



Fakulta zemědělská
a technologická
Faculty of Agriculture
and Technology

Jihočeská univerzita
v Českých Budějovicích
University of South Bohemia
in České Budějovice

JIHOČESKÁ UNIVERZITA V ČESKÝCH BUDĚJOVICÍCH FAKULTA ZEMĚDĚLSKÁ A TECHNOLOGICKÁ

Katedra techniky a kybernetiky

Diplomová práce

Optimalizace navádění robotické ruky pro účely dojení

Autor práce: Mgr. Pavel Olšan, Ph.D.

Vedoucí práce: Mgr. Zbyněk Havelka, Ph.D.

České Budějovice
2022

Prohlášení

Prohlašuji, že jsem autorem této kvalifikační práce a že jsem ji vypracoval pouze s použitím pramenů a literatury uvedených v seznamu použitých zdrojů.

V Českých Budějovicích dne

.....

Mgr. Pavel Olšan, Ph.D.

Abstrakt

Diplomová práce se zabývá problematikou optimalizace navádění robotické ruky využívané při nasazování strukových násadců ve spojitosti s robotickým dojením. Výsledky byly rozděleny na několik dílčích částí:

1. Popsání hlavních parametrů a nastavení procesu vidění a detekce objektů
2. Postupy při nastavení procesů
3. Volba ideálních parametrů
4. Tvorba výstupního programu pro robotické rameno

Diplomová práce byla realizována v rámci projektu MPO TRIO FV40316 – Vývoj komplexu modulárního systému robotizovaného dojení za současného hodnocení parametrů chovu aplikací metod umělé inteligence.

Klíčová slova: dojení; robotické rameno; zpracování obrazu

Abstract

The thesis deals with the optimization of the robotic arm guidance used in the deployment of teat handles in connection with robotic milking. The results were divided into several subparts:

1. Describing the main parameters and settings of the vision and object detection process
2. Process setup procedures
3. Choosing the ideal parameters
4. Creating an output program for the robotic arm

The thesis was realized within the MIT TRIO project FV40316 – Development of a complex modular system of robotic milking with simultaneous evaluation of breeding parameters by application of artificial intelligence methods.

Keywords: milking; robotic arm; image processing

Poděkování

Na tomto místě chci poděkovat mému vedoucímu, Mgr. Zbyňku Havelkovi, Ph.D. za trpělivost, vstřícnost, přátelský přístup a velký počet rad, postřehů a myšlenek, díky kterým tato práce mohla vzniknout.

Můj velký dík patří celé mé rodině, za podporu a vstřícnost, kterou mi věnovali po celou dobu studia.

Obsah

Úvod	7
1 Literární rešerše	8
1.1 Dojírny	8
1.1.1 Rybinové dojírny	8
1.1.2 Paralelní dojírny	9
1.1.3 Tandemové dojírny	9
1.1.4 Kruhové dojírny	10
1.2 Robotizace zemědělství	10
1.3 Robotické dojení	11
1.3.1 Hlavní prvky robotických zařízení	13
1.3.2 Výrobci robotických dojíren	15
1.4 Navádění	18
2 Metodika a cíle práce	26
3 Zařízení použitá v experimentu	27
3.1 StimuLactor	27
3.1.1 Předstimulace	31
3.1.2 Hlavní dojení	31
3.1.3 Čištění	31
3.2 Robotická ruka FANUC Robot M-20iB/25	31
3.3 Umístění robota	33
4 Výsledky	37
4.1 Popis základních parametrů procesu vidění	38
4.2 Nastavení parametrů a postup procesu vidění	41
4.3 Proces učení aplikací nástroje GPM Locator Tool	42
4.4 Postup nastavení měření 3D roviny	43
4.5 Postup nastavení referenční pozice	44
4.6 Realizace úkonů robotické ruky na základě vytvořeného programu	45
5 Diskuze	47
Závěr	49
Seznam použitých zdrojů	50

Seznam obrázků	56
Seznam tabulek	57

Úvod

Již řadu let existují automatizované systémy pro strojové dojení. Znamé jsou například robotické dojící stroje. Dojící robot se obvykle skládá z ramene, které připojuje dojící jednotku k jakémukoli druhu dojného dobytka. Další operace ramene dojícího robota mohou zahrnovat sejmutí dojící jednotky z dobytka, umístění dojící jednotky do pouzdra nebo čištění struků. Znamé systémy a metody však trpí řadou nevýhod. Rameno dojícího robota se například pohybuje na poměrně velké vzdálenosti a zabírá velké prostory. Například pro připojení dojící jednotky k dobytku musí rameno vstoupit do stáje s dobyttem a vystoupit z ní. Mléko se například nedojí přímo do hlavní mléčné linky. Lidská obsluha nemůže kvůli provozu robota přijít do těsného kontaktu s dobyttem. Znamé systémy vyžadují montáž celé nové dojící plošiny nebo přinejmenším vyžadují zásadní změny ve stávající dojící plošině, protože je nelze jednoduše začlenit a namontovat do jakéhokoli typu stávající dojící plošiny. Mnohé z výše popsaných nevýhod vyplývají z koncepce, že zvíře vstupuje do určité robotické zóny, ve které je ošetřováno a dojeno pomocí průmyslových robotických ramen, která jsou uzpůsobena k dojení a podobně. Proto, aby bylo možné takovou robotickou zónu zkonstruovat, je třeba celou dojírnu přestavět a použít průmyslové robotické rameno.

Při dojení se již v praxi využívají automatické dojící systémy (AMS), které mohou nahradit člověka při této činnosti. Myšlenka automatického systému vznikla v Nizozemsku a jejím primárním cílem bylo uspořít pracovní sílu a zvýšit produkci mléka. AMS provádí dojení bez přímé účasti člověka a umožňují dojení po celý den. AMS zvyšuje dojivost krav a zároveň umožňuje monitoring a záznam hodnot jako je doba dojení, čas strávený v dojícím boxu nebo počet dojení za den. Měřené hodnoty mohou být v reálném čase ukládány do databáze (Carlström et al., 2013). První AMS byl uveden do provozu již v roce 1992 a od té doby počet těchto systémů celosvětově stoupá (Bijl et al., 2007; Castro et al., 2012). Z výsledků měření u 62 farem vyplývá, že AMS systémy snížily manuální práci o 29 % v porovnání s konvenčními systémy dojení.

Hlavními výhodami robotizovaného systému dojení, který využívá systém analýzy obrazu je nahrazení nedostatku lidské pracovní síly a vynechání jejich chybovosti a nepřesnosti, nízká spotřeba vody a desinfekčních prostředků se zvýšením efektivity procesu prostřednictvím zlepšení welfare zvířat.

Cílem diplomové práce byla optimalizace navádění robotické ruky firmy Fanuc pro použití lokalizace a detekce struků. Byly hledány optimální parametry a podmínky, při nichž bylo navádění účinné a bezchybné. Výsledky práce jsou získané na základě části experimentu v rámci projektu MPO TRIO FV40316 – Vývoj komplexu modulárního systému robotizovaného dojení za současného hodnocení parametrů chovu aplikací metod umělé inteligence.

1 Literární rešerše

1.1 Dojírny

Klasické dojírny jsou dojicí stání, uspořádaná ve stájích, vybavených dojicím zařízením. Dojí se přímo do potrubí přes odměrné nádoby nebo přes průtokoměry. K dojírně patří i další prostory jako jsou čekárna, přípravné boxy, manipulační prostory, strojovna, mléčnice apod. Proces nasazování a snímání dojicího zařízení na struky, přípravy struků, čištění dojicí soustavy provádí člověk, který se pohybuje v manipulační chodbě mezi zvířaty. Tyto klasické konvenční dojírny se dělí dle svého vnitřního uspořádání (stání jsou po obvodu geometrických obrazců, šikmo/kolmo k manipulační chodbě atd.).

1. Základní dělení podle způsobu dojení (Doležal, 2000):


- individuální
- skupinové

2. Podle uspořádání stání:

- stání vedle sebe (paralelní)
- stání za sebou (tandemové)
- s pohyblivým dojicím stáním
- s pevným dojicím stáním

1.1.1 Rybinové dojírny


Rybinové, jinak nazývané se stáním šikmo vedle sebe, patří mezi nejrozšířenější dojírny se stacionárním stáním a řadí se mezi klasické dojírny se skupinovým způsobem dojení. Během dojení jedné skupiny nastupuje a je připravována skupina druhá. Stání ve skupinách jsou umístěna šikmo vedle sebe s odklonem od podélné osy o 35°. V prostřední části v podélné ose dojírny je umístěno pracoviště dojiče, které je od nulové roviny zapuštěno o 0,7 m–0,75 m. V rámci skupinového způsobu dojení je nutná vyrovnanost stáda uvnitř každých skupin. Jen tak je zaručena účinná dojivost a dojitelnost. Krávy jsou uspořádány po obou stranách manipulační chodby, což je prostor, kde se pohybuje dojič. Vhodný počet stání pro tuto dojírnu je 2 × 5 při obsluze jedním dojičem (obrázek 1.1) (Doležal, 2000).



Obrázek 1.1: Rybinová dojírna

1.1.2 Paralelní dojírny

Tento typ dojírny je někdy označován jako side-by-side a zastupuje individuální způsob dojení. Manipulační prostor pro dojiče je umístěn ve stejné úrovni jako stání. Dojnice postupně přicházejí na jednotlivá stání a řadí se pod úhlem 90° vůči manipulační chodbě. Obsluha dojírny nasazuje strukové násadce na vemeno zezadu mezi nohama. Dojnice vcházejí do dojírny po obou stranách rovnoběžně s chodbou pro dojiče a vystupují ve směru svých stání. Celá skupina dojnic opouští dojicí prostor místem s otočnou bránou (obrázek 1.2) (Andrt, 2011).

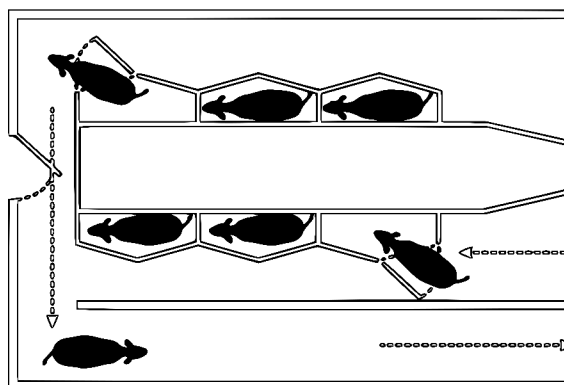


Obrázek 1.2: Paralelní dojírna

1.1.3 Tandemové dojírny

Tandemové dojírny, nazývané jako stání za sebou, využívají jak individuálního, tak skupinového způsobu dojení. Dojnice stojí bokem do pracovní, snížené chodby pro dojiče, která je zapuštěna o cca 0,75 m pod úroveň stání. Nejběžnější je uspořádání ve dvou řadách s počtem stání např. 2x4 a pracovní chodbou uprostřed. Dojnicí se návazně ošetřují vemena, poté se nasazují strukové násadce, ihned po nasazení musí započít dojení a ve stejnou chvíli jsou na protější straně připravovány další dojnice. Po ukončení dojení se první

skupina vypouští ven a následně na stání přichází další skupina (obrázek 1.3) (Bouška, 2006). Tento typ dojírny již může být částečně automatizován a to pomocí automatického otevírání stání.



Obrázek 1.3: Tandemová dojírna

1.1.4 Kruhové dojírny


V souvislosti se zvyšujícím se počtem kusů ve stádě se staly populárními kruhové dojírny a začaly se objevovat rotační platformy schopné dojit 60–80 krav najednou (McGuffey a Shirley, 2016). Kruhové dojírny jsou konstrukčně velmi náročné stavby. Aktuálně se upouští od složitých mechanických řešení, a tak jsou moderní kruhové dojírny umístěné na vodním polštáři. To vede ke snížení poruchovosti, množství hluku a zvýšení welfare ve stáji.

Kruhové dojírny jsou děleny dle stání a umístění dojicího zařízení.

- stání za sebou – Každé jednotlivé stání obsluhuje samostatný dojicí stroj s odměrnou lahví, z té je mléko podtlakem odváděno potrubím do mléčnice. Obsluha přistupuje ke stání ze středu kruhu.
- stání vedle sebe – Dojnice přistupují ke stání a umísťují se hlavami směrem ke středu kruhu. Obsluha přistupuje ke stání z vnějšího obvodu otočné plošiny (obrázek 1.4). Dojnice z dojírny po vydojení couvají ven.

1.2 Robotizace zemědělství

Zvýšený zájem o rozvoj přesného a inteligentního zemědělství podnítil vědeckou diskusi o využití umělé inteligence a robotiky v zemědělských výrobních systémech. Inteligentní a automatizované systémy pro zemědělské operace mají zásadní význam při řešení problému nedostatku pracovních sil, provádění opakujících se úkolů, snižování bezpečnosti a zdravotního rizika pro člověka při provádění zemědělských činností a snižování výrobních nákladů úsporou času, peněz a energie (Gongal et al., 2015). Existuje mnoho příkladů funkčních zařízení pro zemědělské, výrobní a zpracovatelské úkoly, jako jsou přesazovací stroje, roubovací stroje, přesný postřikovací systém, přesný zavlažovací systém, systém



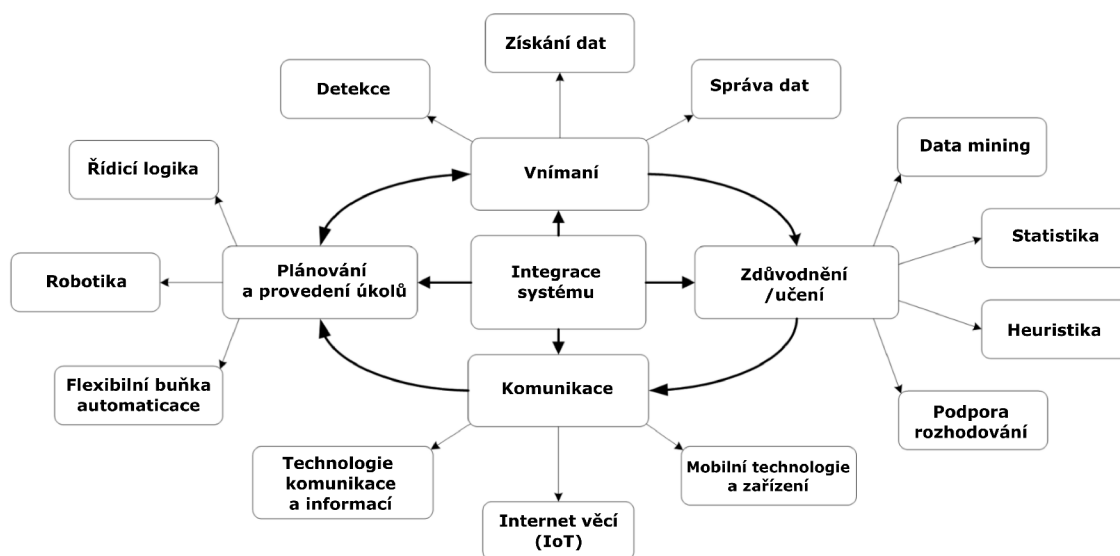
Obrázek 1.4: Kruhová dojírna

kontroly plevelu, inteligentní řídicí systém ve sklenících, sklizňové roboty, UAV (Unmanned Aerial Vehicle), UGV (Unmanned Ground Vehicle), stříhací roboty, porážecí roboty atd. (Kondo a Ting, 1998; Tai et al., 1994).

