umístěné do scény snímání aplikace rozšířené reality. Tyto markery mají specifické vlastnosti, díky kterým je snadné je sledovat a identifikovat jejich pozici v reálné scéně. Jednou z hlavních výhod je vysoká spolehlivost rozpoznání markeru a přiřazení správné informace k reálnému objektu. Mezi omezení patří značná časová náročnost na přípravu markerů a případně nutnost vytváření velkého množství markerů pro různé objekty a lokace. Další nevýhodou je, že není vždy vhodné nebo možné připojit marker ke sledovanému reálnému objektu.

U markerless trackingu jsou využívány přirozené prvky ze sledovaného prostředí bez dodatečného markeru. Tyto přirozené prvky musí splňovat základní podmínky pro správné fungování. Musí být možné vysledovat dostatečné množství feature points pro zajištění spolehlivého odhadu pozice kamery a objektu a sada těchto feature points se nesmí výrazně měnit v závislosti například na světelných podmínkách. Tyto feature points jsou poté porovnány s odpovídajícími feature points uvnitř databáze s využitím šesti stupňů volnosti 6DOF (sex degrees of freedom). Tento úkon je označován jako feature matching a jedná se o jeden z klíčových úkonů v rámci trackingu. [29]

Rozšířená realita může být určena pro velké množství zařízení. Hlavní skupinu tvoří hand-held a head-mounted zařízení. HMD využívají headsety, zatímco HHD jsou určeny především pro mobilní zařízení jako jsou chytré telefony nebo tablety. Z hlediska SDKs (Software Development Kits) je k dispozici také řada možností pro tvorbu AR aplikace. Mezi nejrozšířenější patří ARCore, ARKit a Vuforia.

ARKit od tvůrců Apple je určen pro použití pouze s iOS, ARCore od Google funguje pro Android i iOS, Vuforia od společnosti PTC umožňuje vytvářet aplikace pro Android, iOS a univerzální Windows platformy. Tyto nástroje umožňují tvorbu aplikací pro kategorie HMD i HHD. Trh s HHD je v současné době mnohem rozsáhlejší, jelikož většina prodávaných chytrých telefonů umožňuje použití AR aplikací za relativně dostupnější pořizovací náklady. Na

druhou stranu, AR aplikace nemusí být s ohledem na rozměry displeje telefonu vždy vhodná nebo dobře přehledná.

2.3.1 Google ARCore

ARCore je založeno na 3 hlavních konceptech: Motion Tracking, Environmental Understanding a Light Estimation. Proto ARCore umožňuje podporovaným mobilním zařízením sledovat pozici a orientaci relativní k reálnému světu v 6 stupních volnosti (6DOF) s použitím techniky „Concurrent Odometry and Mapping (COM)“. Ta také pomáhá detekovat velikost a polohu povrchů jako je podlaha, stěny, stůl apod. [30]

2.3.2 Apple ARKit

ARKit je na trhu od roku 2017. Stejně jako ostatní SDKs, využívá i ARKit speciální techniku zvanou Visual Inertial Odometry (VIO), která velmi přesně sleduje svět kolem zařízení. VIO je podobné jako COM u ARCore. Sdílejí také základní koncepty jako jsou World Tracking, Scene Understanding a Rendering. ARKit kromě sledování pozice a orientace zařízení relativní k okolnímu světu v šesti stupních volnosti také nabízí nástroj People and Object Occlusion s technikami jako jsou LiDAR Scene Reconstruction, 2D Tracking, Vertical and Horizontal Planes Detection, Image Detection, 3D Object detection a 3D Object Scanning. [31]

2.3.3 PTC Vuforia

Vuforia patří mezi nejstarší z představených technologií. Vuforia Engine nabízí prakticky srovnatelné hlavní schopnosti jako ARKit nebo ARCore, které doplňuje o další speciální prvky. Jedná se například o Model Targets, které využívají Deep Learning k trénování neural network databází. Dále VISLAM (Visual-Inertial Simultaneous Localization And Mapping) pro markerless AR aplikace. Jednou z výhod Vuforie oproti ARKit a ARCore je větší množství podporovaných zařízení a možnost vývoje pro univerzální Windows platformu. Mezi speciální funkce Vuforie patří například Advanced Model Target 360 s podporou AI k rozpoznání sledovaného objektu, Model Target využívající princip Deep Learning k okamžitému rozpoznání objektů podle tvaru porovnáním s 3D modelem propojeným s algoritmy deep learning. Dále například Image Target, Multi Targets, Cylinder Targets, Ground Plane, VuMarks, Object Targets pro skenování objektu a další. [32]

3 Metodika

Cílem tohoto projektu je návrh a vytvoření interaktivního AR nástroje, který bude sloužit jako podpora pracovníků kontroly kvality svařování přímo na pracovišti. Díky využití 3D modelu a k němu nadefinovaných informací, které se v reálném prostředí překryjí s kontrolovaným dílem je možné snadno provést porovnání virtuálního návrhu a reálného stavu. Tato aplikace byla

vytvořena v prostředí Unity s pomocí Vuforia SDK. Díky vysoké kompatibilitě těchto nástrojů s běžně rozšířenými zařízeními, se kterými mají zpravidla pracovníci zkušenosti, se jedná o uživatelsky relativně dobře dostupné řešení.

Kontrolní operace vyžadují poměrně významné množství času a koncentrace a představují velkou psychickou zátěž pro daného pracovníka zejména v případech, kdy jsou využívány tradiční metody s podporou tištěné technické dokumentace. Pravděpodobnost chyby kontrolora výrazně narůstá s rostoucí složitostí kontrolovaného dílu. Pro každý výrobní podnik je bezchybná a stabilně spolehlivá kvalita nutností a prioritou, neboť v případě dodání vadného produktu zákazníkovi mohou následovat nejen finanční postihy, ale mohou být také ohroženy dlouhodobě budované dodavatelsko-odběratelské vztahy. Většina průmyslových podniků má proto ve svých výrobních procesech zabudované mechanismy pro zajištění maximální úrovně kvality produkce. Zároveň je třeba dodat, že kontrolní operace nejsou úkony přidávající hodnotu při zpracování produktu, dlouhodobým cílem každého podniku je proto provádět tuto aktivitu s maximální efektivitou.

Pro detekci kontrolovaného objektu nebudou využívány markery, jejichž využití může být v řadě případů nevhodné nebo nemožné. K rozpoznání kontrolovaného objektu bude využita umělá inteligence, konkrétně principy deep learning. Pro vybraný model bude v cloudu vytrénována databáze fungující na principu „neural network“, díky které systém sám díl rozpozná, identifikuje a zobrazí k němu přiřazené údaje a informace. Formou interaktivního checklistu bude provedena kontrola kvality provedené svařovací operace. Využitelnost bude následně otestována na vybraném vzorku uživatelů s použitím standardizovaných dotazníků se zaměřením na kvalitativní i kvantitativní parametry, které budou sledovat objektivní charakteristiky provedení kontrolní operace i subjektivní hodnocení využitelnosti a kognitivní zátěže na uživatele.

