

UNIVERZITA PARDUBICE

FAKULTA ELEKTROTECHNIKY A
INFORMATIKY

BAKALÁŘSKÁ PRÁCE

2024

Benjamín Šafář

Univerzita Pardubice
Fakulta elektrotechniky a informatiky

Kontrola specifikace čelního skla a vrchního dílu přístrojové desky s využitím
kamerového systému Cognex

Bakalářská práce

Univerzita Pardubice
Fakulta elektrotechniky a informatiky
Akademický rok: 2023/2024

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Benjamín Šafář**
Osobní číslo: **I21069**
Studijní program: **B0714A150008 Automatizace**
Téma práce: **Kontrola specifikace čelního skla a vrchního dílu přístrojové desky s využitím kamerového systému Cognex**
Zadávací katedra: **Katedra řízení procesů**

Zásady pro vypracování

Cílem práce je vytvořit a implementovat algoritmus pro kontrolu specifikace čelního skla a vrchního dílu přístrojové desky z obrazových dat s využitím kamerového systému Cognex. Řešení kontroly bude založeno na zpracování obrazu s využitím Cognex Designer Software.

V teoretické části práce bude proveden průzkum problematiky kamerové kontroly v automobilovém průmyslu se zaměřením na inspekci specifických komponent vozidla spolu s přehledem stávajících technologických řešení pro požadovanou kontrolu. Dále bude provedena rešerše kamerových systémů Cognex a stručný popis jejich obslužných softwarů.

Praktická část bude zaměřena na aplikaci teoretických poznatků v reálném prostředí výrobní linky. Konkrétně na tvorbu řešení pro samotné zpracování obrazu pro kontrolu specifikace čelního skla a vrchního dílu přístrojové desky a jeho implementaci do systémů Cognex spolu s evidencí záznamů kontroly kvality sledovaných dílů a jejich přehlednou vizualizaci. Závěrem práce bude provedeno shrnutí dosažených výsledků, hodnocení spolehlivosti řešení a diskuze o potenciálních vylepšeních.

Rozsah pracovní zprávy: **cca 40 stran**
Rozsah grafických prací:
Forma zpracování bakalářské práce: **tištěná/elektronická**

Seznam doporučené literatury:

BELBACHIR, Ahmed Nabil, ed. *Smart Cameras* [online]. Boston, MA: Springer US, 2010. ISBN 978-1-4419-0954-1. Dostupné z: doi:10.1007/978-1-4419-0953-4
GONZALEZ, Rafael C. a Richard E. WOODS, [2018]. *Digital image processing*. Fourth edition. New York: Pearson. ISBN 978-013-3356-724.

Vedoucí bakalářské práce: **Ing. Dominik Štursa**
Katedra řízení procesů

Datum zadání bakalářské práce: **15. prosince 2023**
Termín odevzdání bakalářské práce: **10. května 2024**

Ing. Zdeněk Němec, Ph.D. v.r.
děkan

L.S.

Ing. Daniel Honc, Ph.D. v.r.
vedoucí katedry

V Pardubicích dne 12. ledna 2024

Prohlašuji:

Práci s názvem Kontrola specifikace čelního skla a vrchního dílu přístrojové desky s využitím kamerového systému Cognex jsem vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

Byl jsem seznámen s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnicí Univerzity Pardubice č. 7/2019 Pravidla pro odevzdávání, zveřejňování a formální úpravu závěrečných prací, ve znění pozdějších dodatků, bude práce zveřejněna prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 09. 05. 2024

Benjamín Šafář v.r.

PODĚKOVÁNÍ

Děkuji Ing. Dominiku Štursovi za pomoc při vedení bakalářské práce. Mé poděkování patří též Ing. Robertu Zinkovi za pomoc při zpracování praktické části v automobilovém závodě Toyota Motor Manufacturing Czech Republic.

ANOTACE

Tato práce se věnuje vytvoření aplikace kamerové kontroly pro inspekci štítku čelního skla a vrchního dílu přístrojové desky s využitím kamerového systému Cognex. Nejprve jsou uvedeny základní principy kamerové inspekce a strojového vidění. Provedena je rešerše kamerových systémů Cognex. V praktické části je vytvořena inspekční aplikace s využitím nástrojů Cognex Designer, Deep Learning a vyhodnocena její spolehlivost.

KLÍČOVÁ SLOVA

počítačové vidění, strojové učení, kamerová inspekce, Cognex Designer, Cognex VisionPro
Deep Learning

TITLE

Inspection of the specification of the windshield and the upper part of the instrument panel using the Cognex camera system

ANNOTATION

This thesis is dedicated to the creation of a camera inspection application for the inspection of the windshield label and the upper part of the instrument panel using the Cognex camera system. First, the basic principles of camera inspection and machine vision are given. Cognex camera systems are searched. In the practical part, an inspection application is created using Cognex Designer, Deep Learning tools and its reliability is evaluated.

KEYWORDS

computer vision, machine learning, camera inspection, Cognex Designer, Cognex VisionPro
Deep Learning

OBSAH

SEZNAM ILUSTRACÍ A TABULEK.....	11
SEZNAM ZKRATEK A ZNAČEK	12
ÚVOD.....	13
1 KAMEROVÁ KONTROLA V PRŮMYSLU.....	14
1.1 Zajištění bezpečnosti.....	14
1.2 Sledování procesů	14
1.3 Kontrola kvality	14
1.3.1 Manuální kamerová inspekce	15
1.3.2 Automatická kamerová inspekce	15
2 STROJOVÉ VIDĚNÍ.....	16
2.1 Konvoluční neuronové sítě	16
2.2 Trénink modelu strojového učení	17
2.3 Systémy strojového vidění.....	18
2.3.1 Kamerový senzor	19
2.3.2 Inteligentní kamera	20
2.3.3 PC systém	21
3 KAMEROVÉ SYSTÉMY COGNEX	22
3.1 Čtečky čárových kódů DataMan.....	22
3.2 Inteligentní kamery In-Sight.....	23
3.3 PC systémy	24
3.3.1 VisionPro	25
3.3.2 VisionPro Deep Learning	25
3.3.2.1 Uživatelské rozhraní	26
3.3.2.2 Nástroj Blue Locate	27
3.3.2.3 Nástroj Green Classify.....	27
3.3.2.4 Nástroj Blue Read.....	28
3.3.2.5 Nástroj Red Analyze.....	28

3.3.3 Designer Software.....	29
3.3.4 Industriální kamery Cognex.....	30
3.3.4.1 Protokol GigE Vision.....	31
3.3.4.2 Protokol PoE	31
4 PARAMETRY PRO VÝBĚR KAMERY A OBJEKTIVU	32
4.1 Rozlišení senzoru.....	32
4.2 Ohnisková vzdálenost	32
5 KAMEROVÁ INSPEKCE	34
5.1 Výrobní prostředí.....	34
5.2 Specifikační štítek čelního skla.....	35
5.3 Přístrojový panel	35
5.3.1 Head-up displej.....	36
5.3.2 Mřížka reproduktoru	36
5.3.3 Kryt sdružených přístrojů	37
5.4 Výběr a montáž kamery	37
5.5 Nastavení obrazu kamery.....	39
5.6 Příprava pracovní stanice.....	41
5.7 Vývojový diagram	42
5.8 Získávání dat a sběr fotek	43
5.9 Vyhodnocení štítku čelního skla.....	45
5.9.1 Klasifikace bez lokalizace	45
5.9.2 Lokalizace rohu čelního skla	46
5.9.2.1 Klasifikace	47
5.9.2.2 Čtení.....	47
5.9.3 Lokalizace části štítku.....	49
5.9.3.1 Klasifikace	49
5.9.3.2 Čtení.....	50