V posledních letech přinesly aplikace automatizačních technologií znatelné zlepšení zemědělské výroby. Schopnosti strojů podobné lidským, včetně vnímání, uvažování a učení, komunikace, plánování a provádění úkolů a systémové integrace, byly a budou základními předpoklady pro inteligentní automatizační systémy v zemědělství. Schopnost vnímání poskytuje informace prostřednictvím snímání pro získávání a správu dat. Využívá se k lepšímu porozumění okolnímu prostředí. Často se má za to, že bohatství a hodnota inteligence se zvyšuje prostřednictvím forem dat, informací, znalostí a moudrosti (zkráceně DIKW), které vznikají v procesech uvažování a učení. Kromě toho se stala dostupnou podpora rozhodování založená na výsledcích statistické analýzy a heuristického dolování dat. Cílem komunikace je vhodně informovat a získávat odpovědi mezi složkami pro správné monitorování a řízení systému. Často je prezentována ve formách zahrnujících informační a komunikační technologie (ICT), internet věcí (IoT) a mobilní technologie a zařízení. Plánování a provádění úkolů, propojující rozhodnutí a akce, jsou funkce, které vykonávají inteligentní stroje, flexibilní automatizační pracovní buňky a roboty, aby dokončily fyzickou práci pod určitou formou logického řízení. Různé kombinace a integrace schopností strojů podobných člověku vytvářejí "systém systémů". Inteligence v podobě „moudrosti“ podobné té lidské je obvykle nasazována k řízení „akcí“ strojů. Integrace systému rozšiřuje DIKW na DIKW-akce (tj. DIKWA), a vytváří tak kompletní hodnotový řetězec inteligence. Na obrázku 1.5 je zobrazen "systém systémů" sestávající ze čtyř schopností strojů podobných člověku, v jehož rámci může každá schopnost stroje tvořit samostatný subsystem. Prostřednictvím kombinací různých strojových schopností by bylo možné konfigurovat širokou škálu systémů. Ve většině případů je nutná určitá forma systémové integrace, aby bylo zajištěno, že všechny součásti v rámci systému, například inteligentní zemědělské výroby, budou fungovat lépe a společně (Ren et al., 2015).

1.3 Robotické dojení

Při dojení se již v praxi využívají automatické dojící systémy (AMS), které mohou nahradit člověka při této činnosti. Myšlenka automatického systému vznikla v Nizozemsku a jejím primárním cílem bylo uspořít pracovní sílu a zvýšit produkci mléka. AMS provádí dojení



Obrázek 1.5: "Systém systémů", který se skládá ze čtyř strojů podobných člověku.

bez přímé účasti člověka a umožňují dojení po celý den. AMS zvyšuje doживost krav a zároveň umožňuje monitoring a záznam hodnot jako je doba dojení, čas strávený v dojicím boxu nebo počet dojení za den. Měřené hodnoty mohou být v reálném čase ukládány do databáze (Carlström et al., 2013). První AMS byl uveden do provozu již v roce 1992 a od té doby počet těchto systémů celosvětově stoupá (Bijl et al., 2007; Castro et al., 2012). Z výsledků měření u 62 farem vyplývá, že AMS systémy snížily manuální práci o 29 % v porovnání s konvenčními systémy dojení.


Pro úspěšné zaznamenání naměřených hodnot u dojnic je důležitá správná identifikace zvířat. Ta se nejčastěji provádí pasivně pomocí tzv. štítků na základě přenosu rádiových vln (RFID). RFID se vyznačuje levným provozem, nicméně připevnění štítků je časově náročným procesem a pro zvíře stresující. Mezi další nevýhody patří omezený dosah a náchylnost k rušení (Hansen et al., 2018). Na druhou stranu je možné aktivně rozpoznávat zvíře na základě specifických rysů prostřednictvím zpracování obrazu. Rozpoznávání obličeje je již minimálně pět desetiletí v zájmu vědeckého výzkumu a nyní je ve stádiu používání pro tuto činnost na základě algoritmů a architektury neuronových sítí. Používají se zejména dva přístupy, a to srovnávací metoda FisherFaces a přístup hlubokého učení za pomoci neuronových sítí. Například Hansen et al. (2018) provedl výzkum využití aktivního rozpoznání prasat podle jejich obličeje. Při použití 1553 snímků skupiny deseti prasat dosáhla tato metoda míry přesnosti 96,7 % (Hansen et al., 2018; Zhao a Chellappa, 2006).

Motivace pro instalaci systému AMS mohou být různé. Hogeveen et al. (2004) zaznamenal 5 motivací, které vedly zemědělce k investici do AMS namísto konvenčního systému dojení: méně práce, větší flexibilita, možnost dojit krávy více než dvakrát denně, nahrazení zaměstnance nebo potřeba nového systému dojení. Stejně jako u jiných investic je však důležité optimalizovat účinnost stroje, aby se náklady na systém brzy vrátily. Důležitými funkčními aspekty systému AMS jsou mléčná užitkovost, frekvence dojení, intervaly mezi dojeními, úspěšnost připevnění struků a délka dojení (Gygax et al., 2007; Sonck a Donkers, 1995).

Automatické dojení (AM) je jedním z kroků v řadě opatření přijatých za účelem automatizace výroby mléka. V mnoha zemích prochází mlékárenský průmysl strukturálními

změnami a farmy se zvětšují. Vzhledem k vysokým nákladům na pracovní sílu se automatické dojení stává stále běžnějším. Na světě existuje více než 8 000 farem s automatickým dojením, z nichž 90 % se nachází v severozápadní Evropě, včetně Skandinávie (Koning, 2010).

Pinsky (2017) vynalezl robotickou jednotku pro instalaci do dojírny, jejímž úkolem je nasazovat dojicí násadce na struky. Mobilní jednotka se skládá ze zařízení pro ošetřování hospodářských zvířat a procesoru, přičemž mobilní jednotka je konfigurována tak, aby se pohybovala mezi předními a zadními končetinami dojnic na rampě dojírny a používala zařízení k provedení alespoň jednoho úkonu souvisejícího s ošetřováním dojnic (obrázek 1.6).



Obrázek 1.6: Patent 1

Berg (2013) vynalezl robotickou jednotku pro obsluhu dojnic v dojírně, která je nainstalovaná na mobilní platformě. Platforma se může pohybovat minimálně ve dvou směrech. Robotická ruka pak provádí různé operace při nasazování struků či jejich čištění (obrázek 1.7).


1.3.1 Hlavní prvky robotických zařízení

Řídicí jednotka

Řídicí jednotka je hlavní součástí robotických zařízení. Nejčastěji je konstruována pomocí programovatelných logických obvodů – PLC. Ovládání těchto jednotek je možné prostřednictvím různých komunikačních protokolů a zařízení, jenž nejčastěji tvoří PC případně ovládací tablet, někdy označovaný jakou Teach Pendant (Iwamura et al., 2022; Park et al., 2011)

Vstupní brána

Vzhledem k tomu, že některé dojnice navštěvují stroj mnohokrát denně, je žádoucí, aby selekční brána umožňovala identifikaci konkrétního zvířete. Některé typy vstupních bran jsou opatřeny zařízením pro detekci říje, stejně jako měřením hmotnosti či zařízením, které krávu přiměje k odchodu ze vstupní brány (Devir et al., 1996).



Obrázek 1.7: Patent 2

Identifikace zvířete

Pro specifické rozpoznávání zvířat slouží systém Dairy Management System. Identifikace zvířat se pak provádí pomocí infračervených nebo radiofrekvenčních zařízení (RFID) připojených k tělu zvířete. Vysílače mohou být umístěny na noze zvířete, na jeho krku nebo obojku. Často se využívají tzv. transpondéry implantované pod kůži, bachorové bolusy a další systémy. Značkování zvířat umožňuje zemědělcům lepší sledovatelnost, lepší kontrolu chovu, lepší ochranu přírody a samozřejmě sběr dat o každém zvířeti ve stádě. Technologie RFID může také hrát významnou roli při automatickém krmení, sledování přezvykávání, vážení a kontrole zdravotního stavu (Kitikov, 2009; Saha et al., 2022).

Robotické rameno

Rameno je důležitým prvkem dojícního nebo robotického zařízení. Jeho klíčovou částí je optický systém skládající se z kamery nebo senzoru. Další důležitou součástí uchopovacích zařízení, které se někdy nazývá „Gripper“ (Robots, 2022). Rameno operuje ve složitých podmínkách dojírny, proto zásadní vlastností je jeho pevnost a odolnost vůči kontaktu s krávou. Cílem výrobců je snížit riziko poškození ramene v situaci, kdy zvíře údeří rameno a zároveň může rameno nepřiměřenou silou či chybou v navádění poranit zvíře (Maixner, 2006).

Dále mezi hlavní součásti robotických zařízení pro dojení patří:

- systém čištění struků a stroje samotného
- systém stimulace struků
- systém nasazování strukových násadců

1.3.2 Výrobci robotických dojíren

Níže uvedené společnosti nabízejí plně autonomní zařízení, to znamená, že svoji základní roli, tj. dojení, jsou zařízení schopna plnit autonomně, bez lidského zásahu. Vyžadují však pravidelný servis a údržbu, což jsou činnosti, které se bez lidského faktoru neobejdou. Protože jde o plně autonomní stroje, očekává se od nich, že budou automaticky splňovat určité činnosti (např. automatickou identifikaci zvířete, čištění a přípravu struku před dojením, automatické nasazení/znovunasazení strukového kalíšku, sejmutí po ukončení dojení, očištění struku i strukových násadců, automatické vyhodnocení kvality mléka). To vše musí proběhnout bez negativních vlivů na zvíře. Vzhledem k různé geometrii struků a rozložení vemene může být nasazení strukových kalíšků v některých případech obtížnější a může dojít i k tomu, že kráva opustí dojícího robota, aniž by byla podojena. Proto je systém navádění a nasazování neustále zdokonalován, aby bylo možné podojit větší procento krav.

Lely

Nejpoužívanějšími dojícími roboty v České republice jsou roboty Astronaut nizozemské společnosti Lely.

Roboty využívají pneumatické systémy k pohonu kinetických částí stroje, přičemž minimalizují počet pohybů při vkládání a vyjímání strukových násadců. Všechny roboty jsou navrženy tak, aby byla jejich údržba snadná. Pokud robot splňuje základní požadavek jednoduchosti a rychlosti, může výrazně zvýšit produktivitu. Roboti potřebují maximálně 4 pravidelné údržby ročně.

Dojící stroj Lely Astronaut (viz obrázek 1.8) se vyznačuje hybridním ramenem, které se nachází po celou dobu dojení pod krávou a dokáže rychle reagovat v případě shoení násadce ze struku. Pneumatický válec přenáší váhu ramene téměř bez námahy, zatímco elektrické části přesně manipulují s komponenty. Rameno má nízkou spotřebu energie a rychlé pohyby díky přesnému pohonu. Představuje větší pohodlí pro krávy díky tichému provozu a snadnější údržbu díky snadnému přístupu. Navádění strukových násadců se provádí pomocí laseru se třemi paprsky (TDS – Teat Detection Sensor).

Společnost Lely využívá systém „plug and play“, který je známý z různých elektronických zařízení. Plug and Play ve vztahu k robotickým dojírnam umožňuje jednoduchou aplikaci a připojení v jakékoli stáji. Konstruktoři robotů Lely proto cílí na minimalizaci počtu pohyblivých částí robotů Lely se snahou snížit riziko potenciálních poruch (Lely, 2022).

DeLaval

Mezi další využívané robotické dojírny v naší zemi patří švédská společnost DeLaval (obrázek 1.9). Robotická ramena oproti firmě Lely využívají hydraulické systémy k pohonu pohyblivých částí. Výrobce tuto technologii považuje za přesnější s nižší pravděpodobností mechanických poruch. Jako pracovní kapalina v těchto hydraulicky řízených strojích je obvykle použit olej pod tlakem.

Na rozdíl od společnosti Lely využívá DeLaval technologii pro individuální přípravu každého jednotlivého struku. Každý struk je před započatým dojením zvláště očištěn a dezinfikován teplou vodou a vzduchem, poté se stimulují, předdojí a nakonec vysuší.



Obrázek 1.8: *Lely Astronaut*

Každý strukový násadec má vlastní mléčnou linku, díky které je zabráněno znečištění mléka.

DeLaval využívá k navádění strukového násadce systém s optickou kamerou a duálním laserem. Tato společnost má vlastní kontrolní software, který umožňuje také připojení k počítači nebo jiným, třeba bezdrátovým technologiím. Software DelPro se používá pro kontrolu kvality mléka. Kráva je také identifikována pomocí krokoměru, který se nachází v obojku (DeLaval, 2022).



Obrázek 1.9: *DeLaval*

Fullwood

Tato společnost má robota nesoucího název Merlin 225 (obrázek 1.10). Robot má k dispozici možnost pneumaticky poháněného robotického ramene, které nese strukové násadce. Navádění ramene a detekce struků jsou provedeny laserem, který je přímo uchycen na

rameni robota. Společnost Fullwood se pokoušela snížit počet pneumatických válců v systému, aby zmenšila množství poruch daných strojů. Čištění struků probíhá pomocí válečků s dezinfekční tekutinou.

K rozeznání vstupujících zvířat jsou využity transpondéry, ty se nejčastěji umísťují na ucho nebo krk. Dále je možné využít tzv. pedometrů, které jsou třeba umístěny na noze daného zvířete.

Řídicí systém, který používá společnost Fullwood se jmenuje Crystal a je založen na operačním systému Vista. Stejně jako robot konkurenční společnosti, umožňuje Crystal také real-time kontrolu stáda a zprostředkovává aktuální dostupné informace o každém zvířeti zvlášť, stejně tak, jako informace o stroji. Rozbor mléka je prováděn zařízením CrystaLab, které lze zakoupit samostatně (Fullwood, 2022).



Obrázek 1.10: Robot společnosti Fullwood

GEA

Předchozí výrobci byli orientováni na koncepci monoboxového stání, kdy jednu dojnici obsluhuje právě jeden robot či robotické rameno. Společnost GEA se specializuje na multiboxová zařízení. Dojicí stání je modulární, tzn. je možné přidávat zařízení za sebou do série. Celé toto dojicí soustrojí až pěti stání je po celou dobu obsluhováno jednou robotickou paží (obrázek 1.11).



Obrázek 1.11: Robotická dojírna společnosti GEA

Robot GEA MI one je tvořen z jednoho stání, které je modulární a lze k němu přidat až 4 další dojírny v řadě za sebou. Touto variabilitou je umožněno přizpůsobení se velikosti

stáda. Každé stání je spojeno manipulačním prostorem, do něhož zasahuje pouze jedno robotické rameno.