Navržený nástroj je určený experimentům s koncovými uživateli v rámci reálné case study. Cílem těchto testů bude ohodnocení využitelnosti a mentální zátěže na uživatele, které bude hodnoceno s pomocí vybraných standardizovaných dotazníků. V rámci experimentu s uživateli budou sledovány kvantitativní i kvalitativní parametry, budou tedy posuzovány objektivní výsledky provedení kontrolního úkolu stejně jako subjektivní hodnocení provedené operace a úroveň mentální zátěže.

4 Case Study

Představená aplikace byla navržena s ohledem na „user-centered design approach“.[33], který zohledňuje potřeby a požadavky cílového uživatele a zajišťuje vysokou úroveň využitelnosti. Má za úkol zkoumat možnosti a omezení využití HHD (Hand-held device) pro AR jako nástroj k podpoře Human-Machine Interaction.

Pro vytvoření AR aplikace byl zvolen program Unity a SDK Vuforia.

Aplikace je vhodná pro běžně dostupná zařízení jako jsou tablety nebo chytré telefony. Vzhledem k preferenci většího displeje mezi koncovými uživateli, je při vytváření aplikace dimenzovaná především pro použití na tabletu.

Veškeré výpočty a procesy jsou provedeny přímo v zařízení, není proto nutný žádný externí hardware pro zpracování dat.

V rámci Vuforia byla zvolena možnost Model Target for detection and tracking, a konkrétně Advanced Model Target. Cílem bylo zvolit markerless možnost, která by nevyžadovala použití Image Targetu nebo generovaného markeru. Možnost skenování objektu je značně pracná, u komplexnějších dílů také ne zcela spolehlivá a v závislosti na světelných podmínkách také náchylná k nepřesnostem.

Díky funkci Model Target Generator je místo manuálního skenování modelu použitý 3D CAD model. Pro tento model jsou manuálně definovány určité vstupní parametry, které budou představeny níže, a s pomocí deep learning algoritmů vytvoří Vuforia trénovanou databázi, generuje zpracovaný model target, který může sloužit pro inteligentní rozpoznání objektu v AR aplikaci.

Importovaný model musí splňovat určité základní parametry. Pro dobrou funkci rozpoznávání musí mít například dostatečně výrazné geometrické rysy a detaily. CAD model musí také co nejdříve odpovídat reálnému objektu, musí se shodovat v rozměrech i tvarech. Jelikož se reálné objekty mohou často mírně odlišovat od 3D návrhu, toleruje Model Target odchylku až 10 % mezi reálným a virtuálním objektem. Objekt by ale obecně měl být rigidní bez pohyblivých částí, které by sledovacím algoritmem nebylo možné zpracovat. Obecně existují limity ve složitosti importovaného modelu, který může mít maximálně 400 000 polygonů nebo trojúhelníků, obsahovat maximálně 20 částí s celkem maximálně 5 texturami.

V případě, že je k dispozici 3D CAD model, který splňuje dané zásady, je možné vytvořit nový Model Target. MRG (Model Target Generator) podporuje poměrně velké množství formátů, například Creo View, FBX, IGES, STEP, STL a další.

See [Supported Objects and Best Practices](#)

CAD Model

Select ...

Model Target Name

Please enter a value name

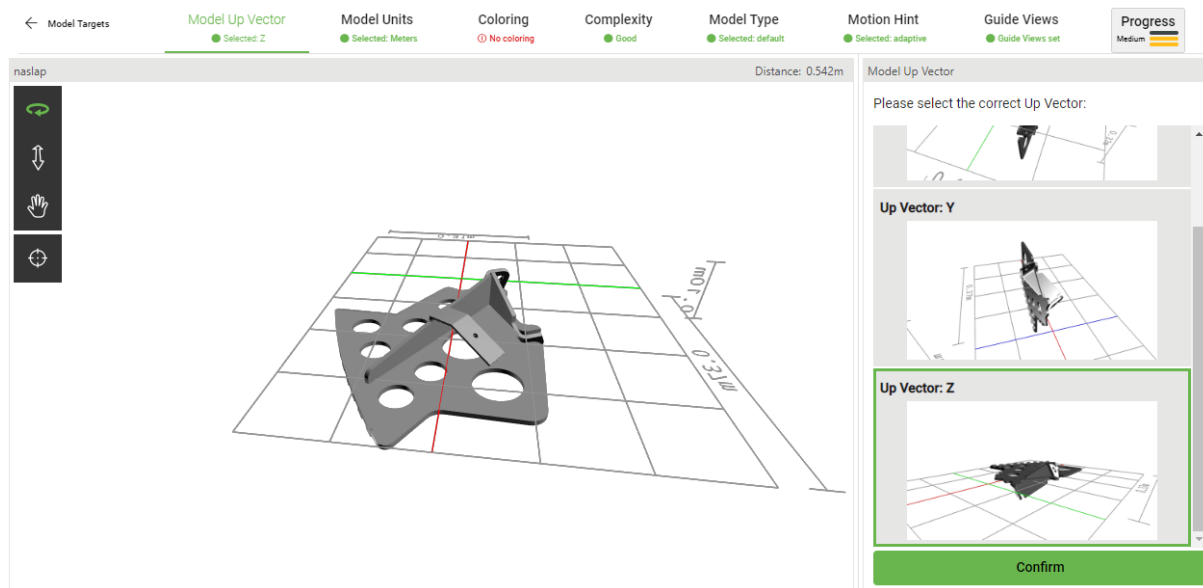
Location

Browse ...

Cancel Create Model Target

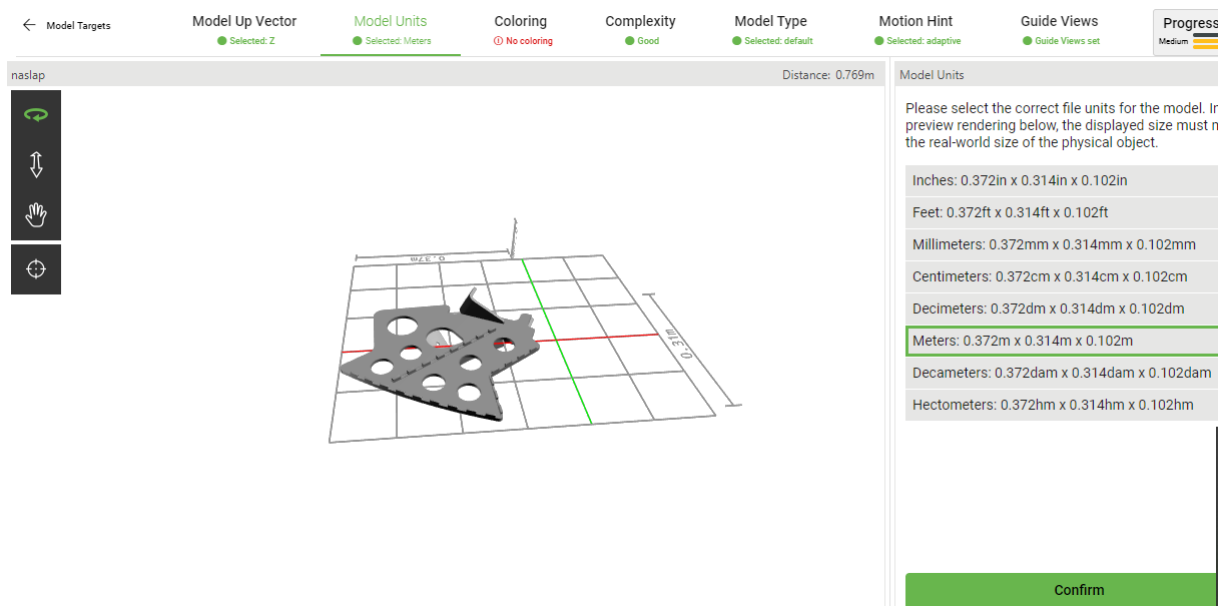
Obrázek 2 - Vytvoření model targetu

Pro importovaný CAD model je možné upravit výchozí nastavení souřadnicového systému a orientace vektorů.