5.10 Vyhodnocení částí přístrojové desky	52
5.10.1 Lokalizace	52
5.10.2 Klasifikace head-up displeje	52
5.10.3 Klasifikace mřížky reproduktoru	53
5.10.4 Klasifikace krytu sdružených přístrojů	53
5.11 Přesnost modelů	54
5.12 Vyhodnocení a zápis výsledku	55
5.13 HMI vizualizace	56
5.14 Spolehlivost finální aplikace	57
ZÁVĚR	58
POUŽITÁ LITERATURA	59
SEZNAM PŘÍLOH	62

SEZNAM ILUSTRACÍ A TABULEK

Obrázek 1 – Manuální kamerová inspekce	15
Obrázek 2 – Automatická kamerová inspekce	15
Obrázek 3 – Architektura konvoluční neuronové sítě, zdroj: [8]	16
Obrázek 4 – Kroky pro trénink modelu strojového učení	17
Obrázek 5 – Blokové schéma kamerového senzoru, podle: [12]	19
Obrázek 6 – Blokové schéma inteligentní kamery, podle: [12]	20
Obrázek 7 – Blokové schéma PC systému strojového vidění, podle [12].....	21
Obrázek 8 – Čtení ID karty vozu pomocí čtečky DM280.....	22
Obrázek 9 – Inteligentní kamera In-Sight D900 na bráně kamerové inspekce TMM CZ	23
Obrázek 10 – Inteligentní kamera In-Sight 2800, detail snímače a zadních konektorů.....	23
Obrázek 11 – Vývojové prostředí VisionPro Quickbuild	25
Obrázek 12 – Rozhraní ViDi Suite, použití uzlového modelu k lokalizaci matice disku kola.....	26
Obrázek 13 – Rozhraní ViDi Suite, klasifikace štítku čelního skla	27
Obrázek 14 – Rozhraní ViDi Suite, čtení štítku čelního skla.....	28
Obrázek 15 – Vývojové prostředí Designer	29
Obrázek 16 – Industriální kamera CIC 5000, detail snímače a zadních konektorů	30
Obrázek 17 – Princip objektivu kamery, podobnost trojúhelníků.....	32
Obrázek 18 – Detail štítku čelního skla pro model Aygo (vpravo), Yaris (vlevo)	35
Obrázek 19 – Detail kontrolované části přístrojové desky modelu Yaris	36
Obrázek 20 – Finalní montáž kamery Basler ace L na inspekční bránu	38
Obrázek 21 – Finalní nastavení obrazu pro štítek čelního skla modelu Aygo a Yaris.....	39
Obrázek 22 – Finalní nastavení obrazu pro přístrojovou desku modelu Yaris	40
Obrázek 23 – Nastavení IP adresy kamery v GigE Vision Configurator.....	41
Obrázek 24 – Principiální schéma zapojení inspekční aplikace.....	42
Obrázek 25 – Vývojový diagram inspekční aplikace.....	43
Obrázek 26 – ROI pro klasifikaci štítku čelního skla bez lokalizace.....	45
Obrázek 27 – Lokalizace rohu čelního skla	46
Obrázek 28 – ROI pro klasifikaci štítku čelního skla s lokalizací v rohu skla.....	47
Obrázek 29 – Čtení štítku čelního skla s lokalizací v rohu skla.....	47
Obrázek 30 – Lokalizace části štítku.....	49
Obrázek 31 – ROI pro klasifikaci štítku čelního skla s lokalizací části štítku	49
Obrázek 32 – Čtení štítku čelního skla s lokalizací části štítku	50
Obrázek 33 – Lokalizace referenčního bodu přístrojové desky	52
Obrázek 34 – ROI pro klasifikaci head-up displeje	52
Obrázek 35 – ROI pro klasifikaci mřížky reproduktoru	53
Obrázek 36 – ROI pro klasifikaci krytu združených přístrojů	53
Obrázek 37 – Vizualizace aplikace pomocí HMI, video (Příloha F).....	56
Tabulka 1 – Souhrn přijatých specifikací inspekce	44
Tabulka 2 – Parametry tréninku klasifikace štítku čelního skla bez lokalizace	46
Tabulka 3 – Parametry tréninku nástrojů s lokalizací v rohu čelního skla.....	48
Tabulka 4 – Parametry tréninku nástrojů s lokalizací části štítku	51
Tabulka 5 – Parametry tréninku nástrojů pro klasifikaci částí přístrojové desky	54
Tabulka 6 – Výsledky přesnosti modelů na testovacím datasetu	55
Tabulka 7 – Výsledky přesnosti běhu finální aplikace.....	57

SEZNAM ZKRATEK A ZNAČEK

TMMCZ – Toyota Motor Manufacturing Czech

CCTV – Closed-Circuit Television

OCR – Optical Character Recognition

CNN – Convolutional neural network

HMI – Human Machine Interface

ROI – Region of Interest

FoV – Field of View

ReLU – Rectified Linear Unit

PoE – Power over Ethernet

AI – Assembly Inspection

ÚVOD

Na výsledek hospodaření automobilového závodu mají vliv různé faktory. Zásadní roli hraje poptávka po nových vozech, dostupnost dílů a tomu odpovídající objem výroby. Pro zefektivnění výrobního procesu se využívá průmyslové automatizace, která snižuje potřebu lidské práce a celkové náklady na provoz.

Automatizované stroje jsou schopny provádět přesnou a konzistentní práci rychle a nepřetržitě. Kvalita výsledného produktu je méně ovlivněna lidskými faktory, snižují se rizika pracovních úrazů a zlepšují se pracovní podmínky. Celkově řečeno, průmyslová automatizace přináší významné výhody a je nezbytným krokem směrem k moderní a efektivní výrobě.

Pro dosažení vysoké kvality výrobků a včasné odhalení závad se provádí kontrola kvality. Výroba automobilu je velmi komplexní výrobní proces, při kterém je třeba ověřovat bezchybnost všech dílčích komponent, vizuální stav vozu po jeho smontování a finální funkčnost vozidla jako celku. V tomto procesu je využíváno čím dál více prvků automatizace. Od automatizovaného měření výrobních tolerancí senzory, přes vizuální kontrolu pomocí kamerové inspekce, až po automatizovanou diagnostiku systémů hotového vozidla.

Tato práce bude zaměřena na problematiku kamerové inspekce v prostředí automobilového závodu, konkrétně Toyota Motor Manufacturing Czech s.r.o. Cílem inspekce bude automatizovaná vizuální kontrola specifikačního štítku čelního skla a částí přístrojové desky. Výsledné řešení bude navrženo tak, aby mohlo být integrováno do stávajícího systému kamerové inspekce na lince Assembly Inspection.

Teoretická část práce bude zaměřena na průzkum a využití kamerových systémů v průmyslu. Poté bude popsán proces kamerové inspekce a strojového vidění. Následně bude stručně vysvětlena architektura konvolučních neuronových sítí a postup trénování modelu strojového učení. Rozděleny a popsány typy kamerových systémů a následně bude provedena rešerše kamerových systémů Cognex a popis jejich obslužných softwarů. Definovány budou základní parametry pro výběr kamerového systému.

V praktické části budou teoretické poznatky přeneseny do reálného prostředí výrobní linky. Detailně bude rozebrána tvorba celkového řešení pro kamerovou inspekci. Od výběru a instalace kamery až po vývoj samotné aplikace, využití nástrojů strojového vidění, komunikace s výrobními systémy a finální vyhodnocení spolehlivosti systému s diskusí o potenciálních vylepšeních.