Systém MIone je možné považovat za plně pneumatický, stejně tak, jako u robotů Astronaut nebo Merlin. MIone, obdobně jako společnost Lely, používá 3D kameru k identifikaci jednotlivých struků a strukových násadců. Osvědčená technologie GEA In-Liner Everything provádí všechny kroky procesu dojení – stimulaci, čištění struků, stahování struků, sběr mléka a následné namáčení – v jediném nástavci. Tento jednotný, rychlý a pohodlný proces probíhá uvnitř strukového násadce, je klíčem ke sklizni mléka vynikající kvality a zároveň maximalizuje efektivitu robotického dojícího zařízení (obrázek 1.12) (Gea, 2022).



Obrázek 1.12: GEA In-Liner Everything

1.4 Navádění

Systém snímání struků by měl být schopen dostatečně rychle a zároveň přesně určit souřadnice prostoru, aby aplikace mohla být úspěšná a zároveň neinvazivní pro zvíře. Zařízení by se nemělo při lokalizaci struků zvířete dotýkat, aby nedošlo k nechtěné provokaci a rozrušení zvířete. Senzorový systém musí také odpovídat konkrétním podmínkám prostředí v místě dojení a zároveň být robustní a spolehlivý (Artmann, 1997).

Ruční přikládání strukových násadců obsluhou dojícího systému je v řádu 10 s a samozřejmě stoprocentně spolehlivé. Ideální a cílená doba automatického přikládání by neměla být delší, než 20 s, aby byla zachována vysoká produktivita. Přestože je pohyb dojnic během procesu přikládání omezen, je nutná detekce v reálném čase, aby systém obnovoval pozice struků každé 1–2 s. Vzhledem k této podmínce a také požadavku na spolehlivost a přesnost, je cílem doba detekce čtyř struků 1 až 2 s s přesností 5 mm (chyba detekce menší než 5 mm).


Všechny snímací systémy používané v komerčním AMS jsou založeny na principu laseru/optiky. K detekci a umístění laserového pruhu, který dopadá na struk, se používá jediná kamera. Aby byla možná triangulace polohy struku je třeba ze snímku zjistit polohu pruhu v prostoru a zároveň relativní vzdálenost laserového pruhu a kamery, stejně jako úhel dopadu (Lars a Mats, 1998). Takový systém může poskytnout spolehlivé a přesné informace týkající se polohy struku, ale může detekovat pouze jeden struk najednou. Jakmile je struk úspěšně lokalizován a je přiložen násadec, systém přejde k dalšímu struku. Tento postup

se opakuje, dokud nejsou všechny násadce přiloženy. V případě současného přístupu jsou polohy všech čtyř struků vyžadovány najednou.

Nedávný vývoj v oboru AMS vedl ke snížení doby detekce struků pomocí přístupu založeného na laserovém skeneru. V roce 2010 DeLaval oznámil vývoj prvního plně automatického rotačního dojícího zařízení (AMR) „DeLaval AMR“ s prvními testy na stádu v Tasmánii v roce 2011 (DeLaval, 2012). Systém se skládá z rotační karuselové dojírny s až pěti roboty umístěnými uvnitř dojírny. Aplikace strukových násadců je prováděna dvěma roboty a lokalizace a nasazení trvá přibližně 1 min. Systém kombinuje předchozí údaje o poloze a laserový skener k identifikaci polohy čtyř násadců. DeLaval uvádí, že systém je schopen podojit až 90 krav za hodinu a je vhodný pro stáda až 300 krav (DeLaval, 2011). Tradiční rotační systémy dojení mají doживost 120 – 300 krav za hodinu. Efektivitu systému lze zvýšit, pokud se zkrátí doba umístění a přiřkládání strukových násadců. Použití systému s viděním, který dokáže okamžitě lokalizovat polohu čtyř struků, by mohlo lokalizaci a nasazení urychlit na požadovaných deset sekund (Frost et al., 2004).

Dalšími přístupy použitými k lokalizaci struků byla vodivost (Akerman, 1980) a mechanické kontaktní senzory (Artmann et al., 1990). Od těchto technik se však rychle upustilo, protože kromě toho, že mohou zvířeti ublížit, mohou také způsobit nežádoucí pohyb krav (Artmann, 1997). V průběhu osmdesátých let se objevily úspěšné pokusy s využitím zpracování obrazu pomocí technik laserového skenování (Montalescot, 1987), ultrazvukových (US) zařízení pro zjišťování vzdálenosti a optických senzorů (Torsius, 1988). Pro měření vzdálenosti pomocí US (Artmann et al., 1990) dostupná řada procesů. Přesná poloha struků je určena triangulací pomocí dvou senzorů ze soustavy senzorů uspořádaných tak, aby oblast vyhledávání US zahrnovala oblast struku. Laboratorní testy ukázaly, že při tomto uspořádání je možné měřit s přesností přibližně 1 mm. Tato metoda byla použita v systému AMS v Duvelsdorfu (Dilck, 1992). Většího úspěchu bylo dosaženo s těmito systémy ve spojení s databází relativních strukových konfigurací. Předchozí údaje o relativní poloze struků pomohly zkrátit čas potřebný k identifikaci všech čtyř struků současně.

Bylo provedeno omezené množství prací s využitím tepelných charakteristik oblasti vemene ((Ordolff, 1984)), nicméně v té době byla termální technologie velmi drahá, pomalá a nebyla komerčně využívána. Předchozí pozorování s termální kamerou ukázala, že oblast vemene a struků vykazuje vyšší teplotu než zbytek těla (viz obrázek 1.13) (Ben Azouz et al., 2015; Systems, 2014).




Obrázek 1.13: Termální snímek vemene a struků u dvou různých krav

Frost et al. (2000) v Silsoe Research institute ve Velké Británii zveřejnili v posledních 20 letech několik publikací popisujících vývoj v oblasti pneumatického robota pro příkládání násadců (Frost et al., 2004, 1993, 2000). Systém využívá tři zdroje informací k určení polohy struků před přiložením násadců: uložená poloha struků, informace o poloze a pohybu krávy ve stáji a místní senzor nad strukovým násadcem. Uložená poloha struků je získána z předchozích návštěv krávy ve stáji, zatímco údaje o poloze dojnice se získávají ze tří lineárních potenciometrů, které jsou umístěny v kontaktu s krávou ve stáji, a nakonec místní snímač u strukového násadce shromažďuje matici světelných paprsků, která zajišťuje vyrovnání násadce v ose struku. Potenciometry byly v pozdějších verzích systému vyřazeny a nahrazeny systémem vidění a rutinní analýzou obrazu (Frost et al., 2000).

V dřívějších pracích (Duffy, 2006) byla výkonnost komerčního systému stereovize hodnocena z hlediska úspěšnosti při identifikaci struků na snímcích a přesnosti při určování pozice struků. Bylo zjištěno, že v cílové oblasti docházelo k falešným identifikacím objektů, které neměly tvar struku a objektů připomínajících velikostí struky v pozadí scény, ale mimo cílovou oblast.

Multimodální systém vidění kombinující optickou stereovizi a termovizi vyvinul Ben Azouz et al. (2015). Byly navrženy algoritmy detekce struků a určení 3D polohy. Laboratorní testy v různých situacích s využitím atrapy termálního vemene byly provedeny v rámci experimentu. Na obrázku 1.14 byl vedle čtyř falešných struků umístěn objekt a byl identifikován a vybrán přednostně před ostatními struky. Tento typ chyby se pravděpodobně vyskytuje v praxi kvůli přítomnosti robotického manipulátoru, který se pohybuje v pracovní oblasti a mimo ni.



Obrázek 1.14: Falešná identifikace struků


I v případě zdánlivě neutrálního pozadí mohou nastat problémy. Například stín vržený falešným strukem byl v některých případech označen jako struk. V důsledku toho byl systém značně citlivý na lokální světelné podmínky. Opakovatelnost odhadů polohy provedených systémem byla proměnlivá a nedostatečná pro účely spolehlivého sledování struků (Duffy, 2006).

Stereovize

Stereovize využívá stejné techniky, jaké používají lidé k určování hloubky obrazu. Dvě kamery slouží k pořízení dvojice snímků stejné scény z mírně odlišných úhlů pohledu. Objekt na scéně se na snímcích pořízených oběma kamerami zobrazí na dvou různých místech. Tento rozdíl, známý jako disparita, se používá k určení vzdálenosti objektu

(hloubky). Pokud je objekt vidět na obraze z obou kamer, lze jeho 3D polohu triangulovat. Optická kamera provádí lineární transformaci z 3D do 2D obrazové roviny kamery. Naproti tomu stereovize je technika, která tuto transformaci obrací a získává 3D zobrazení scény ze dvou nebo více obrazových bodů a z více 2D pohledů kamery.

Základní předpoklad stereofonní rekonstrukce je znázorněn na obrázku 1.15. Na tomto obrázku jsou $C1$, $C2$, $l1$, $l2$, $f1$ a $f2$ známy jako dva středy, obrazové roviny a ohniskové vzdálenosti dvou kalibrovaných kamer. Je potřeba zdůraznit, že obrazové roviny byly umístěny před středy kamer, což je konvence, která se běžně používá při analýze a zachovává stejnou geometrickou interpretaci skutečné situace, kdy jsou obrazové roviny umístěny za středy kamer.



Obrázek 1.15: Schéma stereofonní rekonstrukce. $C1$, $C2$, $l1$, $l2$, $f1$ a $f2$ jsou dva středy, obrazové roviny a ohniskové vzdálenosti dvou kalibrovaných kamer. $u1$ a $u2$ jsou projekce stejného 3D bodu X na $l1$ a $l2$. $L1$, jedinečný 3D paprsek který prochází středem $u1$ a středem kamery $C1$. $L2$ jedinečný 3D paprsek, který prochází $u2$ a středem kamery $C2$. B je euklidovská vzdálenost mezi oběma středy kamer $C1$ a $C2$.

Pro jediný bod $u1$ na $l1$ lze určit jedinečný 3D paprsek $L1$, který prochází bodem $u1$ a středem kamery $C1$. Podobně lze pro obrazový bod $u2$ na $l2$ určit druhý 3D paprsek $L2$. Pomocí těchto dvou paprsků, jsou-li $u1$ a $u2$ projekcemi stejného 3D bodu X , pak by se $L1$ a $L2$ měly protínat ve 3D prostoru v tomto jediném bodě X . 3D souřadnice bodu X lze pak vypočítat pomocí trigonometrie v procesu zvaném triangulace. Je důležité si uvědomit, že je třeba znát euklidovskou vzdálenost mezi dvěma středy kamery $C1$ a $C2$, známou jako základní linie B , aby bylo možné provést 3D rekonstrukci v měřítku (Kelly, 2007).


Tepelná/optická holografie

Před zahájením jakýchkoli testů je třeba systém zkalibrovat. Kalibrace je určení vnitřních a vnějších parametrů, které umožňují vzájemně srovnat souřadnicové systémy kamer a pevný referenční rámec. Kalibrace se dělí na dvě části. První část spočívá v kalibraci obou optických kamer, známé jako kalibrace stereovize (Bouguet, 2013). Druhá část se týká kalibrace termokamery s optickými kamerami za účelem vytvoření termální/optické homografie. Homografie je rovinné zarovnání dat ze dvou různých zdrojů „kamer“. Ob-

vykle je zapotřebí korelovat informaci mezi dvěma nebo více kamerami, které sledují scénu z různých úhlů pohledu a/nebo s různými provozními parametry. Stejně jako u stereokalibrace existuje několik metod zarovnání dat. Většina těchto metod byla vyvinuta pro multimodální systémy vidění používané v lékařských snímcích. V případě lékařských aplikací se používá technika pro maximalizaci vzájemné výměny informací (Pluim et al., 2003; Viola a Wells, 1995). Pro obecné aplikace se počítá planární homografie (Hartley, 2000) k vyrovnání dat mezi termovizní a optickou kamerou.

Strojové zpracování obrazu

V oblasti počítačového vidění a zpracování obrazu jsou detekce a popis příznaků základními součástmi mnoha procesů a aplikací, které vyžadují reprezentaci objektů zájmu (obrázek 1.16) (Tyagi, 2019). Aplikace, jako jsou rozpoznávání objektů nebo sledování objektů, nedosáhnou vysoké přesnosti bez dobrých funkcí. Výzkum v oblasti rozpoznání obrazu přitáhl značnou pozornost a bylo zavedeno několik technik a metod.



Obrázek 1.16: Detekce příznaků

V poslední době se detektory a deskriptory obrazových příznaků staly důležitými algoritmy v oblasti počítačového vidění a popisu při zpracování obrazu. Byly široce aplikovány v mnoha aplikacích založených na vidění, jako je reprezentace obrazu (Yap et al., 2010), klasifikace obrazu (Liu a Bai, 2012), rozpoznávání objektů (Andreopoulos a Tsotsos, 2013), 3D modelování (Moreels a Perona, 2007), sledování (Takacs et al., 2013) a biometrické systémy (Mian et al., 2008).

Detekce příznaků je metoda výpočtu abstrakcí obrazových informací a místního rozhodování v každém bodě obrazu. Detekce příznaků je nízkourovňová operace zpracování. Obecně je provedena jako první operace při zpracování obrazu a zkoumá, zda se v každém pixelu nachází příznak. Po detekci klíčových bodů obrazu je proveden popis lokálních vlastností obrazu v těchto pixelech. Algoritmy extrahují zajímavé informace z obrazových dat v detekovaných klíčových bodech.

Mezi nejnámější a nejpoužívanější algoritmy zpracování a popisu obrazu patří:

- SIFT
- SURF
- FAST
- BRISK
- ORB
- FREAK

Deep learning

Hluboké učení se stalo jednou z nejúčinnějších metod detekce objektů, jejíž nespornou výhodou ve srovnání s tradičními přístupy strojového vidění je automatická extrakce a následná analýza příznaků vyskytujících se ve zpracovávaném obraze.

Na základě hlubokého učení lze detekci objektů rozdělit na dvoustupňové a jednostupňové detektory. Typickým představitelem dvoustupňových detektorů je Fast R-CNN (Ren et al., 2015) a mezi jednostupňové náleží SSD (Liu et al., 2016). Dvoustupňové detektory mají dvě větve sítě: větev RPN (Region Propose Network) a klasifikační větev. Síť RPN navrhuje ROI (Region of Interest) třídy popředí a větev klasifikace vyznačuje a odhaduje bounding box pro každou ROI. Dvoustupňové detektory jsou schopny robustně a přesně lokalizovat objekty na snímcích. Současný špičkový výkon detekce je obvykle dosahován dvoustupňovými metodami (Lin et al., 2020). Jednostupňové detektory spojují klasifikační větev a větev RPN do jedné sítě, což vede k lepší výpočetní efektivitě. Jednostupňové detektory jsou jednodušší a rychlejší než dvoustupňové, ale přesnost detekce je obvykle nižší než u dvoustupňových detektorů.