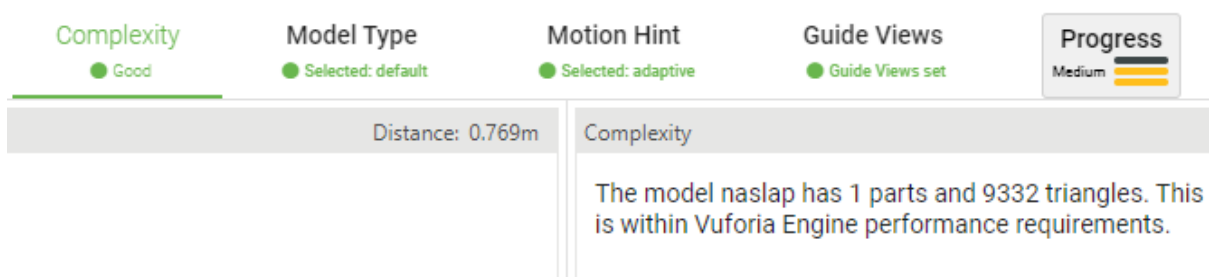
Obrázek 3 - Nastavení orientace vektorů u model targetu

V dalším kroku musejí být nastaveny správné jednotky modelu. Díky tomu bude vytvořený model rozměrově odpovídat reálnému objektu. Jelikož CAD model často nemá zakódované nastavení jednotek, je potřeba tuto informaci manuálně doplnit.



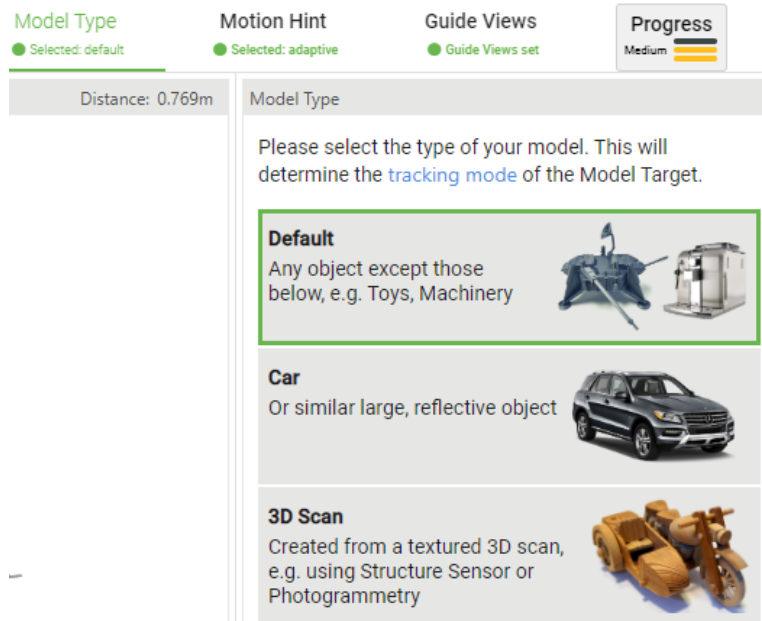
Obrázek 4 - Nastavení jednotek model targetu

Následně MTG kontroluje složitost modelu, která nesmí překročit určité hranice. Pokud je model vyhodnocen jako příliš složitý, je možné spustit automatickou úpravu příkazem Start simplification, který model optimalizuje.



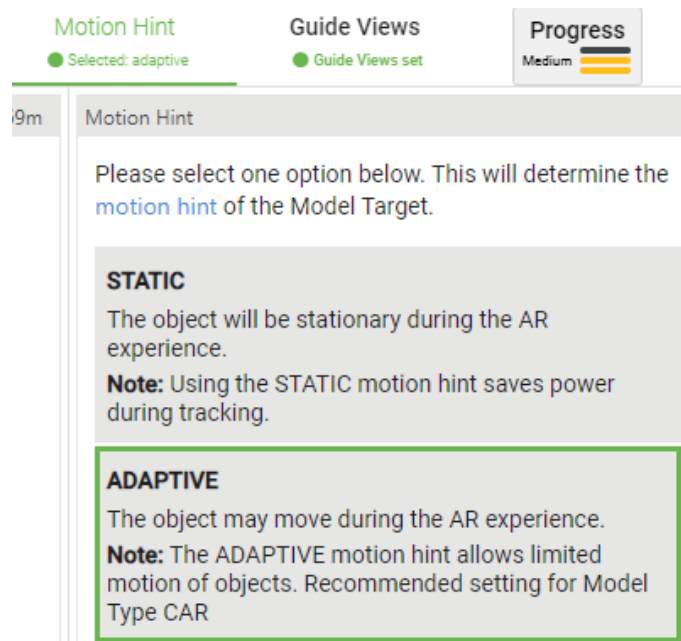
Obrázek 5 - Vyhodnocení složitosti modelu

Dále je zvolen typ modelu mezi Default, Car a 3D Scan. Typ modelu slouží k výběru tracking mode pro model.