1 KAMEROVÁ KONTROLA V PRŮMYSLU

Kamerová kontrola se v průmyslu používá k monitorování výrobních procesů, za účelem zlepšení kvality, bezpečnosti a efektivity výroby. Kamery bývají umístěny na strategických místech výrobních linek nebo zařízení a sledují různé aspekty výroby.

1.1 Zajištění bezpečnosti

V oblasti bezpečnosti se využívají kamerové systémy typu CCTV (Closed-Circuit Television, uzavřený televizní okruh), které se využívají k zobrazení kamerových záběrů na monitorech a případné archivaci nepřetržitého obrazu [1]. Kamery umístěné v průmyslových zařízeních mohou detekovat potenciálně nebezpečné situace, jako jsou překročení bezpečnostních zón, přítomnost neoprávněných osob nebo nesprávné používání zařízení. Významnou výhodou CCTV systémů je jejich schopnost poskytnout důkazní materiál v případě incidentů, nehod nebo trestné činnosti v průmyslovém objektu [2].

1.2 Sledování procesů

Kamery jsou také využívány ke sledování procesů v průmyslovém prostředí. Monitorování pohybu materiálů a komponentů po výrobní lince umožňuje zvýšit efektivitu výroby identifikací případných problémů nebo úzkých hrdel ve výrobním procesu.

Kamery mohou spolehlivě sledovat rychlost nebo tok materiálu. Oproti klasickým rychlostním a průtokovým sensorům není kamera vystavena kontaktu s materiálem ani mechanicky namáhána pohybem dopravníku [3].

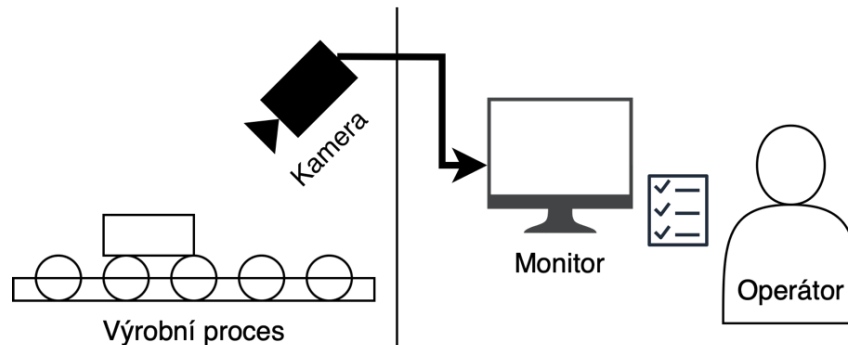
Dále se kamery používají pro logistické účely automatického sledování a třídění zboží. Kamery pomáhají třídít a manipulovat s výrobky za pomoci strojového vidění, načítat identifikační kódy balíků či palet a tím zefektivnit procesy pro příjem a expedici zboží [4].

1.3 Kontrola kvality

Kamery hrají klíčovou roli v procesu kontroly kvality v průmyslovém prostředí. Vizuální inspekce pomocí kamer umožňuje rychlé a přesné hodnocení výrobků na přítomnost vad nebo nedostatků. Kromě kontroly výsledných výrobků mohou kamery také sledovat správnost provedení montážních operací, což zajišťuje dodržení přesných specifikací a standardů výroby [5]. Kamerové inspekce se dají dále rozdělit na manuální a automatizované.

1.3.1 Manuální kamerová inspekce

Manuální kamerová kontrola je proces, při kterém lidský operátor vizuálně kontroluje výrobky nebo komponenty za účelem detekce vad, nedostatků nebo nesrovnalostí. V tomto případě je kamera prostředkem pro zachycení kontrolované oblasti výrobku a využívá se především pro zlepšení ergonomie operátora.

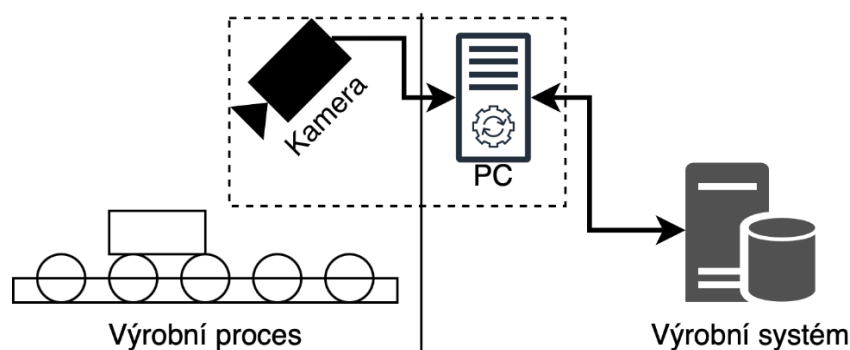


Obrázek 1 – Manuální kamerová inspekce

Operátor sleduje obraz na monitoru, porovnává vizuální data se stanovenými standardy kvality a výsledek kontroly zaznamenává manuálně do evidence. Výstupy kontroly jsou v tomto případě ovlivněny lidským úsudkem, kdy záleží na zkušenostech a pozornosti konkrétního operátora. Manuální systémy jsou cenově dostupnější než automatické, rychleji integrovatelné do procesů a výhodou operátora je flexibilita reagovat na nestandardní situace a detekovat subtilní vady [5].

1.3.2 Automatická kamerová inspekce

Automatická kamerová inspekce je proces využívající moderní technologie pro zajištění kvality výroby a detekci vad. Kamerový systém zachycuje obraz a je vybaven algoritmy strojového vidění, což umožňuje automatické vyhodnocení defektu bez lidského dohledu. Kamerové aplikace přímo komunikují s výrobními systémy a automaticky evidují případné vady [5].



Obrázek 2 – Automatická kamerová inspekce

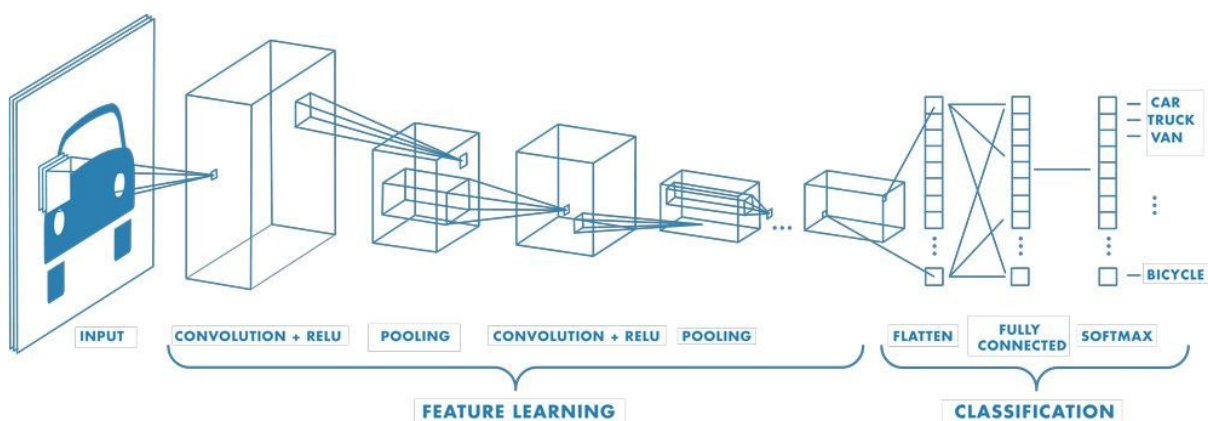
2 STROJOVÉ VIDĚNÍ

Strojové vidění, nebo také počítačové vidění, je obor umělé inteligence, který se zabývá vývojem systémů schopných automaticky analyzovat a interpretovat vizuální informace z digitálních obrázků nebo videí. Tyto systémy napodobují schopnost lidského vidění a porozumění vizuálním datům [6]