V posledních letech se hluboké učení hojně využívá v živočišné výrobě. Andrew et al. (2017) využil síť R-CNN pro individuální identifikaci holštýnského fríského skotu. Přesnost identifikace 89 krav ve stáji byla 86,1 % a přesnost identifikace 23 videí pasoucích se krav pořízených bezpilotním letadlem byla 98,1 %. Detektor Faster R-CNN použili Zheng et al. (2018) k identifikaci pěti poloh prasnic a získání přesné lokalizace prasnic ve volných kotečích. Jako soubor dat byly použity hloubkové snímky prasnic a přesnost byla 93,58 %. Yang et al. (2018a) a Yang et al. (2018b) použili Faster R-CNN k lokalizaci a identifikaci jednotlivých prasat a jejich hlav ze skupinově ustájené ohrady, aby rozpoznali chování prasat při krmení. Spolehlivost a přesnost byly 99,6 % a 86,93 %. Xue et al. (2018) navrhli algoritmus automatického rozpoznávání postojů kojících prasnic založený na vylepšeném Faster R-CNN s využitím hloubkových videosnímků. Průměrná přesnost (mAP) metody byla až 93,25 %. Jiang et al. (2019) aplikoval síť YOLOv3 doplněnou o vlastní vrstvu FilterLayer s integrovanou funkcí Leaky ReLU k detekci klíčových partií dojníc. Celková přesnost, míra spolehlivosti a mAP algoritmu byly 99,18 %, 97,51 % a 93,73 %. Xu et al. (2020) použili algoritmus Mask R-CNN k detekci a počítání skotu ze snímku z kvadroptéry. Přesnost počítání dobytka touto metodou byla 92 % v krmných stájích a 94 % na pastvinách. Riekert et al. (2020) použili detektor Faster R-CNN k detekci polohy a postoje prasat při různých směrech kamery a světelných podmínkách. Průměrná přesnost detekce polohy prasat byla 87,4 % a mAP polohy a postoje prasat byla 80,2 %. Na základě modelů CNN Bezen et al. (2020) navrhli a implementovali systém vidění pro měření individuálního příjmu krmiva kravami pomocí RGB-D kamery v otevřeném kravíně.

System dokáže přesně rozpoznat 93,65 % krav. Byla měřena spotřeba krmiva a průměrné absolutní a kvadratické chyby byly 0,127 kg a 0,034 kg². Na základě charakteristického vektoru relativní velikosti kroku a algoritmu YOLOv3 byla navržena metoda klasifikace kulhajících a nekulhajících krav (Wu et al., 2020). He et al. (2020) navrhli metodu identifikace dojnic na základě vylepšené sítě YOLOv3. U zadních snímků 89 krav byla přesnost, míra spolehlivosti, mAP a IoU 95,91 %, 95,32 %, 95,16 % a 85,28 %.

Metody hlubokého učení mají schopnost identifikovat objekty z nepřehledného pozadí, a to i přes rozdílnost polohy, barvy, osvětlení a velikosti cíle. Pro znečištěné a slabě osvětlené prostředí v rotačním dojčím systému jsou algoritmy hlubokého učení praktickou a robustní volbou pro detekci struků. Účelem snímacího systému je detekovat struky v rámci viditelné scény kamer a vyvést na výstup souřadnice špičky struku do robotického ramene pro přiložení strukového násadce. Výše zmíněné algoritmy hlubokého učení vyznačují detekovaný objekt pomocí bounding boxů, jež mají podobu obdélníku či čtverce se stranami rovnoběžnými se stranami zpracovávaného snímku. Nicméně i při detekci standardních boxů struků zůstává získání špičky struku ve složitém prostředí výzvou, protože struky mají proměnlivou orientaci v prostoru. V oblasti detekce objektů ve vzdáleně pozorovaném obraze navrhli výzkumníci několik přístupů detekce objektů, které přímo předpovídají úhlově orientované ohraničující boxy objektů (Liu et al., 2018; Ma et al., 2019; Yang et al., 2018a).

Shrnutí různých aplikací založené na přístupech hlubokého učení pro detekci objektů v obecných zemědělských výrobních systémech je uvedeno v tabulce 1.1.

Tabulka 1.1: *Různé aplikace založené na přístupu hlubokého učení pro detekci objektů v obecných zemědělských výrobních systémech*

Aplikace	Cíl	Model	Literatura
Detekce zvířat	Vejce	Fast R-CNN	(Joffe a Usher, 2017)
	Chování prasat při krmení ve skupinovém chovu	Fast R-CNN	(Yang et al., 2018a)
	Mléčné kozy	Faster R-CNN	(Wang et al., 2018)
	Dotyková separace prasat	YOLO9000	(Seo et al., 2019)
	Struky u krav	YOLO9000	(Rastogi a Ryuh, 2019)
Detekce ovoce	Jahody	Fast R-CNN	(Yu et al., 2019)
	Kiwi	Fast R-CNN s ZF-Net	(Fu et al., 2018)
Zjišťování zralosti	Divoké borůvky	YOLOv3-spp	(Schumann et al., 2019)
	Jablko	YOLOv3-dense	(Tian et al., 2019)
Zjišťování chorob	Maniok	SSD s MobileNet	(Ramcharan et al., 2019)
	Čaj	YOLOv3	(Bhatt et al., 2019)

2 Metodika a cíle práce

Hlavním cílem diplomové práce bude optimalizace navádění robotické ruky využívané při nasazování strukových násadců. Výsledky práce budou získané na základě části experimentu v rámci projektu MPO TRIO FV40316 – Vývoj komplexu modulárního systému robotizovaného dojení za současného hodnocení parametrů chovu aplikací metod umělé inteligence.

Prvním krokem při tvorbě práce bude seznámení s technologií strojového navádění a zpracování obrazu. Rešerše bude tedy obsahovat literární přehled různých technologií a experimentů používaných při lokalizaci a detekci objektů.

V další části budou popsány použité technologie a zařízení pro dosažení výsledků diplomové práce. Jednotlivá zařízení použitá v experimentu s robotickou dojárnou jsou popsány v kapitole Zařízení použitá v experimentu.

Následná metodika použitá při tvorbě výsledků bude zahrnovat:

1. Popsání hlavních parametrů a nastavení procesu vidění a detekce objektů
2. Postupy při nastavení procesů a výběr nástrojů
3. Volba ideálních parametrů poskytující přesnou detekci
4. Tvorba výstupního programu pro robotické rameno

3 Zařízení použítá v experimentu

3.1 StimuLactor

V rámci experimentu s robotickou dojárnou bylo použito zařízení StimuLactor (obrázek 3.1). Toto zařízení plní funkci automatického dojícího zařízení. Systém dojení je šetrný k lidem i zvířatům. Je založen na jednotce, která je řízena speciálně vyvinutým a patentovaným předstimulačním zařízením. Předstimulační zařízení s pohybovou vibrační složkou (akční člen) simuluje chování sajícího telete během hlavní doby dojení. Dodatečné použití dojící nádoby s ventilem Bio-Milker zajišťuje co nejpřirozenější a nejšetrnější dojení a poskytuje nebývalý stupeň vydojení. Ergonomický design výrazně usnadňuje práci dojiče tím, že chrání jeho klouby a oblasti zad.

StimuLactor se skládá z následujících hlavních součástí (obrázek 3.2):

1. Pouzdro
2. Naklápěcí stojan
3. Akční člen
4. Strukové násadce
5. Oplachovací zařízení
6. Pulzometr pro měření množství mléka


Hlavní součásti řídicího systému a pulzátoru jsou umístěny ve skříni, která zároveň obsahuje uzavírací ventily pro podtlak v násadcích. Naklápěcí podpěra skříně je zavešena na dvou rovnoběžných kolejnicích. Celá přístrojová skříň je uchycena k podpěře pomocí čtyř šroubů a je možné jí otáčet v rozsahu 360° (obrázek 3.3). Akční člen přenáší stimulační pohyby na vemeno prostřednictvím mléčných hadic. Řídicí jednotka je umístěna v přední části přístroje. StimuLactor je vybaven automatickým vypnutím podtlaku.

Technické parametry


V tabulce 3.1 jsou popsány jednotlivé parametry zařízení.



Obrázek 3.1: *StimuLactor*



Obrázek 3.2: Hlavní části StimuLactoru



Obrázek 3.3: Schéma StimuLactoru. 1 – pouzdro, 2 – naklápěcí stojan, 3 – závěs, 4 – oplachovací jednotka, 5 – hadice s násadci, 6 – rozdělovací hadice, 7 – pneumatický terminál, 8 – řídicí blok pulzátoru, 9 – pulzátor

Tabulka 3.1: Technická data StimuLactoru

Parametr	Hodnota
Rozměry	Š/H/V: 410 mm/430 mm/1830 mm
Hmotnost	42 kg
Napájení	Vstup: 230 V AC, 50 Hz, Výstup: 24 V DC, 2 A
Stupeň krytí	IP65
Podmínky prostředí	Teplota: 6 °C–50 °C Vlhkost: 90 %
Vakuum	Hodnota vakua: 32 kPa–36 kPa Sací výkon: 100 L · min ⁻¹ při tlaku 50 kPa Vakuový systém dle DIN ISO 5707 Připojení z pulzního vakuového vedení: silikonová hadice DN16
Přívod vzduchu	Čistý vzduch přes filtr Připojení: silikonová hadice DN16
Materiál	Nerezová ocel, POM, silikonové hadice na mléko DN16, DN14, DN12, DN10, vysoce kvalitní odolné komponenty
Stlačený vzduch	600 kPa Kvalita stlačeného vzduchu podle normy DIN ISO 8573-1:2010 Kontaminace pevnými látkami: max. 5 μm; 5 mg · m ⁻³ Celkový obsah oleje: max. 0,01 mg · m ⁻³ Objemový průtok na StimuLactor: min. 25 L · min ⁻¹ při 600 kPa (provozní objemový průtok)
Měření mléka	Pulsametr 2-1 (výrobce: Labor- und Messgeräte GmbH) Stützerbach). Hodnocení se provádí pomocí původního algoritmu LMS závislého na toku mléka GmbH. Měřené množství: 100 g/struk
Připojení hadic	Uzavírací ventil: PE hadice modrá 6x1 Přívodní hadice na mléko: silikonová DN16 Odtok mléka: silikonová DN16 Čisticí ventil: PE hadice žlutá 6x1

3.1.1 Předstimulace

Akční člen způsobuje vibrace strukových násadců prostřednictvím mléčných trubic, které vedou k uvolnění svalů vemene a zajištění tvorby vysoké koncentrace hormonu oxytocinu, který je nezbytný k vytlačení alveol. Tento úkon vychází z přirozeného chování telat na začátku kojení. Současně se automaticky spustí pulzace, způsobující proudění malého množství mléka, které zabrání vniknutí příliš velkého podtlaku do vemene.

3.1.2 Hlavní dojení

Po úspěšné předstimulaci se pulzace nastaví na režim 60 % ve fázi sání a 40 % ve fázi klidu. Fáze a frekvence pulzátoru je automaticky nastavena na 60 cyklů/min. Pulzování nadále probíhá v sekvenčním režimu. To zaručuje výjimečně šetrný transport mléka s výsledkem nízkého obsahu FFA v dodávaném mléce. Současně je frekvence akčního členu snížena na jemné kmitání, které je pro zvíře příjemné. Úroveň podtlaku v systému by měla být nastavena na 32 – 36 kPa. Chování zvířat a úspěšnost dojení, jakož i přilnavost strukových násadců, by měly být využívány jako vodítko pro nastavení úrovně podtlaku. Všechna tato opatření vedou ke zvláštnímu uvolnění dojnice během hlavního dojení. Na konci hlavního dojení, když průtok mléka dosáhne $800 \text{ g} \cdot \text{min}^{-1}$, se zintenzivní pohyb akčního členu, aby se více stimulovalo svalstvo a vyčerpala se zbývající část mléka. Po dosažení průtoku mléka $200 \text{ g} \cdot \text{min}^{-1}$ se po nastavitelné době prodlevy spustí automatický sběr násadců.

3.1.3 Čištění

Po ukončení dojení se celý systém mléčné linky vyčistí. Násadce se vloží do nádoby na oplachování a při zvýšeném podtlaku 50 kPa dochází k jejich čištění. Na konci programu oplachování se dojící zařízení přepne do pohotovostního režimu.


3.2 Robotická ruka FANUC Robot M-20iB/25

Pro účely experimentu s navigováním a nasazováním strukových násadců byla využita robotická ruka od firmy Fanuc s názvem Fanuc Robot M-20iB/25. Robotické zařízení se skládá z dutého ramena a zápěstí osazeného nejmodernějšími servomotory pro precizní pohyb a navádění. Robot je uzavřené konstrukce (žádné odkryté kabely ani motory) a vyznačuje se třídou ochrany těla minimálně IP54 a zápěstí IP67. Tato jeho vlastnost mu dává předpoklady pro práci v náročném prostředí, jakým zemědělské provozy (dojírny) jsou. Rameno je lehké a štíhlé, čímž se minimalizuje riziko kontaktu s periferními zařízeními.

Roboty FANUC jsou tzv. učící se roboty. Jejich pracovní režim teaching-playback způsobuje, že se učí specifické úkoly předem. Poté vykonávají činnosti přesně tak, jak byly naučeny. Série instrukcí, které určují, jakou operaci mají roboti provést, se nazývá program robota. Proces vytváření programů robotů se nazývá „výuka“. Provádění naučených programů robotů se nazývá „přehrávání“. Roboti, kteří se učí a přehrávají, dokáží pohyb provést přesně tak, jak byl naučen. Na druhou stranu nedokáže provést úkoly nad rámec učení.


Robot má 6 ovladatelných os a opakovatelnost pohybu je $\pm 0,02^\circ$. Hmotnost celého robota je 210 kg a jeho maximální zatížení zápěstí je 25 kg, které je pro potřeby nasazení strukových násadců plně dostačující. Maximální dosah ruky je 1853 mm. Rozsah pohybu

a jednotlivé rozměry jsou na obrázku 3.4. Robot může být usazen na podlaze nebo díky své nízké hmotnosti může být zavěšen. Pro aplikaci v praxi je tato variabilita velice výhodná, protože v různých provozech může být žádoucí jiné usazení, případně využití více robotů najednou. Robot je osazen na pojezdu, kterým je možné řídit přímo robota, tzn. robotický kontrolér definuje polohování pojezdové osy jako svoji 7. osu. Osa je poháněna servopohonem FANUC Alfa iS 12/4000 (Fanuc, 2022).



Obrázek 3.4: Pracovní rozsah robota

Robot je napojen na třífázové elektrické napětí 50 Hz/60 Hz 380 V–575 V a průměrný výkon je 1 kW. Ovládání ruky je řešeno přes inteligentní řídicí jednotku R-30iB Plus, která zajišťuje nejlepší možný výkon, rychlost, přesnost a bezpečnost robota (obrázek 3.5).