Obrázek 6 - Model Type

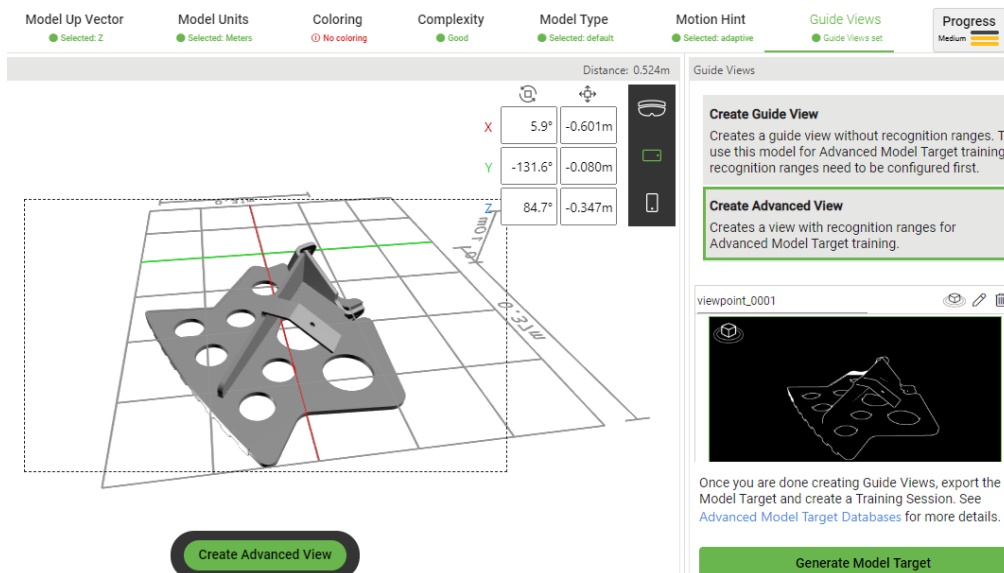
V části Motion Hint jsou nastaveny podmínky, v jakých se bude pravděpodobně díl vyskytovat. Pokud je pravděpodobné, že se s dílem bude hýbat, je vhodná možnost Adaptive, pokud bude ustaven ve stabilní poloze, je zvolena možnost Static. Pro objemnější díly, které jsou kontrolovány například v kontrolním nebo svařovacím přípravku by byla zvolena možnost Static. Jelikož zvolený díl je zpravidla kontrolován a otáčen ručně, je upřednostněna druhá varianta Adaptive.



Obrázek 7 - Motion Hint


Důležitou součástí tohoto nastavení jsou Guide View, které jsou zásadní z hlediska inicializace trackingu model targetu. Je možné zvolit mezi možnostmi Guide View a Advanced Guide View.

První možnost funguje jako renderované obrysy modelu, které během použití AR aplikace uživatel spáruje s reálným objektem a tím spustí další obsah aplikace.



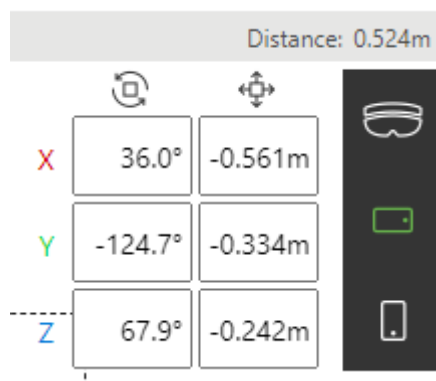
Obrázek 8 - Advanced Guide View

Advanced Views využívají Recognition Ranges, které automaticky spustí obsah AR aplikace, pokud je model rozpoznán z libovolného zvoleného úhlu. Pro toto nastavení je možné zvolit variantu 360°, díky které je model rozpoznán z každého úhlu, ze kterého uživatel k dílu přistoupí. Pro Advanced Model je spuštěno trénování databáze v cloudu.



Obrázek 9 - Recognition Ranges

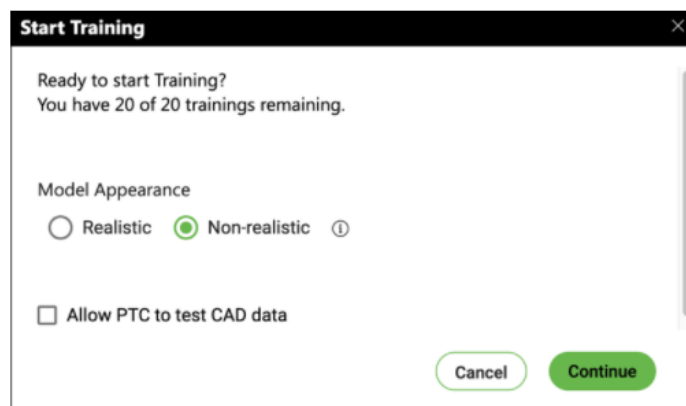
Před dokončením nastavení Guide View je zvolen způsob zobrazení aplikace. Na výběr jsou 3 základní možnosti Digital Eyewear pro HoloLens, Landscape a Portrait.



Obrázek 10 - Způsob zobrazení aplikace

Před spuštěním trénování databáze musí být určen Appearance Mode, dle kterého má být model trénován. Na výběr jsou 2 základní možnosti Realistic a Non-realistic. Realistický vzhled je určen pro případ, kdy zvolený 3D model přesně odpovídá reálnému fyzickému objektu s ohledem na texturu a barvy. Pokud je zvolena tato první možnost, vytvořený model bude při rozpoznání uvažovat shodu jen u dílů s přesnou shodou nejen geometrie, ale i barvy a textury apod. Tato možnost je vhodná pro rozlišení velmi podobných objektů, které se liší například barevným provedením.

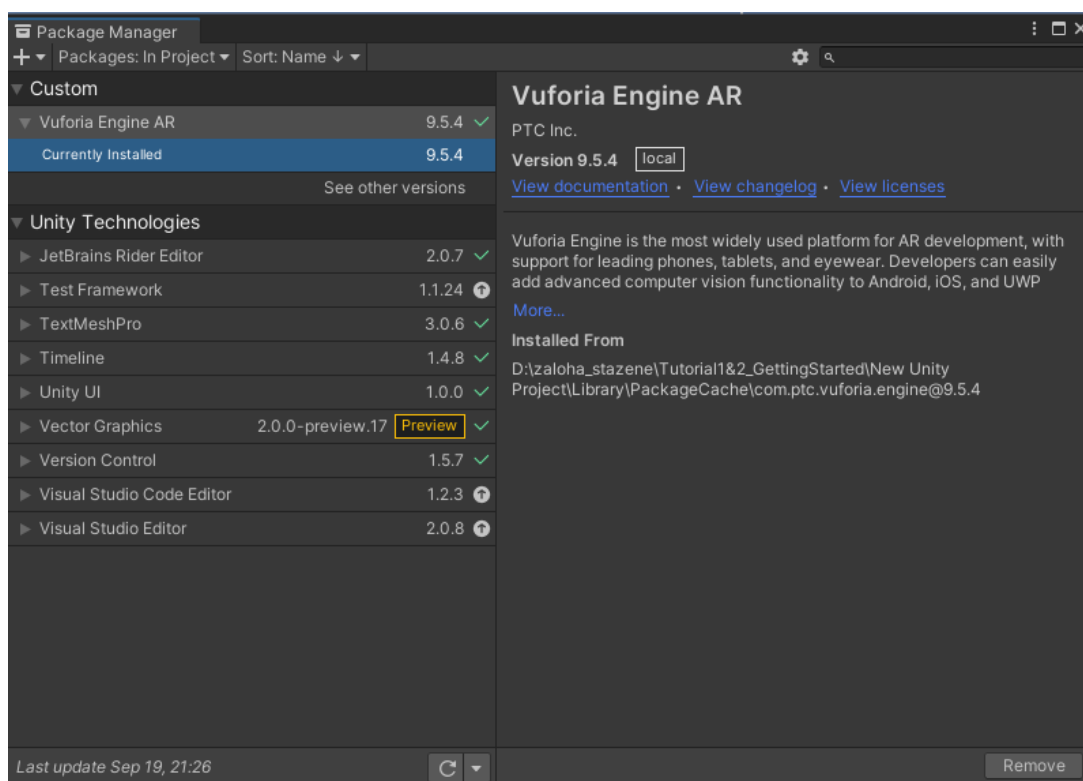
Varianta Non-realistic je zvolena, pokud se generovaný CAD model a reálný objekt neshodují barvě a textuře. V takovém případě databáze tyto parametry uvažovat nebude. Jelikož v rámci projektu bude díl sledován po svažení, není barva nebo textura pro tvorbu databáze uvažována.