Mezi hlavní úlohy počítačového vidění patří rozpoznávání obrazu, což zahrnuje identifikaci a klasifikaci objektů nebo vzorů v obrazech. Další úlohou může být detekce objektů, která je soustředěna na nalezení a lokalizaci všech významných vlastností v obraze a přiřazení jim odpovídajících popisů. Rozdělením obrázku na části nebo segmenty podle jejich vizuálních vlastností se zabývá segmentace, jejíž hlavním využitím je oddělení objektů od pozadí. Pro průmyslové využití je velmi důležitou úlohou OCR (Optical Character Recognition, Optická Detekce Znaků), která se zabývá čtením a digitalizací textu. V oboru strojového vidění se využívají algoritmy strojového učení jako jsou konvoluční neuronové sítě.

2.1 Konvoluční neuronové sítě

Konvoluční neuronové sítě (CNNs) jsou speciální typ neuronových sítí, které byly navrženy pro práci s vizuálními daty, jako jsou obrázky a videa. Tyto sítě se skládají z vrstev neuronů, které provádějí různé operace a jsou schopné automaticky extrahovat vlastnosti a vzory z vizuálních dat [7].



Obrázek 3 – Architektura konvoluční neuronové sítě, zdroj: [8]

Konvoluční vrstva je první vrstvou v CNN. V této vrstvě jsou použity filtry (jádra), které jsou posouvány po vstupních datech (obrázku). Každý filtr reaguje na různé vzory v datech, čímž vytváří mapy příznaků (feature maps) prostřednictvím konvoluce. Celkově konvoluční vrstva hraje klíčovou roli při extrakci a hierarchické reprezentaci příznaků ze vstupních dat.

Po konvoluci se aplikuje nelineární aktivační funkce. Aktivační funkce určuje, které rysy jsou relevantní. Nejběžněji používanou aktivační funkcí je ReLU (Rectified Linear Unit). Funkce ReLU zůstává pro vstupy větší než nula lineární, což usnadňuje učení a zlepšuje efektivitu výpočtů. Pro záporné vstupy má nulový výstup, což pomáhá eliminovat "mrtvé neurony". Je jednoduchá na výpočet a efektivní pro trénování sítě.


Pro redukci rozměrů map funkcí a počtu parametrů sítě se využívají Pooling vrstvy. Pooling napomáhá snížit výpočetní náročnost a zachovat důležité informace. Nejběžnější je metoda MaxPooling, která pro každý region vstupní mapy příznaků vybere maximální hodnotu.

Vrstva pro rozprostření (Flatten) převede výstupní mapy příznaků z předchozí vrstvy na jednorozměrný vektor. Tím se umožní předání výstupu konvolučních a pooling vrstev do plně propojených vrstev, které vyžadují jednorozměrný vstup.

Plně propojené vrstvy jsou tvořeny neurony, které jsou v každé vrstvě spojeny s každým neuronem z předchozí vrstvy. Pro každý neuron v této vrstvě se provádí lineární kombinace vstupů s váhami a poté výsledek projde nelineární aktivační funkcí. Tímto způsobem plně propojené vrstvy pomáhají neuronové síti pochopit složité vzory a vztahy v datech. Tato vrstva je využívána především pro klasifikační úkoly, kde je schopná modelovat složité vztahy mezi vstupy a výstupy.

Poslední vrstvou v CNN je obvykle Softmax vrstva, která vrací pravděpodobnostní distribuci mezi různými třídami v případě klasifikační úlohy. Jejím hlavním účelem je transformovat výstupy neuronů z předchozí plně propojené vrstvy na pravděpodobnostní distribuci mezi různými třídami. Výstupy lze následně použít k rozhodnutí, do které třídy daný vstup patří na základě nejvyšší pravděpodobnosti [9].

2.2 Trénink modelu strojového učení



Obrázek 4 – Kroky pro trénink modelu strojového učení

Prvním krokem je sběr snímků, kde se získávají data potřebná pro trénink modelu. Tato data by měla zahrnovat rozmanité scény, objekty a podmínky osvětlení, aby byla zajištěna robustnost a generalizace modelu. Tyto snímky lze manuálně nasbírat pomocí kamery nebo internetové databáze obrázků.

Následuje příprava snímků, kde se získané obrázky upravují a připravují pro samotný trénink. To zahrnuje úpravu rozlišení, normalizaci osvětlení, oříznutí nebo odstranění šumu. Cílem je zajistit konzistenci formátu a kvality obrázků, což usnadní jejich zpracování v dalších fázích.

Poté je nutné vybrat vhodný model pro trénink. V závislosti na konkrétní úloze může být použitý model pro klasifikaci, lokalizaci, segmentaci obrazu či čtení textu. Model je následně trénován na připravených datech, kde se postupně přizpůsobuje tak, aby lépe rozpoznával vzory a struktury v datech.

Po tréninku je důležité optimalizovat model, což zahrnuje ladění jeho parametrů. Cílem je dosáhnout co nejlepších výsledků a zlepšit spolehlivost a generalizaci modelu. Upravovat lze parametry jako počet epoch určující počet průchodů tréninkovým datasetem během tréninku modelu nebo velikost dávky. Ta určuje počet tréninkových vzorků použitých pro aktualizaci vah modelu během jedné iterace tréninku. Dále se upravují parametry rychlosti učení a využívají různé optimalizační algoritmy pro řízení aktualizace vah během tréninku. Pro omezení přetréování modelu se využívá regularizace.

Po optimalizaci je třeba vyhodnotit výkon modelu pomocí validačních dat, která nebyla použita během tréninku. To zahrnuje různé metriky jako přesnost a návratnost, aby se posoudila spolehlivost a účinnost modelu.

Nakonec je model připraven k nasazení do produkčního prostředí, což zahrnuje jeho integraci do aplikací a nasazení pro provoz v reálném čase [10].

2.3 Systémy strojového vidění

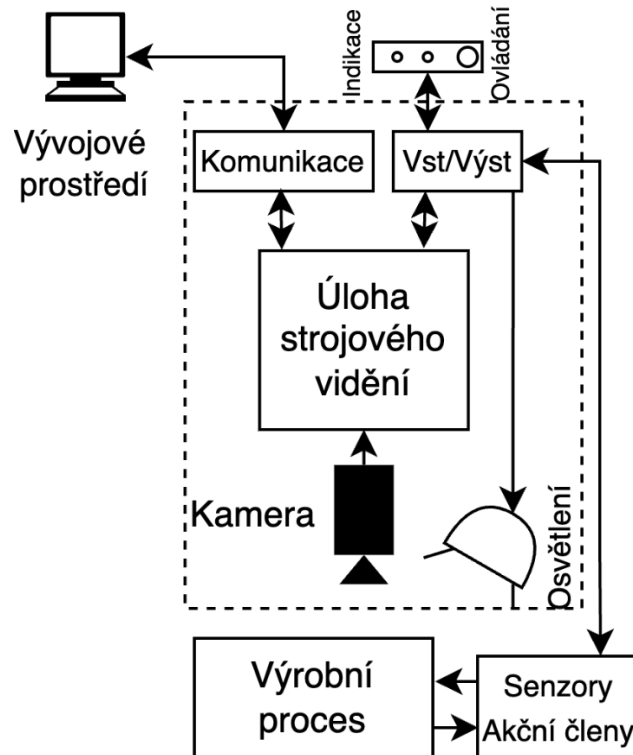
Systém strojového vidění je technologický systém, který využívá počítačové zpracování obrazu k automatickému získávání, analýze a interpretaci informací obsažených v obrazech nebo videích. Cílem systému strojového vidění je umožnit počítačům "vidět" a porozumět svému okolí, podobně jako lidské oko a mozek.