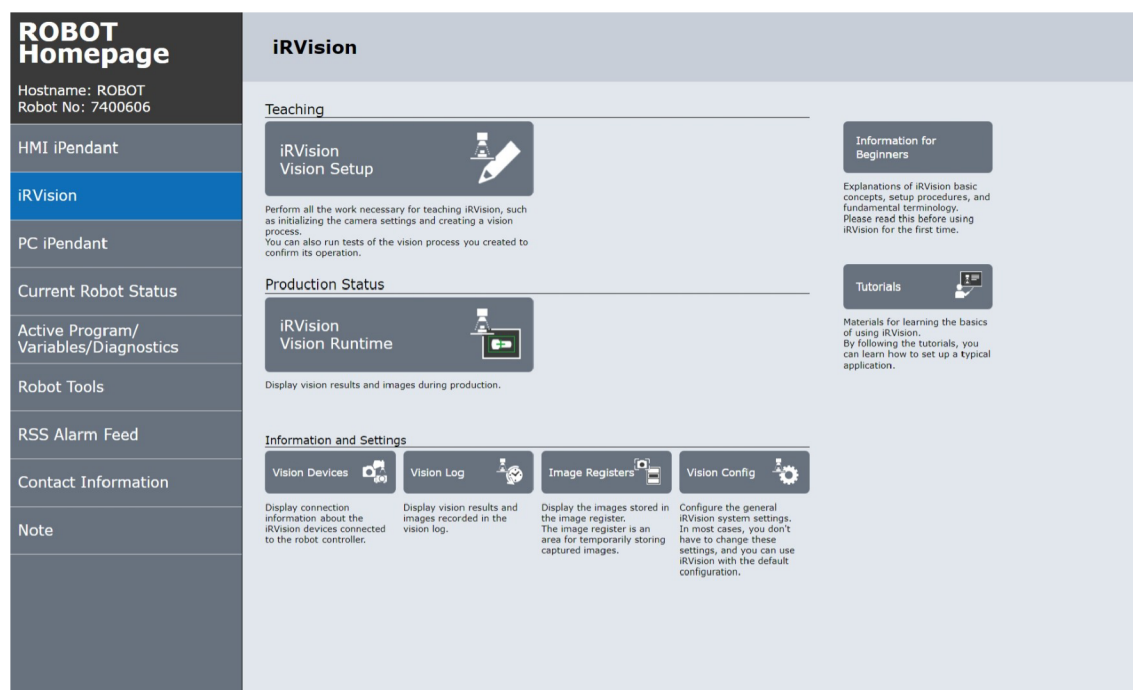


Obrázek 3.5: Řídicí jednotka R-30iB Plus

Programování ruky a detekce objektů

Programování robota lze provádět za pomoci integrované řídicí jednotky. Výkonná jednotka PCM je integrována do řídicí jednotky a má přístup k celému I/O systému robota. Tato řídicí jednotka používá vlastní patentovaný software od firmy FANUC. Programování probíhá

v softwaru ROBOGUIDE, který dovoluje navrhovat systémy a pohyby offline. Na zápěstí robotické ruky je umístěn 3D senzor (3D Vision Sensor 3DV/400) a kamery. Senzor je schopný rozlišit rastr v rozlišení 1280×1024 px. Další klíčové vlastnosti jsou uvedeny v tabulce 3.2. Senzor využívá tzv. iRVision, což je funkce zpracování obrazu integrovaná do řídicí jednotky robota (obrázek 3.6). Vyhledává části v obraze pořízeném z kamery, vyrovnává pohyb robota a měří vlastnosti objektu. iRVision obsahuje 2D kamerový systém, kameru, která provádí 2D posun, 3DV senzor, 3D senzor plochy a 3D senzor laserového vidění, které provádí 3D posun. iRVision měří polohu každé součásti pomocí kamer a upravuje pohyb robota tak, aby robot mohl manipulovat s dílem stejným způsobem, jakým byl naprogramován, a to i v případě, že se poloha dílu liší od polohy dílu nastavené při učení programu robota. Programování a komunikace jsou možné prostřednictvím grafického rozhraní iPendant Touch.




Obrázek 3.6: Prostředí programu iRVision

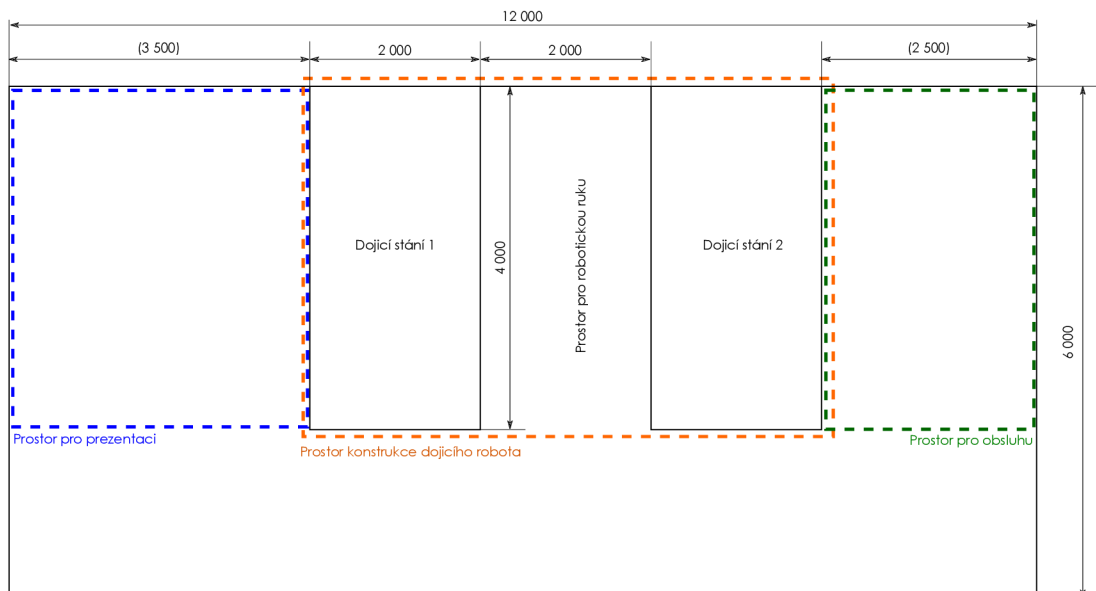
3.3 Umístění robota

Robot se nachází ve speciální místnosti v rámci prostor Fakulty zemědělské a technologické Jihočeské univerzity v Českých Budějovicích. Místnost byla vybrána s ohledem na dostatečný prostor pro všechno potřebné vybavení. Místnost je ve tvaru obdélníku s půdorysem $12 \text{ m} \times 6 \text{ m}$ a výškou $3,5 \text{ m}$. Podlaha je zátěžová s nosností $8000 \text{ kg} \cdot \text{m}^{-2}$. Místnost byla koncipovaná s ohledem na množství a charakter vybavení, které je nutné do místnosti integrovat. Funkčně by se měla přibližovat co nejvíce reálné stáji s dojicím stáním (obrázek 3.7)

Místnost je členěna do několika oblastí. Nejzásadnější je prostor konstrukce dojícího robota, kde jsou umístěna dojící stání, pojezd pro robotickou ruku a samotná robotická ruka. Neméně důležitou oblastí je prostor pro obsluhu, kde je vytvořeno zázemí pro pracovníky,

Tabulka 3.2: Parametry 3D senzoru

	Metoda měření	3D s jednoduchým vzorem světla
	Maximum 3D bodů [px]	1104 × 950
	Rozsah měření [mm]	3DV/400: 268 × 262 × 500 3DV/600: 575 × 499 × 500
	LED paprsek pro 2D detekci	Modrá barva
	Vnější rozměry [mm]	154 × 133 × 51
	Zpracování obrazu [ms]	100–300 (3DV/400, 3DV/600) 300–700 (3DV/1600)
	Hmotnost [kg]	1,1



Obrázek 3.7: Koncepte místnosti a rozmístění pro robotické zařízení

kterí budou nastavovat a kontrolovat činnost dojicího zařízení. Jelikož je celé zařízení pro Fakultu zemědělskou a technologickou JU ČB velmi významné, plánuje se také jeho prezentace veřejnosti. Z tohoto důvodu je v místnosti vyčleněna oblast pro prezentaci.


V prostoru konstrukce dojicího robota se nachází dvě konstrukce sloužící pro instalaci dojicích stání pracovních nazvané jako pódia. Jedná se o vyvýšený prostor 4 000 mm na délku, 2 000 mm na šířku a o výšce 1 000 mm. Tato pódia se skládají z mobilní železné kostry opláštěné dřevotřískovými deskami. S ohledem na tloušťku použitých desek jsou rozměry železné kostry 3 982 mm × 1 964 mm a výšce 830 mm. Kostra je vyrobena ze železných svařenců o rozměrech 60 mm × 60 mm o tloušťce 6 mm. Výška pódia je nastavena pomocí šroubovacích patek. Konstrukce poskytuje pevný a stabilní prostor pro ukotvení dojicích stání.

Zakrytí železné kostry je provedeno deskami z foliované překližky F/W. Materiál desek byl zvolen s ohledem na jeho odolnost vnějšímu prostředí, kdy při provozu zařízení není možné zabránit kontaktu desek s kapalinami. Parametry použitých desek jsou následující:

- fenolická folie 120–240 g
- vodovzdorné lepení WBP
- BFU100
- F/W jednostranně hladká, jednostranně protiskluzová
- tloušťka: 18 mm
- dřevina: buk

Pohyblivost pódíí zajišťují nastavitelná kolečka umístěná v každém rohu. Tyto kolečka je dle potřeby možné zasunout do pódia a tím celou konstrukci zajistit proti pohybu.

Rozměry pódíí umožňují umístit na každém z nich stání pro tři dojnice. Pro laboratorní potřeby je využita pouze část stání blíže k dojicí jámě (obsluze). Tato část výrazně ovlivňuje navádění robotické ruky se strukovými nástavci dojicího zařízení. Zádržný systém a vstupní/výstupní branka není při pokusech potřebná (nejsou obsluhovány živé dojnice). Konstrukce stání je vyrobena dle standardních rozměrů, které jsou běžně používány v chovatelské praxi. Konstrukce stání je vyrobena z pozinkovaných trubek a je pevně ukotvena k pódíím (obrázek 3.8).




Obrázek 3.8: *3D vizualizace dojicího stání*

4 Výsledky

Smyslem robotického ramene je úspěšné nasazení strukových násadců. V dalších návazných částech experimentu v příští etapě bude software schopný navigovat robotické rameno k zařízení StimuLactor a automaticky bude uchopovat jednotlivé strukové násadce a umožní nasazení na struky. Výsledkem této práce je prvotní část v rámci projektu, kdy software bude schopný lokalizovat strukové násadce. Tomuto úkonu předchází učení tvořené několika kroky, které jsou nezbytné pro vytvoření programu. Jednotlivé části jsou popsány v samostatných podkapitolách jako je nastavení procesu vidění, učícího nástroje GPM Tool, 3D roviny, referenční pozice a vytvoření programu. Nastavení vidění a rozpoznání předmětu jsou náročným procesem zahrnující velké množství parametrů, které jsou popsány v následující kapitole.

Vzájemné pozice robotického ramene, senzoru a pozice objektů jsou vyobrazeny v obrázku 4.1.



Obrázek 4.1: Přehledová situace robotického ramene a objektů k detekci

4.1 Popis základních parametrů procesu vidění

3DV Sensor

Pro správnou inicializaci programu a nastavení vidění je nutné vybrat konkrétní konfiguraci senzoru pro 3D vidění.

Application

Volba procesu vidění vzhledem k pohybu nástroje a sledovaného objektu.

- Fixed Frame Offset – Výpočet dat při pevném umístění hledaných objektů
- Tool Offset – Výpočet dat při pohyblivém umístění hledaných objektů
- Bin-Picking – Totožné s Fixed Frame Offset s funkcemi, umožňujícím uchopování velkého množství objektů

Offset Frame

Položka vhodná pro práci v 3D vidění – [3DV Single-View Vision Process] vypočítá velikost posunu vůči objektu v zadaném snímku.

Camera Base Find

Tato položka slouží pro pokročilé nastavení základní pozice kamery a senzoru.

Meas. Z Range

Nastavení rozsahu osy Z pro získání 3D dat. Vyplňuje se horní a spodní hranice rozsahu osy Z v jednotkách milimetrů. Hodnota pro nastavení by měla být stejná jako výstupní hodnota z parametru Offset Frame.

Display Image


Pokud je v procesu vidění k dispozici více nástrojů pro pořízení snímku, je nutné vybrat obrázek pořízený konkrétním senzorem z rozevíracího seznamu.

Image Display Mode

Výběr způsobu zobrazení pořízených záběrů z kamery:

- 2D Obraz + Body – Zobrazení získaných 3D bodů sledovaného objektu na snímku pořízeném kamerou.
- 2D Obraz + Výsledek – Zobrazení nalezených výsledků (objektů) na snímku pořízeném kamerou.
- 3D Data – Zobrazení získaného rozsahu obrazu 3D dat.

V položce [Meas. Z Range] je možné zobrazit hloubku předmětů, čili vzdálenost v ose Z od senzoru. 3D body s vyšší hodnotou Z jsou zobrazeny červeně a 3D body s nižší hodnotou na ose Z modře. 3D body s vyšší vzdáleností Z než je horní hranice položky [Meas. Z Range], jsou zobrazeny bíle a 3D body s nižším Z, než je spodní hranice položky [Meas. Z Range], jsou zobrazeny šedě. 3D body, které nebyly rozpoznány, jsou zobrazeny černě. Hloubkové označení 3D bodů je na obrázku 4.2.



Obrázek 4.2: Zobrazení vzdáleností osy Z

Show Discarded

Proces 3DV Single-View Vision zobrazuje výsledky nalezených objektů příkazových nástrojů. Pokud je povolena možnost [Show Discarded], špatně detekované objekty se zobrazí v obrazové části. Objekty z příkazových nástrojů mohou být vyřazeny, pokud jsou duplicitní nebo pokud nepřekročily práh viditelnosti.

Image Logging Mode

Určení, zda se při spuštění procesu vidění ukládají 2D obraz a hloubkový obraz do protokolu procesu sledování objektů. Pokud je protokolování objektů na stránce konfigurace zakázáno, obrázky se neukládají. Položku je možné měnit v těchto režimech:

- Bez záznamu – Snímky se neukládají.
- Záznam chybných obrazů – Obraz a hloubkový obraz se uloží pouze v případě, že operace vidění selže a objekty jsou špatně alokovány.
- Záznam všech obrazů – Uloží všechny snímky včetně hloubkových snímků.

Number to Find

Nastavení maximálního počtu objektů při procesu hledání. Rozsah jejich počtu lze nastavit v rozmezí 1 – 100.

Duplication Check (pokročilá volba)

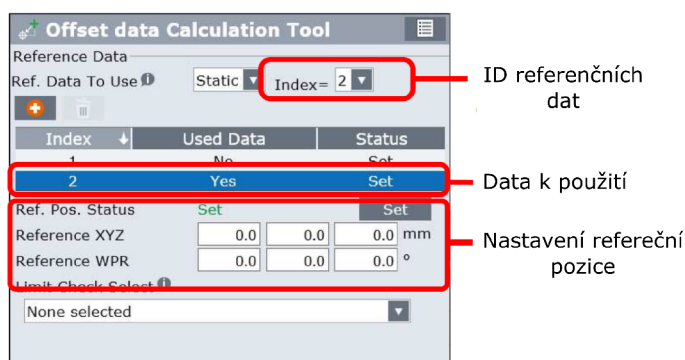
V případech, kdy jsou polohy a úhly dvou nalezených objektů blíže, než je zadaná prahová hodnota, kontrola duplicit vyřadí jeden z nalezených objektů. Jako jeden z typů selhání nálezu může být stejný objekt, který je detekován více než jednou. V takových případech zabrání tato funkce duplicitu vypsaní více detekcí pro jeden objekt.