Obrázek 11 - Appearance Mode

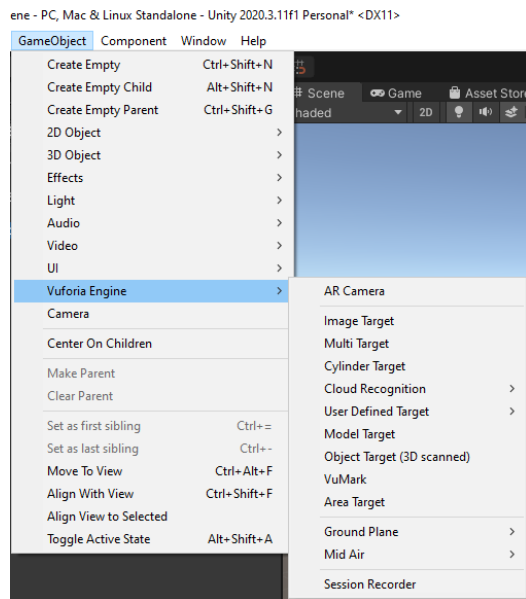
Vytvořená trénovaná databáze a vygenerovaný model 360° jsou importovány do prostředí Unity.

Pro správné fungování musí být nejprve nastavena funkce Vuforia Engine AR prostřednictvím Package Managera.




Obrázek 12 - Nastavení Vuforia Engine v Unity

Díky úspěšné instalaci se zpřístupní funkce rozšířené reality podporované Vuforií, včetně AR kamery, která v této aplikaci nahradí původně nastavenou Main kameru.



Obrázek 13 - Vuforia funkce v Unity

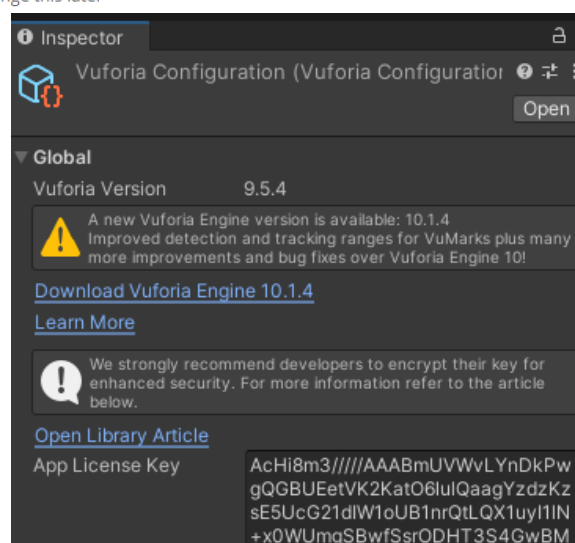
Prostřednictvím developer portálu Vuforia Engine je vytvořen licenční klíč, který je zároveň vložen přímo do aplikace.



[Back To License Manager](#)