Takové systémy zahrnují hardware, jako jsou kamerové senzory pro snímání obrazů, a software pro jejich zpracování. Software provádí různé operace, jako je detekce objektů, rozpoznávání vzorů, extrakce vlastností a rozhodování na základě získaných dat.

Pro aplikaci strojového vidění v praxi se využívají různé systémy, které jsou koncipovány s ohledem na jejich konkrétní použití. Systémy se dají rozdělit na jednodušší kamerové senzory, inteligentní kamery a komplexní PC systémy [11].

2.3.1 Kamerový senzor

Kamera senzor je zařízení pro jednoduché aplikace v průmyslovém prostředí. Na rozdíl od univerzálních systémů strojového vidění, které nabízejí širokou škálu funkcí a flexibilitu, kamerové senzory jsou jednodušší, levnější a specializované na konkrétní úlohy [12].

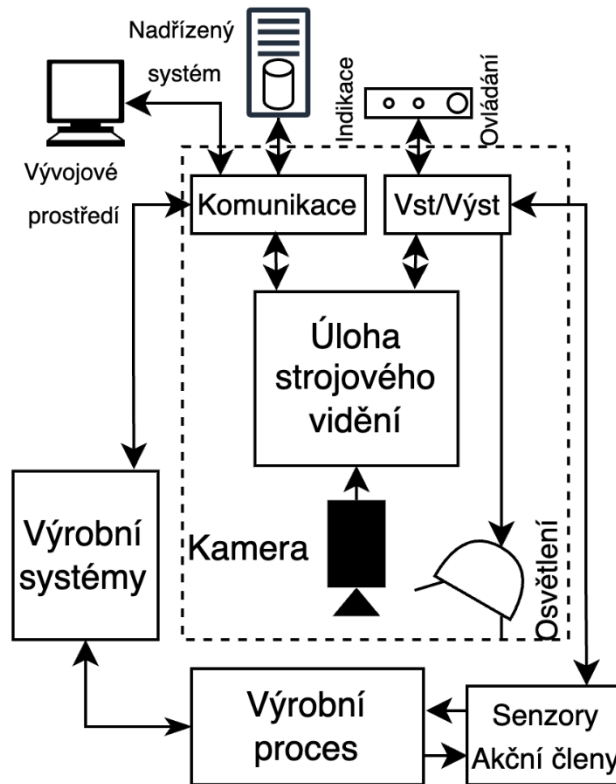


Obrázek 5 – Blokové schéma kamerového senzoru, podle: [12]

Kamerový senzor je systém, který do jednoho pouzdra integruje kameru, osvětlení a omezený počet digitálních výstupů/vstupů, které mívají pevně danou funkci (např. spoušť, výstup signalizace). Pro komunikaci se většinou využívá Ethernet, kdy konfigurační rozhraní umožňuje měnit základní parametry úlohy a velmi omezené možnosti programování a komunikace přes průmyslové sběrnice. Použití je tedy omezeno typicky na aplikace čtení textu, kódů nebo jednoduché klasifikace celého obrazu bez možností lokalizace a s omezeným počtem tříd.

2.3.2 Inteligentní kamera

Inteligentní kamera, nebo také Smart kamera, je zařízení vybavené kamerovým senzorem a integrovaným mikropočítačem pro řešení složitých aplikací strojového vidění. Smart kamery jsou univerzální systémy, které nabízejí rozsáhlé možnosti funkcí za cenu vyšší pořizovací částky [12].

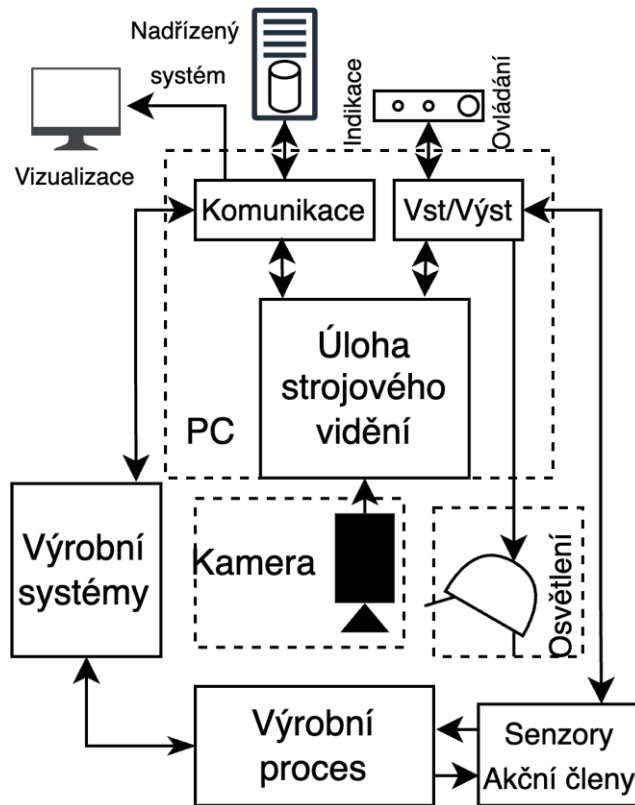


Obrázek 6 – Blokové schéma inteligentní kamery, podle: [12]

Mezi charakteristické znaky inteligentní kamery patří kompaktnost a využití výkonného mikročipu. V jednom pouzdře je integrován čip kamery, osvětlení a univerzální digitální vstupy/výstupy, jejichž funkce se dá konfigurovat v rozhraní kamery. Pro komunikaci využívají inteligentní kamery především Ethernet a disponují robustním vývojovým rozhraním, které umožňuje vývoj složitých aplikací, trénování modelů strojového vidění a nastavení komunikace pomocí širokého spektra průmyslových protokolů. Inteligentní kamera je vhodná pro řešení komplexních úloh strojového vidění s vyhodnocením více snímků, lokalizací vlastností, maskováním, klasifikací v určitém regionu, nástroji analýzy povrchu, čtením kódů a textu. V rámci aplikace je možné komunikovat s výrobními systémy a nadřizenými systémy pro získávání dat k vyhodnocení inspekce a následně i zapisovat výsledky.

2.3.3 PC systém

Počítačové systémy (PC vision) pro strojové vidění jsou robustní výpočetní platformy ke zpracování obrazu a analýze dat. Tyto systémy jsou schopné řešit širokou škálu aplikací pro zpracování obrazu s vysokou přesností a spolehlivostí, díky flexibilitě v použitém hardwaru a softwaru [12].