Reference Data

Referenční data se používají k výpočtu offsetových dat ze zjištěného výsledku. Proces vidění může mít více než jednu sadu referenčních dat. Za normálních podmínek se používá pouze jedna sada referenčních dat. Avšak v případech, kdy se používá více příkazových nástrojů a každý příkazový nástroj má jiný způsob, jak uchopit předmět, je nutné nastavit více referenčních dat.

Ref. Data To Use

- Static – Stejná referenční data se používají pro výpočet údajů o posunu. Pokud má proces vidění více referenčních dat, zobrazí se následující tabulka. Důležité je vybrat [Index] referenčních dat, která se použijí (obrázek 4.3).
- Model ID – Referenční údaje, které se použijí, závisí na ID modelu nalezeného předmětu. Tato možnost se nastaví, pokud existují různé typy předmětů. Hodnoty referenčních údajů vybraných ze seznamu referenčních údajů se zobrazí v okně oblasti nastavení referenční polohy, jak je znázorněno v obrázku 4.4.



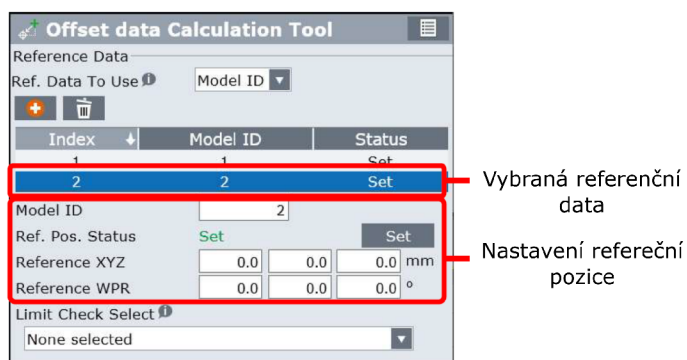
Obrázek 4.3: Možnost Static

Možnosti zobrazení stavu nastavení referenční polohy:

- Pokud je referenční poloha nastavena, zobrazí se [Set] zeleně.
- Pokud referenční poloha není nastavena, zobrazí se [Not set] červeně.

Reference XYZ

Zobrazí se rámcové hodnoty X, Y a Z referenční polohy zaznamenané v referenčních datech. Jednotky jsou uvedené v milimetrech (mm).



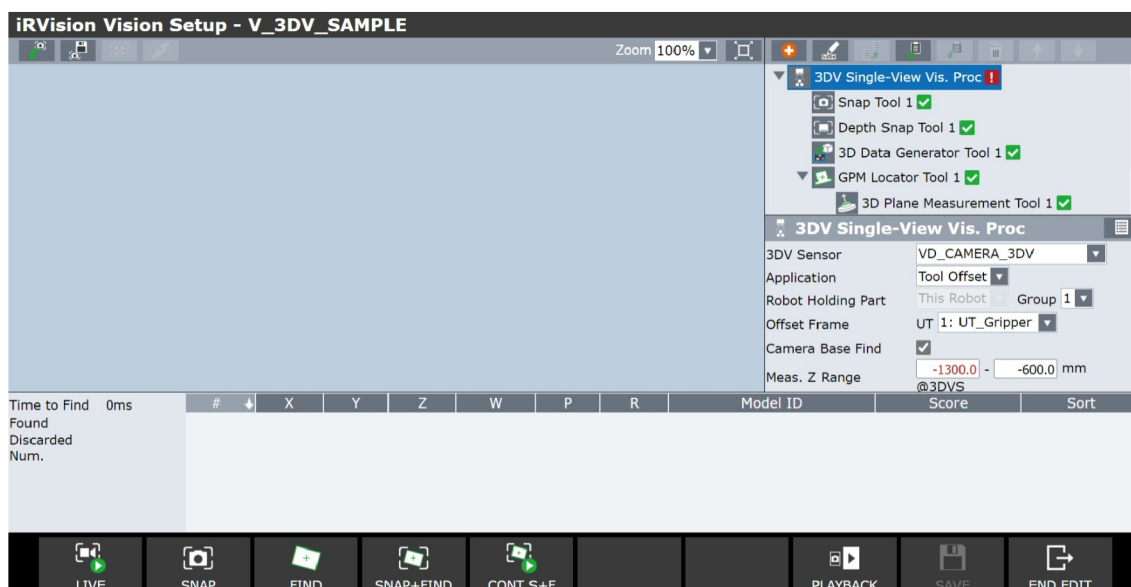
Obrázek 4.4: Možnost Model ID

Reference WPR

Úhly (úhel natočení kolem osy X, Y a Z) rámcových hodnot W, P a R referenčního bodu zaznamenané v referenčních datech. Jednotky jsou uvedené ve stupních ($^{\circ}$).

4.2 Nastavení parametrů a postup procesu vidění

Vytvoření správné koncepce a sledu kroků při rozpoznání objektů je náročný proces. V rámci velkého množství parametrů byly zkoušeny různé hodnoty na základě předchozích pozorování a zkušeností. Empiricky byly tedy zvoleny parametry, které vedly k nejlepším výsledkům při rozpoznání a detekci objektů. Vybrané provozní parametry pro nalezení strukových násadců jsou následující (viz obrázek 4.5):



Obrázek 4.5: Zvolené parametry procesu vidění

1. První krok zahrnuje výběr přednastaveného 3DV senzoru, který je uchycen na robotickém rameni. V tomto případě se jedná o kombinaci kamery a senzoru – VD_CAMERA_3DV.

2. V dalším kroku se v nabídce [Application] vybere [Tool Offset] vzhledem k tomu, že se sledovaný objekt se nepohybuje.
3. Třetí položka Offset Frame slouží k vybrání předdefinovaného uživatelského 3D prostoru spolu s kartézským souřadnicovým systémem.
4. Ve čtvrtém kroku je nutné ručně přesunout robotické rameno do polohy, kde 3DV senzor a uživatelský prostor s objekty jsou ve vzájemné poloze a rovina je v zorném poli snímače 3DV.
5. V tomto kroku je provedeno učení aktuální polohy objektu, jenž je součástí procesu detekce, a následně dojde k zapsání těchto údajů do programu robota. Tento systém má předinstalovaný vzorový program TP pro lokalizaci objektů v neměnné poloze.
6. Další krok zahrnuje pokročilé volby, které jsou popsány v kapitole 4.1.
7. Výběr možnosti [Camera Base Find], která umožní aktuální vyhledání a detekci objektů, které jsou v zorném poli senzoru.

4.3 Proces učení aplikací nástroje GPM Locator Tool

V rámci tohoto procesu je třeba provést nastavení parametrů pro 2D měření (detekce a měření 2D prvků). Ve stromovém zobrazení je vybrána položka [GPM Locator Tool 1].

Postup nastavení

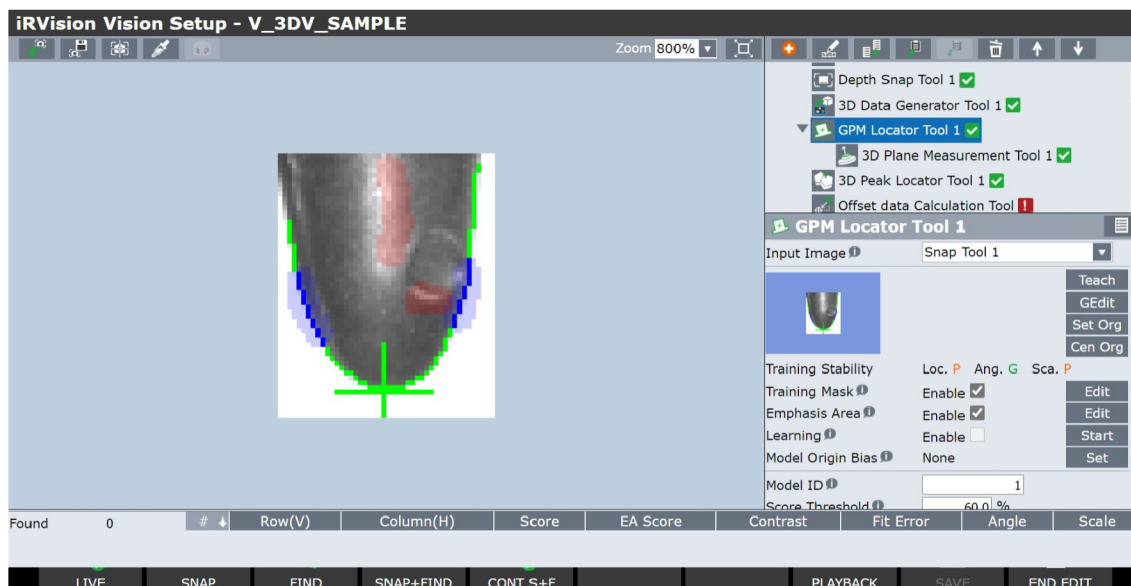
Výsledné vybrané hodnoty a postup nastavení jsou znázorněny v obrázku 4.6.

1. Umístění robota do oblasti měření a detekce objektů.
2. Po ustálení umístění a pohybu předmětu v oblasti měření je stisknuto tlačítko [SNAP].
3. Stisknutí tlačítka [Teach] k učení objektu. Zobrazí se obrazovka nastavení modelu GPM Locator Tool, kde se program naučí rozpoznávat 2D prvky používané pro detekci polohy. Pokud by mělo dojít k učení více objektů, musí být ve stejné rovinné hladině, aby byl omezen vliv změny tvaru v důsledku paralaxy.
4. Nastavení je potvrzeno tlačítkem [Save].

Test detekce

1. Kontrola zjištěné detekce [Training Stability]. Tato položka zobrazuje hodnoty polohy, úhlu a velikosti a správné rozpoznání u vyučovaného objektu. Hodnocení je označeno [G] (dobře), [P] (špatně) a [N] (žádné). [N] označuje, že stabilní detekce modelu nemusí být provedená.
2. Pomocí tlačítka [SNAP+FIND] je provedeno zachycení objektu a jeho detekce.

3. V dalším kroku se zkontrolují výsledky detekce. Při špatném výsledku je nutné zkontrolovat skóre, kontrast a další výsledky detekovaného modelu. Pokud jsou hodnoty skóre a kontrastu vyšší, než nastavené prahové hodnoty alespoň o 10 bodů, nejedná se o problém.



Obrázek 4.6: GPM Tool lokace

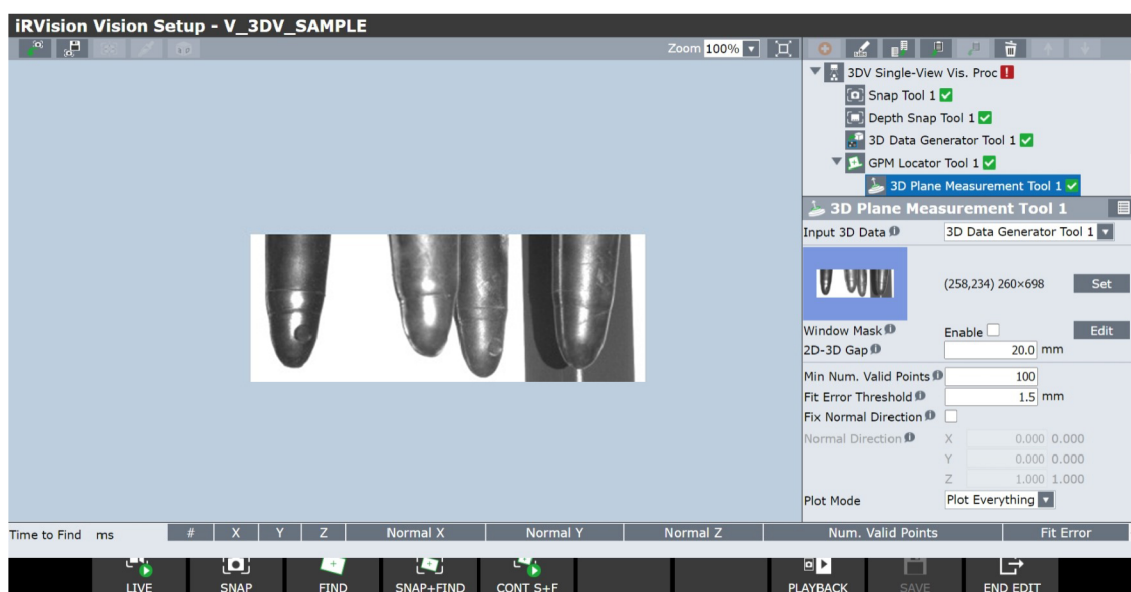
4.4 Postup nastavení měření 3D roviny

Nastavení 3D roviny zahrnuje předešlé zjištěné parametry a hodnoty v rámci 2D detekce v konfiguraci GPM Locator Tool.

Postup nastavení

Výsledné vybrané hodnoty a postup nastavení jsou znázorněny v obrázku 4.7.

1. Umístění robota do oblasti měření a detekce objektů.
2. Selekcce nástroje [3D Data Generator Tool 1] v [Input 3D Data].
3. Stisknutí tlačítka [Set]. Zobrazí se obrazovka výuky oblasti měření pro rovinné měření.
4. V dalším kroku je nutné vybrat položku [Plot Everything] ze seznamu [Plot Mode].
5. Nastavení je potvrzeno tlačítkem [Save].



Obrázek 4.7: 3D rovina

Test detekce

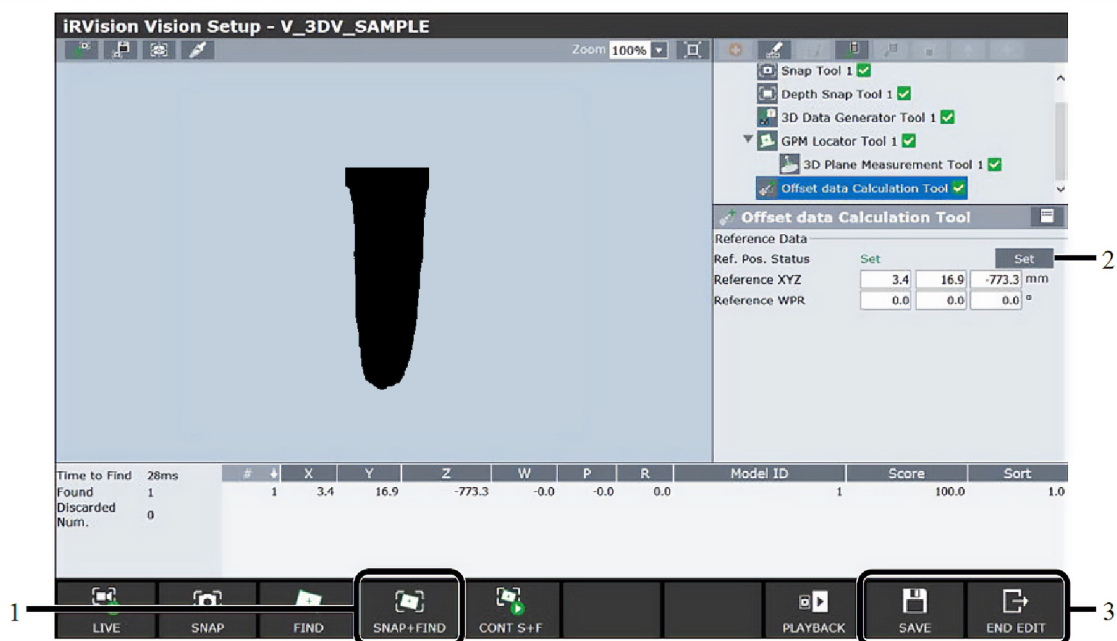
V tomto procesu je provedena kontrola, zda je vyučovaná oblast vhodná. V případě potřeby je možné parametry upravit tak, aby byla umožněna stabilní a přesná detekce objektu.