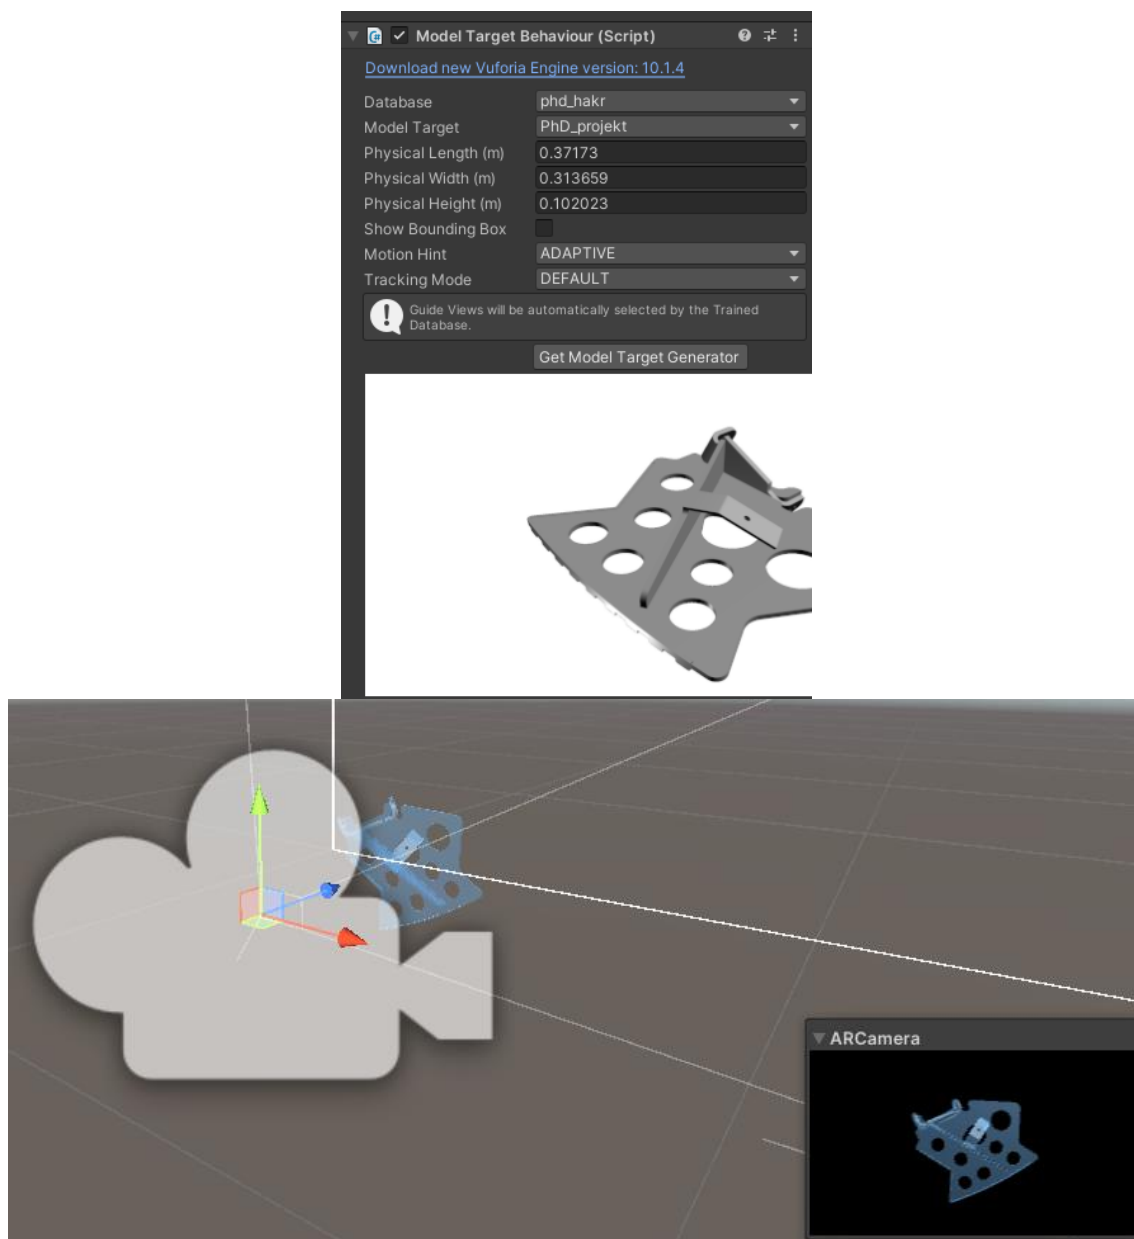
Add a free Development License Key

You can change this later



Obrázek 14 - Vuforia Licence Key


Generovaný model a jeho databáze jsou importovány do prostředí Unity jako Unity package obsahující dataset včetně .xml dat. V části Model Target Behaviour je do aplikace propojena vytvořená databáze a model.



Obrázek 15 - Import model targetu

Zobrazený model slouží jako informace o poloze reálného sledovaného objektu. Pro vytvoření obsahu rozšířené reality musí být pro tento model vložena další data, která se budou po rozpoznání modelu zobrazovat.


Kontrolované parametry jsou graficky vyznačeny v následujícím obrázku, který zachycuje model použitý v aplikaci.



Obrázek 16 - Vstupní model pro AR aplikaci


Volnou dynamických tlačítek, která jsou součástí uživatelského rozhraní je možné specifikovat data, která se mají na detekovaném modelu zobrazovat.

Uživatel si může zobrazit pouze informace o svarech přímo na reálný objekt. K těmto údajům je připojen kód, který dynamicky natáčí text směrem ke kameře.




Obrázek 17 - Zobrazení instrukcí pro kontrolu

Volbou druhého tlačítka si může uživatel zvolit jen překrytí navrženého modelu se zvýrazněnými svary v určitém stupni transparentnosti přes reálný objekt.



Obrázek 18 - Zobrazení CAD modelu

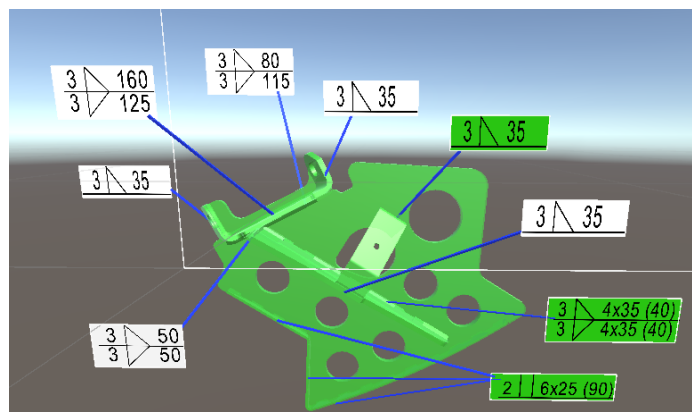
Jako třetí možnost může být zvoleno zobrazení modelu i doplňujících informací.



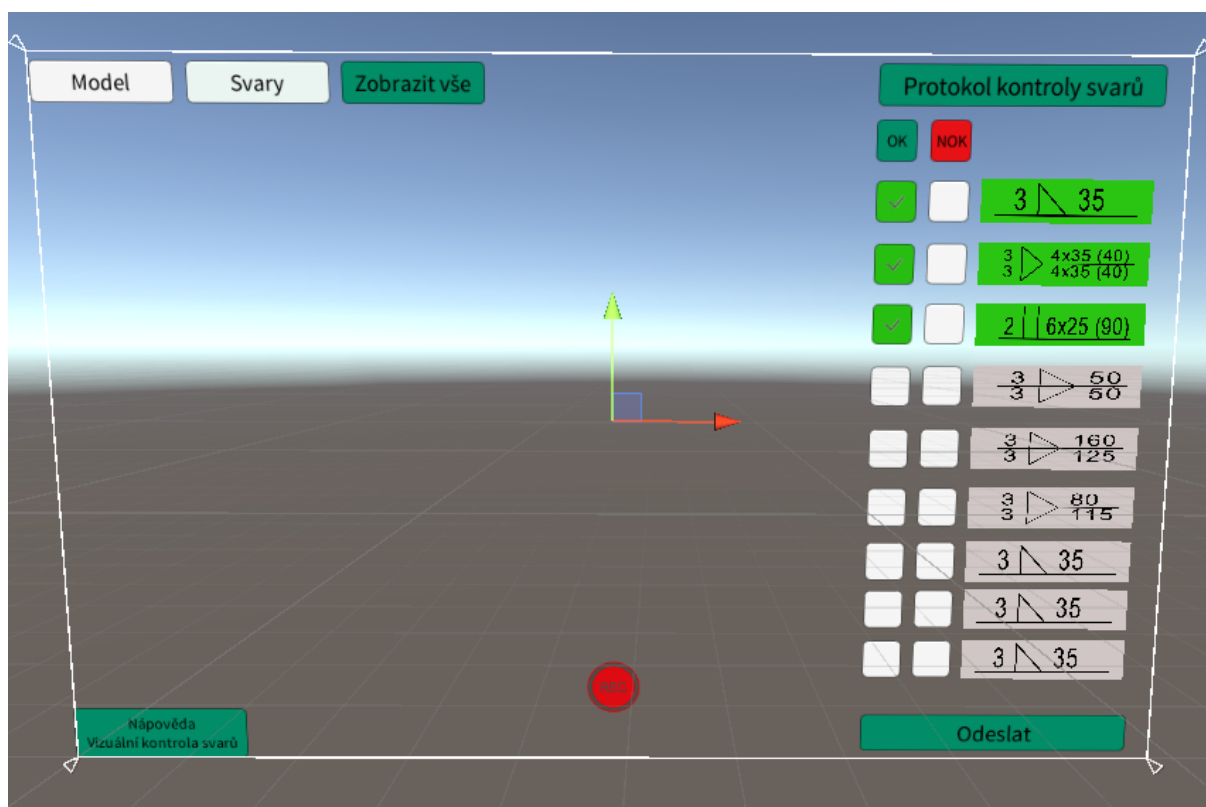
Obrázek 19 - Zobrazení CAD modelu včetně instrukcí

Aplikace je doplněná o interaktivní checklist pro kontrolu svarů. Pro lepší přehlednost úvodní scény se checklist otevře na novém panelu až po stisknutí příslušného tlačítka. V této chvíli je možné začít kontrolovat svary na reálném

dílu. Zkontrolované části jsou zaznamenány do checklistu, který funkcí automatického zbarvení tlačítka i příslušného textu vizuálně podporuje uživatele v rozpoznání již provedených úkonů.