Obrázek 7 – Blokové schéma PC systému strojového vidění, podle [12]

PC systémy strojového vidění jsou založeny na kombinaci použití osobního počítače nebo mikropočítače jako vyhodnocovací jednotky. Kamera je umístěna samostatně a systém umožňuje připojení i většího množství kamer do jednoho PC. Pro připojení kamer se využívají rozhraní jako Ethernet nebo USB a počítač disponuje přídatnou kartou (frame grabber), která zajišťuje komunikaci s kamerou. Vstupně výstupní periférie jsou řešeny dalšími přídatnými I/O kartami a využít lze průmyslové sběrnice a TCP/IP protokoly. Výpočetní jednotkou pro trénování modelů a následný běh nástrojů strojového vidění se využívají výkonné grafické karty s vysokým počtem jader. Využity jsou pokročilé algoritmy strojového vidění pro klasifikaci, lokalizaci objektů, analýzu obrazu a čtení kódů či textu. Pro nastavení kamery a vývoj aplikace se využívá software nainstalovaný do počítače a v případě komerčního softwaru je vyžadován HW klíč pro jeho aktivaci. Vývojové prostředí pro počítačové systémy bývá zpravidla nejflexibilnější z hlediska komplexnosti aplikace a dovoluje řešit rozsáhlé inspekce s několika kamerami současně.


3 KAMEROVÉ SYSTÉMY COGNEX

Cognex Corporation je americký výrobce systémů strojového vidění, softwaru a senzorů používaných v automatizovaném průmyslovém výrobním procesu. Jejich technologie umožňuje inspekci a identifikaci dílů, detekci vad, ověření montáže produktů a řízení montážních robotů. Společnost Cognex sídlí v Natick, Massachusetts, USA a má kanceláře ve více než 20 zemích, včetně České republiky. Společnost Cognex nabízí v oblasti strojového vidění několik kategorií produktů od jednoduchých čteček kódů, přes kamerové sensory a smart kamery, až po komplexní PC systémy [13].

3.1 Čtečky čárových kódů DataMan

Mezi základní kamerové zařízení Cognex patří řada industriálních čteček DataMan, které slouží ke čtení jednorozměrných a dvourozměrných kódů. Čtečka využívá monochromatickou kameru a algoritmy pro skenování v reálném čase, což umožňuje spolehlivé čtení pod různými úhly s velkou šířkou zorného pole snímání. V porovnání s obyčejnými čtečkami čárových kódů nabízí řada DataMan vývojové prostředí, kde je možná základní konfigurace parametrů obrazu a možnosti skriptování v jazyce JavaScript.


Zástupce řady DataMan je model DM280, který disponuje rozlišením obrazu 1.6MP s rychlostí snímání 45 Hz. Pro zaměření disponuje čtečka dvěma směrovými LED a čtyřmi přísvětlovacími. K dispozici jsou dva opticky oddělené diskrétní vstupy a výstupy, dvojice GPIO a Ethernet. Napájení je řešeno pomocí PoE nebo externě 24 V. Možnosti komunikace zahrnují simulaci klávesnice přes USB a protokoly RS-232, TCP/IP, PROFINET, EtherNet/IP, Modbus, NTP, SFTP a FTP a čtečka splňuje krytí IP67 [14].



Obrázek 8 – Čtení ID karty vozu pomocí čtečky DM280

3.2 Inteligentní kamery In-Sight

Do zástupců kategorie inteligentních kamer spadají základní modely In-Sight 2800. Kamery nabízí nástroje strojového vidění Edge Learning s možnostmi klasifikace několika tříd a čtení textu s pomocí předučených sad textů. Pro nastavení kamery je využito prostředí EasyBuilder, které nabízí základní nástroje pro konfiguraci obrazu kamery, inspekční nástroj pro Edge Learning modely a jednoduchý program ve formě omezené tabulky Spreadsheet u vyšších modelů, konfigurátor komunikace TCP/IP, PROFINET, EtherNet/IP, SLMP, OPC/UA, FTP a menu pro nastavení funkce diskretních výstupů a nástroj pro tvorbu jednoduchého webového HMI. K dispozici je maximálně rozlišení snímače 2MP. Kamera je vhodná pro řešení jednoduchých klasifikačních úloh, kde je cílem rychlé nasazení. HW kamery je jinak totožný se čtečkou DM280 a liší se tedy především softwarem a využitím [15].



Obrázek 10 – Inteligentní kamera In-Sight 2800, detail snímáče a zadních konektorů



Obrázek 9 – Inteligentní kamera In-Sight D900 na bráně kamerové inspekce TMMCZ

Zástupci vyšší řady inteligentních kamer jsou modely In-Sight D900. Jedná se o kamery pro univerzální použití a nabízí pokročilé nástroje pro čtení textu, lokalizaci a klasifikaci velkého množství vlastností a inspekční nástroje pro hledání defektů. Pro vytváření modelů strojového vidění je využita knihovna Cognex ViDi, tudíž je kamera kompatibilní s modely pro počítačové inspekční systémy. Vývojové prostředí kamery disponuje komplexním rozhraním, které je založené na navazování buněk tabulky Spreadsheet.

Kamera disponuje modulárním systémem pro montáž různých kombinací objektivů s C závitem, přisvětlení a filtrů. Na výběr jsou modely se snímači o rozlišení 2.3 a 5MP, monochromatické a barevné se maximální snímkovací frekvencí od 16 po 51 fps. Interní úložiště kamery nabízí 16 GB, operační paměť má kapacitu 3 GB. Komunikace probíhá přes Ethernet port a protokoly TCP/IP a FTP. K dispozici je dvojice GPIO, dedikovaný trigger a opticky oddělený diskretní vstup a dva dvojice výstupů. Napájení je externí 24 V a kamera disponuje krytím IP67 [16].

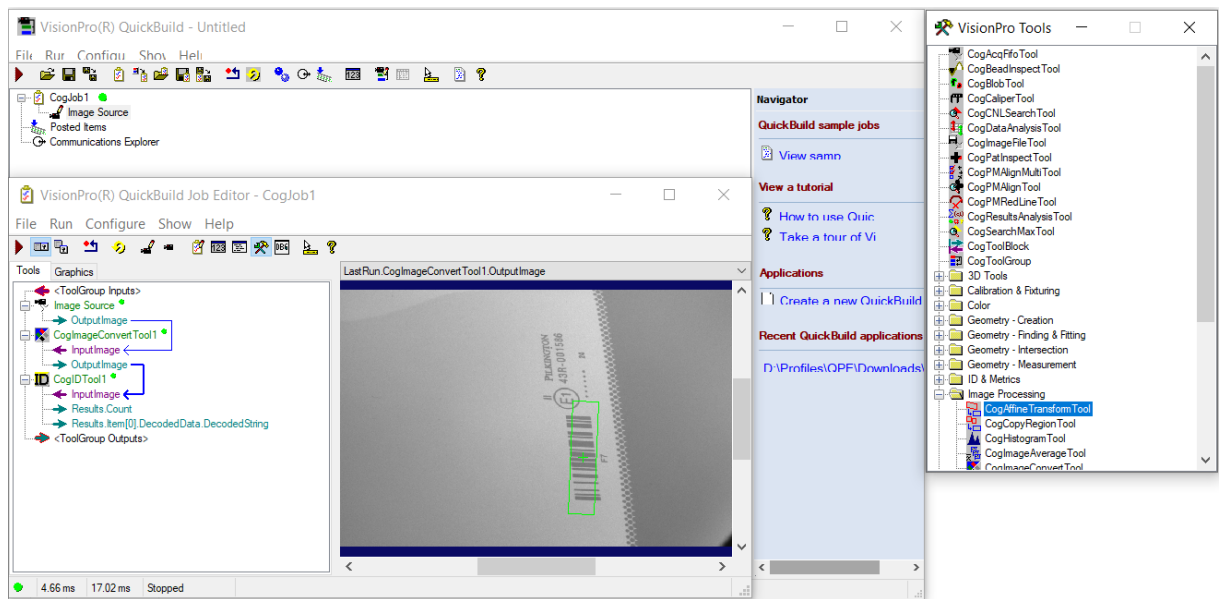
3.3 PC systémy

Počítačové systémy Vision jsou nejflexibilnějším řešením značky Cognex pro kamerové inspekce se strojovým viděním. Výhodou je možnost na jednom počítači zpracovávat obraz z několika kamer a pro zpracování obrazu využít vysoký výkon grafických karet.