1. Prvním krokem je stisk tlačítka [SNAP+FIND]. Obraz je zachycen a detekce je provedena.
2. Dalším důležitým krokem je uložení detekce [Save].
3. Opakování kroku 1–2 pro různé natočení objektu.
4. Nastavení je potvrzeno tlačítkem [Save].

4.5 Postup nastavení referenční pozice

Při spuštění procesu vidění po nastavení dojde k výpočtu údajů o posunu prostřednictvím porovnání skutečné polohy, ve které je objekt detekován, s referenční polohou. Detekované strukové násadce dle nastavených parametrů jsou znázorněny v obrázku 4.8.

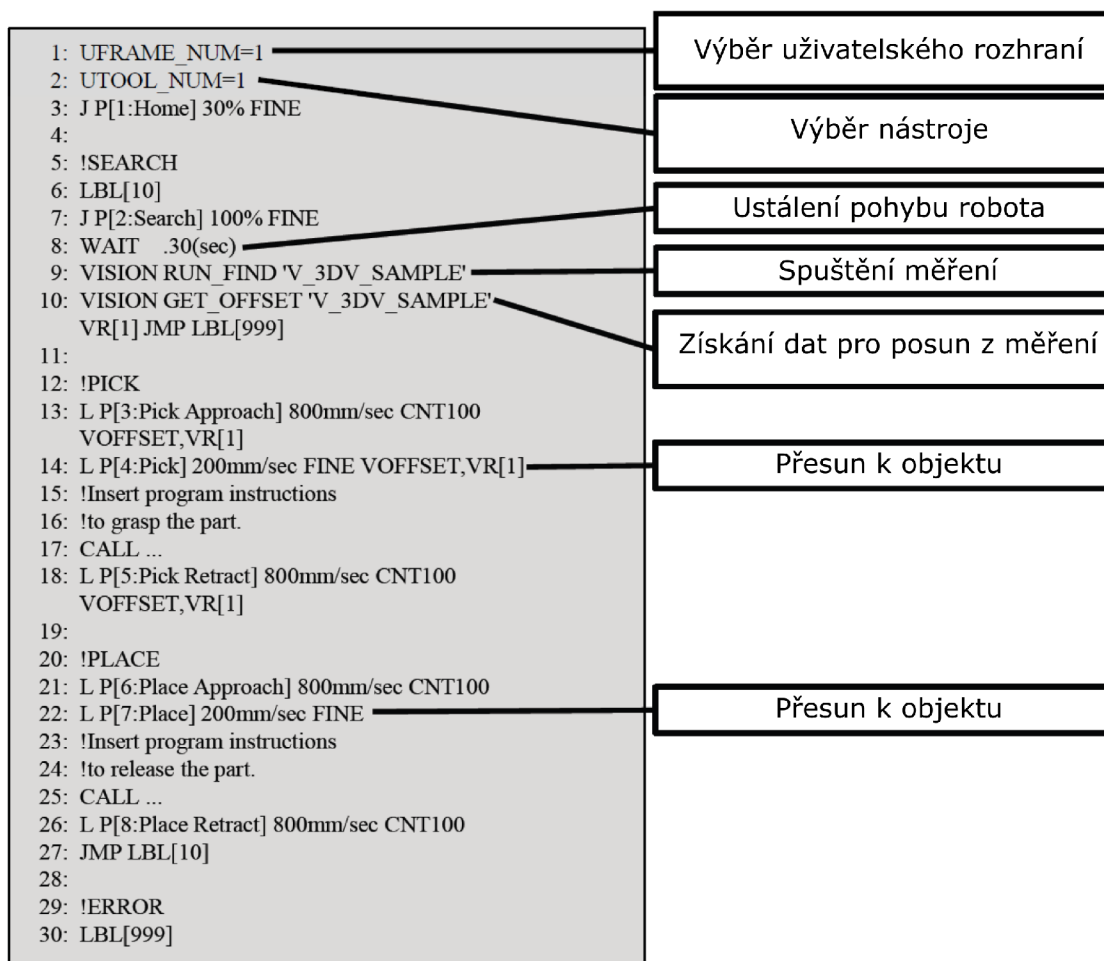
1. Umístění objektu do zorného pole kamery a stisknutí tlačítka [SNAP].
2. Tlačítkem [FIND] dojde k vyhledání objektu.
3. Následně se spustí tlačítko [Set] v rámci položky [Ref. Pos. Status]. Položka Ref. Pos. Status se musí změnit na hodnotu Set.
4. Další krok zahrnuje uživatelskou kontrolu, zda jsou nastaveny hodnoty pro všechny položky referenční polohy.
5. Pomocí tlačítka [Save] dojde k uložení parametrů a zjištěných pozic.



Obrázek 4.8: Detekce referenční pozice

4.6 Realizace úkonů robotické ruky na základě vytvořeného programu

Veškerá konfigurace zmíněných procesů se automaticky přeloží do strojového kódu. Takto vytvořený program je možné spustit nebo editovat v rozhraní iPendant Touch, které komunikuje s robotickým ramenem a řídicí jednotkou. Software řídicí jednotky, zpracovávající zadaný program, vypočítá souřadice pro posun k uchopení násadců. Trajektorie a posun robotického ramene je automaticky vyhotovena na základě vnitřích algoritmů. Výsledný strojový kód je znázorněn v obrázku 4.9.



Obrázek 4.9: Program pro lokalizaci objektů

5 Diskuze

V současné době je stěžejní problém při využívání algoritmů umělé inteligence, potažmo neuronových sítí, výpočetní výkon při jednotlivých procesech detekce objektů. Aktuální možnosti běžně dostupného hardwaru nejsou plně schopny využít jejich potenciál a sílu. Správné vyhodnocování a přesné určení polohy strukových násadců a jejich orientace v prostoru je závislé na mnoha faktorech, z nichž k nejzávažnějším patří světelnost a značná dynamika pozorovaného prostředí či rovnováha mezi přesností detekce a nároky na výpočetní výkon použitých metod strojového vidění (Filip et al., 2020).

Problémy, které se vyskytovaly při detekci objektů v použitém robotickém systému se týkaly převážně světelných podmínek. Rozlišovací schopnost kamery a čipu je silně závislá na množství světla, které na snímací čip dopadá, jak popisuje Zamir et al. (2021). Přičemž je obecně známo, že stájové prostředí a místo, v kterém je dojící zařízení použito, nemá stále a mnohdy dostatečné světelné podmínky. Řešení tohoto problému a nedostatku spočívá v nahrazení současného senzoru, senzorem kvalitnějším s vyšší rozlišovací schopností a vyšší citlivostí na horší světelné podmínky.

Dalším stěžejním problémem je rychlost, s jakou software dokáže detekovat objekty a vydat příkaz jednotce pro pohyb pohyblivých částí ramene. Jak uvádí Frost et al. (2004), je žádoucí z biologických důvodů, aby robotický systém byl schopný nasadit strukové násadce během několika desítek sekund. Delší čas způsobuje diskomfort krav u procesu dojení. Z biologického pohledu je nutné zachytit správný okamžik při tvorbě hormonu oxytocinu, aby bylo spuštěno samotné dojení (Machálek, 2011). Robotické rameno v této konfiguraci nedisponuje dostatečnou rychlostí potřebnou pro včasné nasazení strukových násadců. Úspěšná lokalizace je prvotním úkolem, který tvoří dílčí celek v celém projektu. Je nutné vyřešit i mnoho funkčních problémů a úskalí.

V části nastavení nástroje pro učení v kapitole 4.3 – Proces učení nástrojem GPM Locator Tool se vyskytoval problém s každou další novou naučenou pozicí objektu. Nová naučená pozice byla podobná té předchozí a senzor ji špatně detekoval. Dále se v některých případech vyskytovaly nekvalitní detekce v hodnocení polohy, úhlu a velikosti. V tomto případě bylo nutné změnit hodnotu prahu skóre a kontrastu.

V rámci nastavení měření 3D roviny v kapitole 4.4 – Postup nastavení měření 3D roviny docházelo často k problému s natočením hran detekovaných objektů. Dále se často vlivem špatného naučení objektu neprovedlo správně nastavení 3D rovin. Proces měření roviny bylo tedy nutné zopakovat vícekrát.

V části nastavení kapitoly 4.5 – Postup nastavení referenční pozice docházelo vlivem pohybu objektu při detekci ke špatnému rozpoznání. Bylo nutné před zapsáním program do řídicí jednotky ověřit a zajistit neměnnou pozici objektu.

Současná možnost a zároveň limit použitého senzoru spočívá v přesném nadefinování a naučení pozic struků u jednotlivých krav. To znamená, že je nutné každou krávu přemě-

řit a uložit do databáze jednotlivé souřadnice každého struku. V návaznosti na kvalitnější a výkonnější senzor pro detekci objektů je možné uvažovat o funkci automatického propočtu a kalibraci autonomního lokalizování struků u krav. Takový systém bude schopný v reálném čase propočítat pozice jednotlivých struků a nebude závislý na předchozím nastavení.

Závěr

V práci byly shrnuty a popsány klíčové parametry a jejich použití v dílčích procesech při detekci objektů. Následně byly popsány nejdůležitější postupy při detekci objektů a vybrány parametry, které vedly k nejlepším a nejpřesnějším výsledkům. Na závěr byl vytvořen a popsán program tvořený strojovým kódem, který byl zapsán do řídicí jednotky robota. V jednotlivých dílčích částech nastavení parametrů a procesů byly popsány časté problémy spojené s chybnou detekcí a nedostatečně přesnou konfigurací těchto parametrů. Řešení a vylepšení těchto nedostatků bylo popsáno v kapitole Diskuze.

Robotické dojení za pomoci robotické ruky má potenciál nahradit konvenční systém ručního dojení. Nicméně je důležité znát dobře prostředí, ve kterém systém bude umístěn. Zásadní věci pro použitý hardware a software jsou podmínky prostředí, především světelné podmínky. Robotická dojírna vytvořená v prostorách Fakulty zemědělské a technologické Jihočeské univerzity v Českých Budějovicích je prvotním konceptem robotického dojení pomocí robota Fanuc, který je používán převážně v průmyslové výrobě.

Dalším milníkem v rámci projektu s robotickou rukou bude pořízení přesnějšího a výkonnějšího 3DV senzoru, který bude méně náchylný na výše popsané problémy spojené s detekcí objektů a s nedostatečnými světelnými podmínkami. Diplomová práce tedy poslouží jako znalostní databáze k dalším následným postupům při operacích robotického ramene.

Seznam použitých zdrojů

- Akerman, D. (1980). Milking method and apparatus. US4223635.
- Andreopoulos, A. a Tsotsos, J. K. (2013). 50 Years of object recognition: Directions forward. *Computer Vision and Image Understanding*, 117(8):827–891.
- Andrew, W., Greatwood, C., a Burghardt, T. (2017). Visual Localisation and Individual Identification of Holstein Friesian Cattle via Deep Learning. In *2017 IEEE Int. Conf. Comput. Vis. Work*, pp. 2850–2859.
- Andrt, M. (2011). *Technika a technologie pro chov zvířat*. Česká zemědělská univerzita v Praze, Provozně ekonomická fakulta.
- Artmann, R. (1997). Sensor systems for milking robots. *Computers and Electronics in Agriculture*, 17(1):19–40. Robotic Milking.
- Artmann, R., Schillingmann, D., Kroeger, G., a Bollmann, B. (1990). Lokalisierung der Zitzenposition mittels Ultraschall und Bildverarbeitungssystem. In *Robotereinsatz in der Landwirtschaft am Beispiel des Melkens*, volume 9, pp. 126–152.
- Ben Azouz, A., Esmonde, H., Corcoran, B., a O’Callaghan, E. (2015). Development of a teat sensing system for robotic milking by combining thermal imaging and stereovision technique. *Computers and Electronics in Agriculture*, 110:162–170.
- Berg, K. V. D. (2013). Autonomous device for executing one or more operations on or near the teats of a dairy animal for the purpose of milking the dairy animal and method of milking a dairy animal. WO 2013/039384 A1.
- Bezen, R., Edan, Y., a Halachmi, I. (2020). Computer vision system for measuring individual cow feed intake using RGB-D camera and deep learning algorithms. *Computers and Electronics in Agriculture*, 172:105345.
- Bhatt, P. V., Sarangi, S., a Pappula, S. (2019). Detection of diseases and pests on images captured in uncontrolled conditions from tea plantations. In *Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping IV*, volume 11008 1100808, p. International Society for Optics and Photonics.
- Bijl, R., Kooistra, S., a Hogeveen, H. (2007). The Profitability of Automatic Milking on Dutch Dairy Farms. *Journal of Dairy Science*, 90(1):239–248.
- Bouguet, J. (2013). Camera calibration toolbox for matlab. [cit. 2022-01-15], Dostupné z: http://www.vision.caltech.edu/bouguetj/calib_doc/index.html.

- Bouška, J. (2006). *Chov dojeného skotu*. Profi Press.
- Carlström, C., Pettersson, G., Johansson, K., Strandberg, E., Stålhammar, H., a Philipsson, J. (2013). Feasibility of using automatic milking system data from commercial herds for genetic analysis of milkability. *Journal of Dairy Science*, 96(8):5324–5332.
- Castro, A., Pereira, J., Amiama, C., a Bueno, J. (2012). Estimating efficiency in automatic milking systems. *Journal of Dairy Science*, 95(2):929–936.
- DeLaval (2011). DeLaval AMR™ in use on a real farma. [cit. 2022-01-15], Dostupné z: <http://www.delaval.com/en/About-DeLaval/DeLaval-Newsroom/?nid=56410>.
- DeLaval (2012). DeLaval AMR™ is a reality in Tasmania. [cit. 2022-01-15], Dostupné z: <http://www.delaval.com/en/About-DeLaval/Innovation-at-DeLaval/AMR/>.
- DeLaval (2022). DeLaval. [cit. 2022-01-15], Dostupné z: <http://www.delaval.com/>.
- Devir, S., Hogeveen, H., Hogewerf, P., Ipema, A., Ketelaar-de Lauwere, C., Rossing, W., Smits, A., a Stefanowska, J. (1996). Design and implementation of a system for automatic milking and feeding. *Canadian agricultural engineering*, 38:107–1113.
- Dilck, M. (1992). Evolution of diivelsdorf milking robot. In *Proc. Symp. Prospects for Automatic Milking*, pp. 23–25.
- Doležal, O. (2000). *Mléko, dojení, dojírny*. Agrospoj.
- Duffy, H. (2006). Teat detection for an automated milking system. Diplomová práce, Dublin City University.
- Fanuc (2022). Fanuc Robots. [cit. 2022-01-15], Dostupné z: <https://www.fanuc.eu/cz/en/robots>.
- Filip, M., Zoubek, T., Bumbalek, R., Cerny, P., Batista, C. E., Olsan, P., Bartos, P., Kriz, P., Xiao, M., Dolan, A., a Findura, P. (2020). Advanced Computational Methods for Agriculture Machinery Movement Optimization with Applications in Sugarcane Production. *Agriculture*, 10(10).
- Frost, A., French, A., Tillett, R., Pridmore, T., a Welch, S. (2004). A vision guided robot for tracking a live, loosely constrained pig. *Computers and Electronics in Agriculture*, 44(2):93–106.
- Frost, A., Street, M., a Hall, R. (1993). The development of a pneumatic robot for attaching a milking machine to a cow. *Mechatronics*, 3(4):409–418.
- Frost, A., Tillett, R., a Welch, S. (2000). The development and evaluation of image analysis procedures for guiding a livestock monitoring sensor placement robot. *Computers and Electronics in Agriculture*, 28(3):229–242.
- Fu, L., Feng, Y., Majeed, Y., Zhang, X., Zhang, J., Karkee, M., a Zhang, Q. (2018). Kiwifruit detection in field images using Faster R-CNN with ZFNet. *IFAC-PapersOnLine*, 51(17):45–50. 6th IFAC Conference on Bio-Robotics BIOROBOTICS 2018.