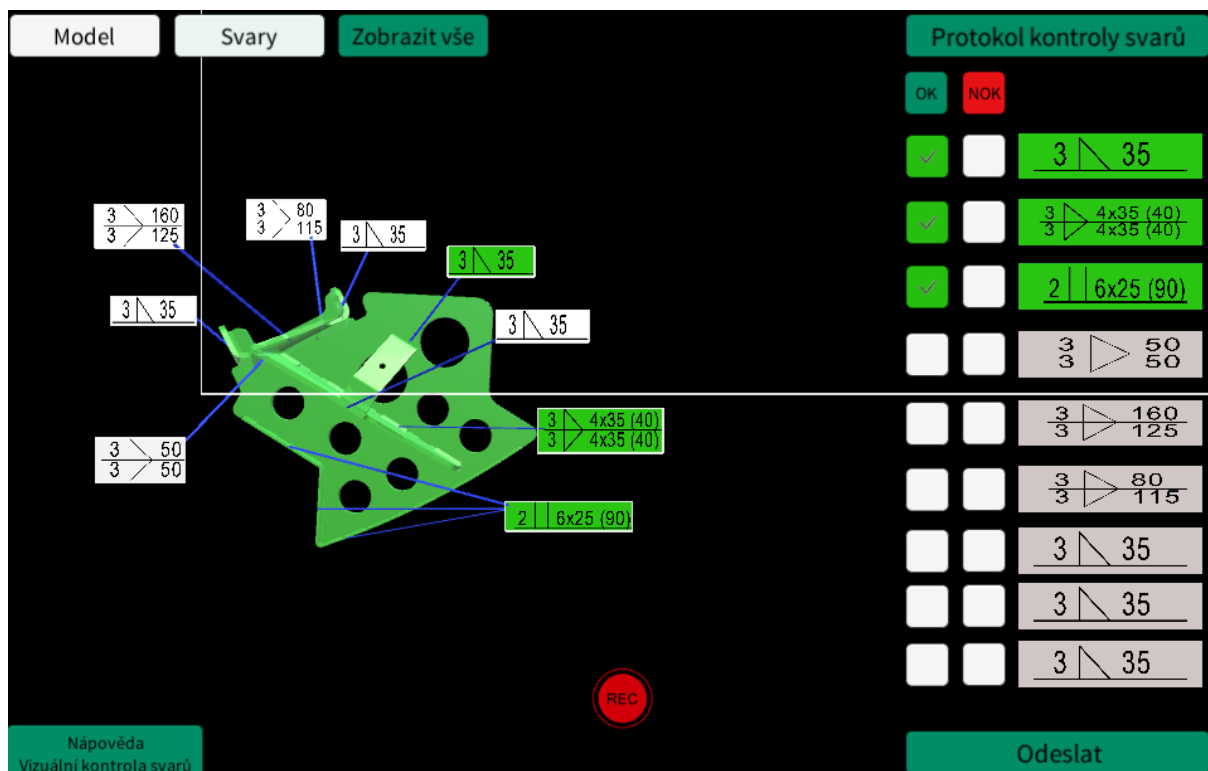


Obrázek 20 - Vizuální zvýraznění zkontrolovaných prvků



Obrázek 21 - Návrh interaktivního checklistu v prostředí Unity

Dle potřeby si uživatel může zobrazit a opět skrýt nápovědu s návodem na vizuální kontrolu provedení svarového spoje.



Obrázek 22 - Náhled návrhu AR aplikace v prostředí Unity

5 Závěr

V předloženém textu byla představena problematika spojení dvou dynamicky se rozvíjejících technologií zásadních pro Industry 4.0, Augmented Reality a Artificial Intelligence, a potenciál jejich spojení pro účely podpory pracovníků přímo na pracovišti při kontrolních úkolech svařovacích operací.

Na základě výstupů teoretické rešerše byla navržena případová studie a představena aplikace rozšířené reality pro následné experimentální testování na reprezentativním vzorku uživatelů. Navržený AR nástroj byl vytvořen v prostředí Unity s podporou SDK Vuforia Engine a s využitím deep learning algoritmů pro automatické rozpoznání a identifikaci kontrolovaného dílu. Úkolem navržené AR aplikace je snížení kognitivní zátěže na operátory kontroly kvality a snížení nutnosti vysoké míry odborné kvalifikace a zkušeností.

Cílem dalšího projektu je dokončení AR nástroje pro účely experimentů a její otestování na vybraném vzorku uživatelů pro posouzení použitelnosti na základě objektivních i subjektivních parametrů. Experimenty s uživateli budou provedeny pro sledování kvalitativních a kvantitativních parametrů použitelnosti navrženého nástroje.

Poděkování

Příspěvek byl vytvořen za podpory projektu SGS-2021-028 s názvem "Vývojové a tréninkové prostředky pro interakci člověka a kyber-fyzického výrobního systému" řešeného v rámci Interní grantové agentury Západočeské univerzity v Plzni.

Použitá literatura

- [1] Xu, L.D., Xu, E.L., Li, L., 2018. Industry 4.0: state of the art and future trends. *Int. J. Prod. Res.* 56 (8), 2941–2962, <http://dx.doi.org/10.1080/00207543.2018.1444806>.
- [2] Romero, D., Stahre, J., Taisch, M., 2020]. The Operator 4.0: towards socially sustain-able factories of the future. *Comput. Ind. Eng.* 139, <http://dx.doi.org/10.1016/j.cie.2019.106128>.
- [3] Azuma, Ronald, Yohan Baillot, Reinhold Behringer, Steven Feiner, Simon Julier, and Blair MacIntyre. 2001. "Recent Advances in Augmented Reality." *IEEE Computer Graphics and Applications* 21 (6): 34–47..
- [4] Thomas, P. C., and W. M. David. 1992. "Augmented Reality: An Application of Heads-up Display Technology to Manual Manufacturing Processes." *Hawaii international conference on System Sciences, Kauai, HI*, 659–669..
- [5] Backs, R.W., Seljos, K.A., 1994. Metabolic and cardiorespiratory measures of men-tal effort: the effects of level of difficulty in a working memory task. *Int. J. Psychophysiol.* 16 (1), 57–68, [http://dx.doi.org/10.1016/0167-8760\(94\)90042-6](http://dx.doi.org/10.1016/0167-8760(94)90042-6).
- [6] Barbieri, L., Marino, E., 2019. An augmented reality tool to detect design discrepan-cies: a comparison test with traditional methods. *International Conference on Augmented Reality, Virtual Reality and Computer Graphics*, 99–110, http://dx.doi.org/10.1007/978-3-030-25999-0_9.
- [7] Egger, J., Masood, T., 2020. Augmented reality in support of intelligent manufacturing – a systematic literature review. *Comput. Ind. Eng.* 140, 106195, <http://dx.doi.org/10.1016/j.cie.2019.106195>.
- [8] F. A. Barreiro, A. J. Barreiro, L. D. Aguirre M. A. Simiand, Applying New Technologies: Virtual Reality (VR) & Augmented Reality (AR) applied to the Iron & Steel industry from Training to Commissioning, SCADA and Plant Simulation.
- [9] Kranzer, S., Prill, D., Aghajanpour, D., Merz, R., Strasser, R., Mayr, R., Steringer, R., 2017. An intelligent maintenance planning framework prototype for pro-duction systems. 2017 IEEE International Conference on Industrial Technology (ICIT), 1124–1129, <http://dx.doi.org/10.1109/ICIT.2017.7915520>.
- [10] Leutert, F., Schilling, K., 2015. Augmented reality for Telemaintenance and - inspection in force-sensitive industrial robot applications. *IFAC Papers On Line* 48(10), 153–158, <http://dx.doi.org/10.1016/j.ifacol.2015.08.124>.
- [11] Sauer, S., Berndt, D., Schnee, J., et al., 2011. Worker assistance and quality inspec-tion: application of optical 3D metrology and augmented reality