Základem pro běh aplikace je libovolný počítač s vícejádrovým procesorem a moderní grafickou kartou NVIDIA. Kapacita operační paměti by měla být minimálně stejná jako kapacita paměti grafické karty. Uložiště je doporučeno typu SSD. Pro připojení kamery musí být přítomná grabovací karta s ethernetovými porty, podporující standard GigE Vision nebo lze použít podporované kamery USB či CameraLink.

Do portu USB je po dobu vývoje i nasazení aplikace připojený platný hardwarový licenční klíč Cognex Security Dongle. Licenční klíče se prodávají ve dvou variantách. Pro vývojové účely slouží trénovací licence, která je dražší a její platnost je časově omezená. Pro následné nasazení finální aplikace postačí licence Runtime, jejíž platnost není časově omezená a umožňuje aplikaci pouze spustit, nikoliv upravovat. Licence jsou v obou případech konfigurovatelné a podle ceny se odvíjí softwarové funkce. Zároveň s datem zakoupení je limitována maximální verze softwaru, kterou je schopný klíč licencovat.

3.3.1 VisionPro



Obrázek 11 – Vývojové prostředí VisionPro Quickbuild

Software VisionPro je základní nástroj pro vývoj aplikací systémů Cognex. Program nabízí velmi jednoduché rozhraní, které umožňuje připojit, nakonfigurovat kameru a poté navázat na vstup aplikace [17].

V prostředí QuickBuild se využívají bloky nástrojů, které se dají skládat do libovolného pořadí a různě mezi sebou navazovat. VisionPro obsahuje základní funkce pro úpravu vstupních snímků, základní skriptování a obrazové nástroje založené na pravidlech a jejich funkce jsou geometrická detekce objektů, měření vzdálenosti, kontrola a inspekce hran, čtení textu a čárových kódů (viz. obrázek 11), analýza barev a histogramové statistiky. Program je schopný komunikovat pomocí protokolu TCP/IP a ovládat diskrétní vstupy a výstupy rozšiřujících karet I/O. K dispozici je jednoduché a automaticky generované HMI pro operátora, které zobrazuje výstupy aplikace a základní možnosti ovládání.

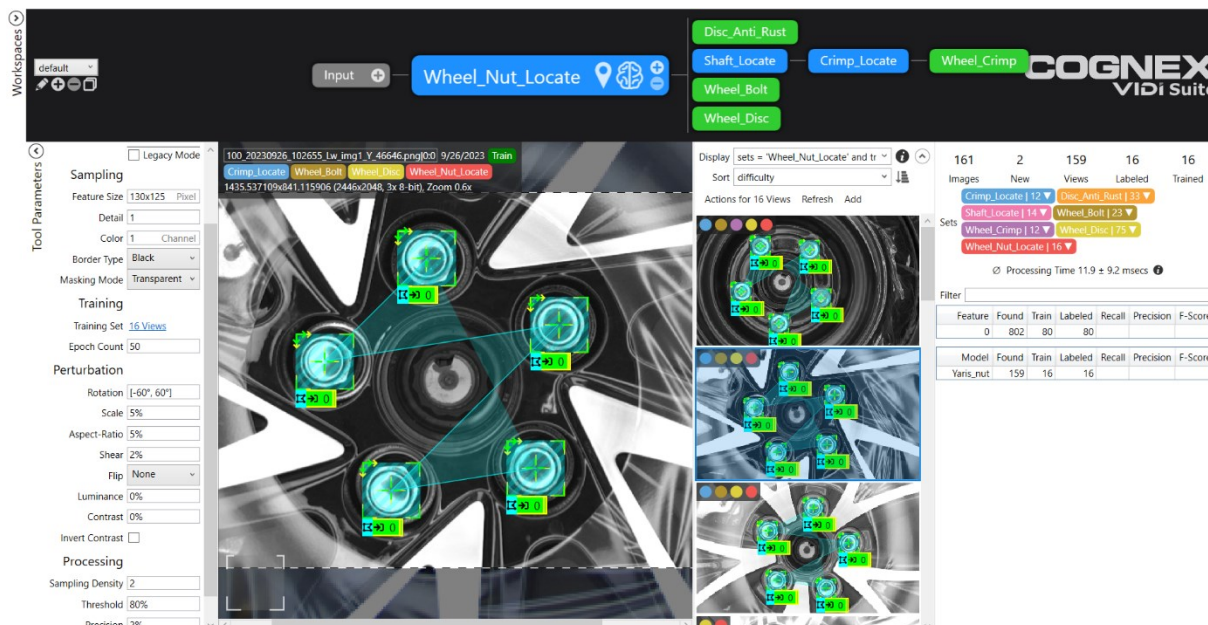
VisionPro se v dnešní době využívá častěji už jen jako nástroj pro vytváření funkčních bloků do modernějšího prostředí Designer, které je na základech VisionPro založeno a poskytuje pokročilejší funkce.

3.3.2 VisionPro Deep Learning

Deep Learning (dříve ViDi) je nástroj pro trénování modelů strojového vidění s využitím neuronových sítí a hlubokého učení. Deep Learning nabízí čtveřici nástrojů, a to pro lokalizaci prvků, analýzu dílů a povrchů, klasifikaci objektů a čtení textu. Práce s nástroji je velmi

jednoduchá a intuitivní oproti starším Vision inspekčním nástrojům, založených na manuálním nastavování pravidel [18].

3.3.2.1 Uživatelské rozhraní



Obrázek 12 – Rozhraní ViDi Suite, použití uzlového modelu k lokalizaci matic disku kola

Uživatelské prostředí Deep Learning Studio (ViDi Suite) je jednoduché a veškerá práce v něm probíhá na jedné stránce. Samotné pracovní prostředí je rozděleno do několika částí. V levém horním rohu se otevírá lišta s výběrem projektů z aktuálního adresáře. Projektů lze otevřít více najednou a prostředí tak umožňuje trénovat více modelů současně. Importované fotografie se nachází ve sloupci náhledů vlevo. V tomto sloupci lze dále fotografie hromadně označovat a seskupovat do setů a také nabízí kolonky Display a Sort, kam lze zadávat filtrovací fráze.

Přehled databáze je panel, který zobrazuje aktuální informace o celkovém počtu fotografií v databázi, setech a počet zpracovaných, označených a natrénovaných fotografií. Vrchní nabídka nahoře je určena k přidávání nástrojů do projektu, spuštění zpracování fotek a tréninku modelů. Na výběr je ze čtyř nástrojů – Blue Locate, Green Classify, Blue Read a Red Analyze.

Hlavník oknem prostředí je náhled aktuální fotografie, který slouží pro nastavení ROI a označení hledaných vlastností. Pro nastavení parametrů nástroje je určena postranní nabídka vpravo, která obsahuje parametry pro úpravu chování modelu.