- Fullwood (2022). Merlin. [cit. 2022-01-15], Dostupné z: <https://fullwoodpacko.com/cz/reseni/roboticke-dojeni/m2erlin/>.
- Gea (2022). GEA DairyRobot R9500 Robotic Milking System. [cit. 2022-01-15], Dostupné z: <https://www.gea.com/en/products/milking-farming-barn/dairyrobot-automated-milking/dairyrobot-r9500-robotic-milking-system.jsp>.
- Gongal, A., Amatya, S., Karkee, M., Zhang, Q., a Lewis, K. (2015). Sensors and systems for fruit detection and localization: A review. *Computers and Electronics in Agriculture*, 116:8–19.
- Gygax, L., Neuffer, I., Kaufmann, C., Hauser, R., a Wechsler, B. (2007). Comparison of Functional Aspects in Two Automatic Milking Systems and Auto-Tandem Milking Parlors. *Journal of Dairy Science*, 90(9):4265–4274.
- Hansen, M. F., Smith, M. L., Smith, L. N., Salter, M. G., Baxter, E. M., Farish, M., a Grieve, B. (2018). Towards on-farm pig face recognition using convolutional neural networks. *Computers in Industry*, 98:145–152.
- Hartley, R. (2000). A. Zisserman Multiple view geometry in computer vision.
- He, D., Liu, J., Xiong, H., a Lu, Z. (2020). Individual Identification of Dairy Cows Based on Improved YOLO v3. *Nongye Jixie Xuebao/Transactions of the Chinese Society for Agricultural Machinery*, 51(4):250–260. cited By 14.
- Hogeveen, H., Heemskerk, K., Mathijs, E., et al. (2004). Motivations of Dutch farmers to invest in an automatic milking system or a conventional milking parlour. *Automatic milking: A better understanding*, pp. 56–61.
- Iwamura, S., Mizukami, Y., Endo, T., a Matsuno, F. (2022). Cable-path optimization method for industrial robot arms. *Robotics and Computer-Integrated Manufacturing*, 73:102245.
- Jiang, B., Wu, Q., Yin, X., Wu, D., Song, H., a He, D. (2019). FLYOLOv3 deep learning for key parts of dairy cow body detection. *Computers and Electronics in Agriculture*, 166:104982.
- Joffe, B. P. a Usher, C. T. (2017). Autonomous robotic system for picking up floor eggs in poultry houses. In *2017 ASABE Annual International Meeting 1*, p. American Society of Agricultural and Biological Engineers.
- Kelly, P. (2007). Pedestrian detection and tracking using stereo vision techniques. Dizertační práce, Dublin City University.
- Kitikov, V. a Ternov, E. (2009). Comparative technical and economic analysis of complex dairy management system on the basis of radiofrequency and infra-red identification of animals for milking parlor of foreign manufacture. In *Engineering for rural development*, pp. 76–80.
- Kondo, N. a Ting, K. (1998). Robotics for Plant Production. *Artificial Intelligence Review*, 12(1-3):227–243. cited By 71.

- Koning, D. (2010). Automatic milking – common practice on dairy farms.
- Lars, A. a Mats, N. (1998). Apparatus and method for recognising and determining the position of a part of an animal. PCT/SE1998/000,744.
- Lely (2022). Lely produkty pro chov dojnic. [cit. 2022-01-15], Dostupné z: https://www.lely.com/media/filer_public/cf/4f/cf4f1bcf-b8e4-4be1-bfbf-8ae32f89f14c/lely_dairy_equipment_2014_-_cs.pdf.
- Lin, T.-Y., Goyal, P., Girshick, R., He, K., a Dollár, P. (2020). Focal Loss for Dense Object Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2):318–327.
- Liu, S. a Bai, X. (2012). Discriminative features for image classification and retrieval. *Pattern Recognition Letters*, 33(6):744–751.
- Liu, W., Anguelov, D., a Erhan, D. (2016). Single shot multibox detector. In *European Conference on Computer Vision*, pp. 21–37.
- Liu, Z., Hu, J., Weng, L., a Yang, Y. (2018). Rotated region based CNN for ship detection. volume 2017-September, pp. 900–904. cited By 103.
- Ma, J., Zhou, Z., Wang, B., Zong, H., a Wu, F. (2019). Ship Detection in Optical Satellite Images via Directional Bounding Boxes Based on Ship Center and Orientation Prediction. *Remote Sensing*, 11(18).
- Machálek, A. (2011). *Analýza a metodika hodnocení interakcí systému člověk – zvíře – robot na farmách dojnic*. Praha: Výzkumný ústav zemědělské techniky.
- Maixner, L. (2006). *Mechatronika*. Brno: Computer Press.
- McGuffey, R. a Shirley, J. (2016). The Dairy Farm. In *Reference Module in Food Science*. Elsevier.
- Mian, A., Bennamoun, M., a Owens, R. (2008). Keypoint Detection and Local Feature Matching for Textured 3D Face Recognition. *International Journal of Computer Vision*, 79:1–12.
- Montalescot, J. (1987). Robotic milking: Research already has made good progress [Robotisation de la traite: Des Travaux déjà bien avancés]. *Revue laitière élevage*, 30(3):101–103. cited By 2.
- Moreels, P. a Perona, P. (2007). Evaluation of Features Detectors and Descriptors based on 3D Objects. *International Journal of Computer Vision*, 73:263–284.
- Ordolff, D. (1984). A system for automatic teat-cup attachment. *Journal of Agricultural Engineering Research*, 30:65–70.
- Park, C., Kyung, J. H., Do, H. M., a Choi, T. (2011). Development of direct teaching robot system. In *2011 8th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)*, pp. 730–732.

- Pinsky, N. (2017). Mobile milking robot with minimal footprint. US 2019/269096(A1).
- Pluim, J., Maintz, J., a Viergever, M. (2003). Mutual-information-based registration of medical images: a survey. *IEEE Transactions on Medical Imaging*, 22(8):986–1004.
- Ramcharan, A., McCloskey, P., Baranowski, K., Mbilinyi, N., Mrisho, L., Ndalaha, M., Legg, J., a Hughes, D. P. (2019). A mobile-based deep learning model for cassava disease diagnosis. *Frontiers in plant science*, 10:272.
- Rastogi, A. a Ryuh, B. S. (2019). Teat detection algorithm: YOLO vs. Haar-cascade. *Journal of Mechanical Science & Technology*, 33(4).
- Ren, S., He, K., a Girshick, R. (2015). Faster R-CNN: towards real-time object detection with egion proposal networks. In *International Conference on Neural Information rocessing Systems*, pp. 91–99.
- Riekert, M., Klein, A., Adrion, F., Hoffmann, C., a Gallmann, E. (2020). Automatically detecting pig position and posture by 2D camera imaging and deep learning. *Computers and Electronics in Agriculture*, 174:105391.
- Robots, U. (2022). HOW TO CHOOSE THE BEST ROBOTIC GRIPPER FOR YOUR WORK? [cit. 2022-01-15], Dostupné z: <https://www.universal-robots.com/blog/how-to-choose-the-best-robotic-gripper-for-your-work/>.
- Saha, H. N., Chakraborty, S., a Roy, R. (2022). Chapter 21 - Integration of RFID and sensors in agriculture using IOT. In Abraham, A., Dash, S., Rodrigues, J. J., Acharya, B., a Pani, S. K., eds., *AI, Edge and IoT-based Smart Agriculture*, Intelligent Data-Centric Systems, pp. 361–372. Academic Press.
- Schumann, A. W., Mood, N. S., Mungofa, P. D., MacEachern, C., Zaman, Q., a Esau, T. (2019). Detection of three fruit maturity stages in wild blueberry fields using deep learning artificial neural networks. In *2019 ASABE Annual International Meeting 1*, p. American Society of Agricultural and Biological Engineers.
- Seo, J., Sa, J., Choi, Y., Chung, Y., Park, D., a Kim, H. (2019). A yolo-based separation of touching-pigs for smart pig farm applications. In *2019 21st International Conference on Advanced Communication Technology (ICACT)*, pp. 395–401. IEEE.
- Sonck, B. a Donkers, H. (1995). 62(1):25–37. cited By 14.
- Systems, F. (2014). Thermal imaging cameras keep dairy health in check. [cit. 2022-01-15], Dostupné z: http://www.foodprocessing.com.au/case_studies/67032-Thermal-imaging-cameras-keep-dairy-health-in-check.
- Tai, Y., Ling, P., a Ting, K. (1994). Machine vision assisted robotic seedling transplanting. *Transactions of the American Society of Agricultural Engineers*, 37(2):661–667. cited By 51.
- Takacs, G., Chandrasekhar, V., Tsai, S., Chen, D., Grzeszczuk, R., a Girod, B. (2013). Rotation-Invariant Fast Features for Large-Scale Recognition and Real-Time Tracking. *Image Commun.*, 28(4):334–344.

- Tian, Y., Yang, G., Wang, Z., Wang, H., Li, E., a Liang, Z. (2019). Apple detection during different growth stages in orchards using the improved YOLO-V3 model. *Computers and Electronics in Agriculture*, 157:417–426.
- Torsius, A. (1988). Milking apparatus. US4726322A.
- Tyagi, D. (2019). Introduction To Feature Detection And Matching. [cit. 2022-01-15], Dostupné z: <https://medium.com/data-breach/introduction-to-feature-detection-and-matching-65e27179885d>.
- Viola, P. a Wells, W. (1995). Alignment by Maximization of Mutual Information. volume 24, pp. 16–23.
- Wang, D., Tang, J., Zhu, W., Li, H., Xin, J., a He, D. (2018). Dairy goat detection based on Faster R-CNN from surveillance video. *Computers and Electronics in Agriculture*, 154:443–449.
- Wu, D., Wu, Q., Yin, X., Jiang, B., Wang, H., He, D., a Song, H. (2020). Lameness detection of dairy cows based on the YOLOv3 deep learning algorithm and a relative step size characteristic vector. *Biosystems Engineering*, 189:150–163.
- Xu, B., Wang, W., Falzon, G., Kwan, P., Guo, L., Chen, G., Tait, A., a Schneider, D. (2020). Automated cattle counting using Mask R-CNN in quadcopter vision system. *Computers and Electronics in Agriculture*, 171:105300.
- Xue, Y., Zhu, X., Zheng, C., Mao, L., Yang, A., Tu, S., Huang, N., Yang, X., Chen, P., a Zhang, N. (2018). Lactating sow postures recognition from depth image of videos based on improved Faster R-CNN. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering*, 34(9):189–196. cited By 16.
- Yang, Q., Xiao, D., a Lin, S. (2018a). Feeding behavior recognition for group-housed pigs with the Faster R-CNN. *Computers and Electronics in Agriculture*, 155:453–460.
- Yang, X., Sun, H., Fu, K., Yang, J., Sun, X., Yan, M., a Guo, Z. (2018b). Automatic Ship Detection in Remote Sensing Images from Google Earth of Complex Scenes Based on Multiscale Rotation Dense Feature Pyramid Networks. *Remote Sensing*, 10(1).
- Yap, P.-T., Jiang, X., a Kot, A. C. (2010). Two-Dimensional Polar Harmonic Transforms for Invariant Image Representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(7):1259 – 1270.
- Yu, Y., Zhang, K., Zhang, D., Yang, L., a Cui, T. (2019). Optimized Faster R-CNN for Fruit Detection of Strawberry Harvesting Robot. In *2019 ASABE Annual International Meeting 1*, p. American Society of Agricultural and Biological Engineers.
- Zamir, S. W., Arora, A., Khan, S., Khan, F. S., a Shao, L. (2021). Learning digital camera pipeline for extreme low-light imaging. *Neurocomputing*, 452:37–47.
- Zhao, W. a Chellappa, R., eds. (2006). *Front Matter*. Academic Press, Burlington.
- Zheng, C., Zhu, X., Yang, X., Wang, L., Tu, S., a Xue, Y. (2018). Automatic recognition of lactating sow postures from depth images by deep learning detector. *Computers and Electronics in Agriculture*, 147:51–63.

Seznam obrázků

1.1	Rybinová dojírna	9
1.2	Paralelní dojírna	9
1.3	Tandemová dojírna	10
1.4	Kruhová dojírna	11
1.5	"Systém systémů", který se skládá ze čtyř strojů podobných člověku. . . .	12
1.6	Patent 1	13
1.7	Patent 2	14
1.8	Lely Astronaut	16
1.9	DeLaval	16
1.10	Robot společnosti Fullwood	17
1.11	Robotická dojírna společnosti GEA	17
1.12	GEA In-Liner Everything	18
1.13	Termální snímek vemene a struků u dvou různých krav	19
1.14	Falešná identifikace struků	20
1.15	Schéma stereofonní rekonstrukce	21
1.16	Detekce příznaků	22
3.1	StimuLactor	28
3.2	Hlavní části StimuLactoru	29
3.3	Schéma StimuLactoru	29
3.4	Pracovní rozsah robota	32
3.5	Řídicí jednotka R-30iB Plus	32
3.6	Prostředí programu iRVision	33
3.7	Koncepce místnosti a rozmístění pro robotické zařízení	34
3.8	3D vizualizace dojícího stání	36
4.1	Přehledová situace robotického ramene a objektů k detekci	37
4.2	Zobrazení vzdáleností osy Z	39
4.3	Možnost Static	40
4.4	Možnost Model ID	41
4.5	Zvolené parametry procesu vidění	41
4.6	GPM Tool lokace	43
4.7	3D rovina	44
4.8	Detekce referenční pozice	45
4.9	Program pro lokalizaci objektů	46

Seznam tabulek

1.1	Různé aplikace hlubokého učení v zemědělství	25
3.1	Technická data StimuLactoru	30
3.2	Parametry 3D senzoru	34