- technologies. 14th Joint International IMEKO TC1, TC7, TC13 Symposium on Intelligent Quality Measurements - Theory, 112–113.
- [12] Jayaweera, M., Wijesooriya, I., Wijewardana, D., et al., 2017. Enhanced Real-time machine inspection with Mobile augmented reality for maintenance and repair. Proceedings of the 2nd ACM/IEEE International Conference on Internet-of-Things Design and Implementation, 287–288, <http://dx.doi.org/10.1145/3054977.3057302>.
- [13] Antonelli, D., Astanin, S., 2015. Enhancing the quality of manual spot welding through augmented reality assisted guidance. Procedia Cirp 33, 556–561, <http://dx.doi.org/10.1016/j.procir.2015.06.076>.
- [14] Ashish, D., Smith, R.T., Thomas, B.H., et al., 2017. Use of projector based augmented reality to improve manual spot-welding precision and accuracy for automotive manufacturing. Int. J. Adv. Manuf. Technol. 89 (5– 8), 1279–1293, <http://dx.doi.org/10.1007/s00170-016-9164-5>.
- [15] Georgel, P., Schroeder, P., Benhimane, S., Hinterstoisser, S., Appel, M., Navab, N., 2007. An industrial augmented reality solution for discrepancy check. 2007 6th IEEE and ACM International Symposium on Mixed and Augmented Reality, 111–115, <http://dx.doi.org/10.1109/ISMAR.2007.4538834>.
- [16] Wasenmüller, O., Meyer, M., Stricker, D., 2016. Augmented reality 3d discrepancy check in industrial applications. 2016 IEEE International Symposium on Mixed and Augmented Reality (ISMAR), <http://dx.doi.org/10.1109/ISMAR.2016.15>.
- [17] Lee, J.M., Lee, K.H., Kim, D.S., Kim, C.H., 2010. Active inspection supporting system based on mixed reality after design and manufacture in an offshore structure. J. Mech. Sci. Technol. 24 (1), 197–202, <http://dx.doi.org/10.1007/s12206-009-1129-2>.
- [18] Ramakrishna, P., Hassan, E., Hebbalaguppe, R., Sharma, M., Gupta, G., Vig, L., Shroff, G., 2016. An ar inspection framework: feasibility study with multiple ar devices. 2016 IEEE International Symposium on Mixed and Augmented Reality (ISMAR-Adjunct), 221–226, <http://dx.doi.org/10.1109/ISMAR-Adjunct.2016.0080>.
- [19] He, F., Ong, S.K., Nee, A.Y., 2019. A mobile solution for augmenting a manufacturing environment with user-generated annotations. Information 10 (2), 60, <http://dx.doi.org/10.3390/info10020060>.
- [20] An Augmented Reality inspection tool to support workers in Industry 4.0 environments. In: MARINO, Emanuele, Loris BARBIERI, Biagio COLACINO, Anna Kum FLERI a Fabio BRUNO. Computers in Industry. Volume 127. 2021. ISSN 0166-3615,. Available: doi:<https://doi.org/10.1016/j.compind.2021.103412>.
- [21] Liu, Ying, Rahul Rai, Anurag Purwar, Bin He, and Mahesh Mani. 2020. “Machine Learning Applications in Manufacturing.” Journal of Computing and Information Science in Engineering 20 (2): 020301. doi:10.1115/1.4046427.

- [22] Zhang, Xianyu, Xinguo Ming, Zhiwen Liu, Dao Yin, Zhihua Chen, and Yuan Chang. 2019. "A Reference Framework and Overall Planning of Industrial Artificial Intelligence (I-AI) for New Application Scenarios." *The International Journal of Advanced Manufacturing Technology* 101 (9–12): 2367–2389.
- [23] Park, Kyeong-Beom, Minseok Kim, Sung Ho Choi, and Jae Yeol Lee. 2020. "Deep Learning-based Smart Task Assistance in Wearable Augmented Reality." *Robotics and Computer- Integrated Manufacturing* 63: 101887.
- [24] Rüßmann, Michael, Markus Lorenz, Philipp Gerbert, Manuela Waldner, Jan Justus, Pascal Engel, and Michael Harnisch. 2015. "Industry 4.0: The Future of Productivity and Growth in Manufacturing Industries." *Boston Consulting Group* 9 (1): 54–89. Accessed 14 May 2020. https://www.bcg.com/publications/2015/engineered_products_project_business_industry_4_future_productivity_growth_manufacturing_industries.
- [25] Yao, Xifan, Jiajun Zhou, Jiangming Zhang, and Claudio R. Boër. 2017. "From Intelligent Manufacturing to Smart Manufacturing for Industry 4.0 Driven by Next Generation Artificial Intelligence and Further On." 5th International conference on Enterprise Systems (ES), Beijing, China, 311–318. IEEE.
- [26] Tao, Fei, Qinglin Qi, Ang Liu, and Andrew Kusiak. 2018. "Data driven Smart Manufacturing." *Journal of Manufacturing Systems* 48: 157–169.
- [27] Yacob, Filmon, Daniel Semere, and Erik Nordgren. 2019. "Anomaly Detection in Skin Model Shapes Using Machine Learning Classifiers." *The International Journal of Advanced Manufacturing Technology* 105 (9): 3677–3689.
- [28] Bajic, B., I. Cosic, M. Lazarevic, N. Sremcevic, and A. Rikalovic. 2018. "Machine Learning Techniques for Smart Manufacturing: Applications and Challenges in Industry 4.0." 9th International Scientific and Expert Conference, TEAM2018, Novi Sad, Serbia, 29.
- [29] B. Furht. "Handbook of Augmented Reality". 1th ed. New York, NY: Springer New York, 2011.
- [30] Google ARCore. Google Developers [online]. 2021 [cit. 2021-9-17]. Available: <https://developers.google.com/ar>
- [31] Augmented Reality: Apple Developer [online]. Apple, 2021 [cit. 2021-9-17]. Available: <https://developer.apple.com/augmented-reality/>
- [32] Vuforia. "Vuforia Engine Features". Available: <https://library.vuforia.com/content/vuforia-library/en/features/overview.html>. Accessed on 202- 09-15.
- [33] Barbieri, L., Angilica, A., Bruno, F., Muzzupappa, M., 2012. An interactive tool for the participatory design of product interface. In: ASME 2012 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference, American Society of Mechanical Engineers, pp. 1437–1447, <http://dx.doi.org/10.1115/DETC2012-71097>.