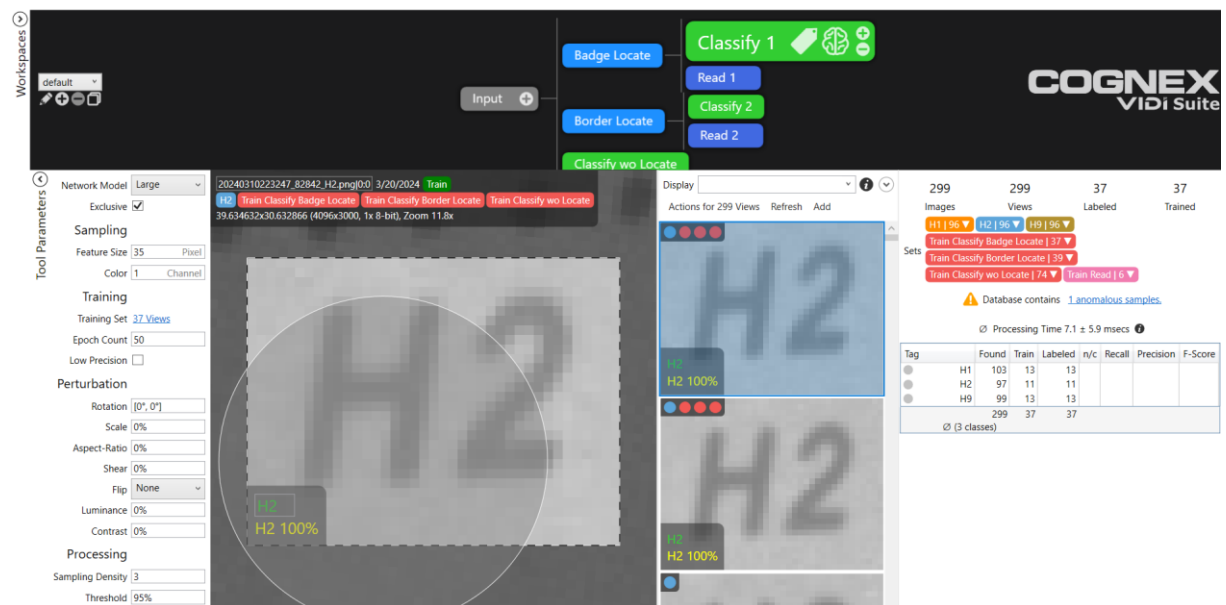
Výsledný projekt se exportuje a vkládá jako funkční blok do softwaru VisionPro, nebo Designer.

3.3.2.2 Nástroj Blue Locate

Nástroj Blue Locate, jak už název napovídá, posluhuje k lokalizaci vlastností nebo objektů. Trénink nástroje probíhá tak, že je označen pracovní ROI (Region Of Interest) a hledané vlastnosti na obrázku. Označit lze hned několik vlastností anebo také svázat uzlovým modelem v případě hledání konkrétního rozmístění (viz. **Obrázek 12**). Fotografie s vyznačenými vlastnostmi se přidávají do trénovacího setu a po tréninku se upravují parametry modelu a validují výsledky.

Výstupem nástroje Locate může být informace o nalezení konkrétní vlastnosti, nebo počet nalezených vlastností. Nástroj Locate se často používá v kombinaci s jinými nástroji, kdy navazující nástroj získává stabilní výchozí pozici a ROI může být soustředěn do menší oblasti.

3.3.2.3 Nástroj Green Classify



Obrázek 13 – Rozhraní ViDi Suite, klasifikace štítku čelního skla

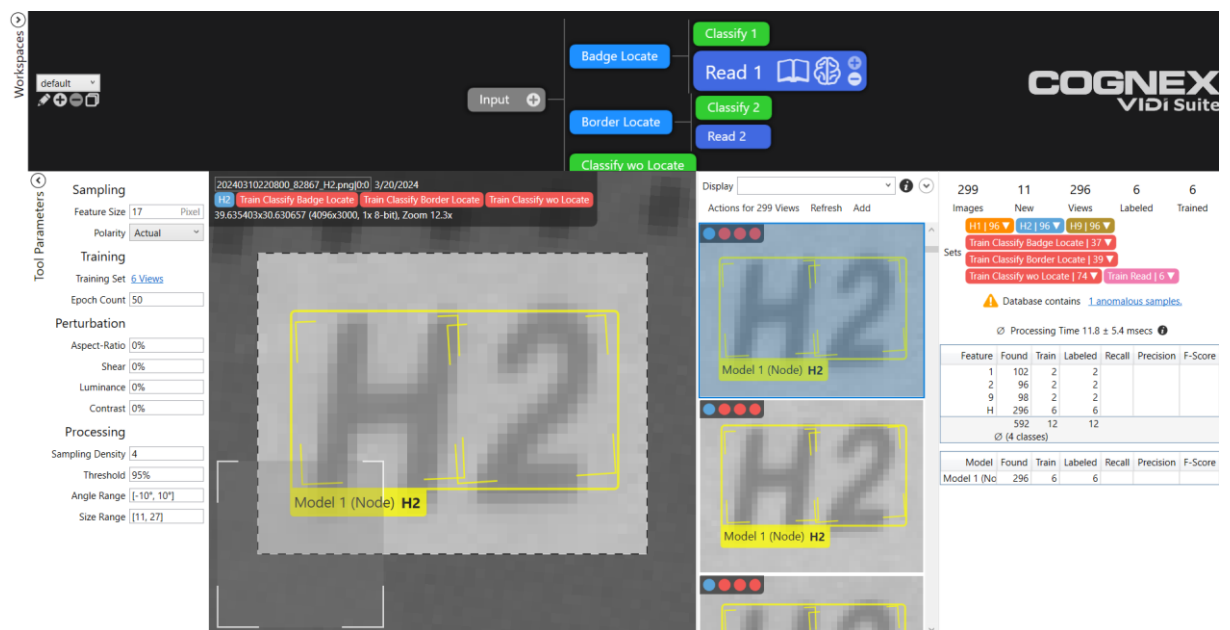
Nástroj Green Classify je využitelný ke klasifikaci určitého regionu fotografie na základě podobnosti s natrénovanými snímky. Trénink nástroje probíhá tak, že je nastaven ROI pro klasifikaci, poté jsou snímky rozříděny do tříd a vytvořen trénovací set. Od každé třídy je vhodné označit fotografie s určitou obrazovou variací. V případě nestabilní klasifikované oblasti nebo velké variace v obraze, bude pro přesnou klasifikaci trénovat aspoň desítky fotografií.

Nástroj pracuje spolehlivě, když se od sebe učené třídy významně liší a do regionu nezasahuje nechtěný shodný vzor. Výstupem nástroje je informace o nalezené třídě s její procentuální shodou.

3.3.2.4 Nástroj Blue Read

Nástroj Blue Read umožňuje čtení textu pomocí OCR a je předtrénovaný na databázi snímků s textem různého fontu a pozadí. Nástroj je schopný rozpoznávat písmena A-Z, čísla 0-9 a speciální znaky. Trénink nástroje probíhá tak, že se vybere pracovní ROI pro hledání textu. V případě použití přetrénovaného modelu stačí nastavit velikost hledaného textu. V případě trénování vlastní sady znaků, je nutné vytvořit trénovací sadu znaků. Pro spolehlivé natrénování modelu stačí jednotky trénovacích znaků.

Výstupem nástroje jsou jednotlivé znaky. V případě svázání nalezených znaků do uzlového modelu je možný výstup ve formě pevně daného textového řetězce.



Obrázek 14 – Rozhraní ViDi Suite, čtení štítku čelního skla

3.3.2.5 Nástroj Red Analyze

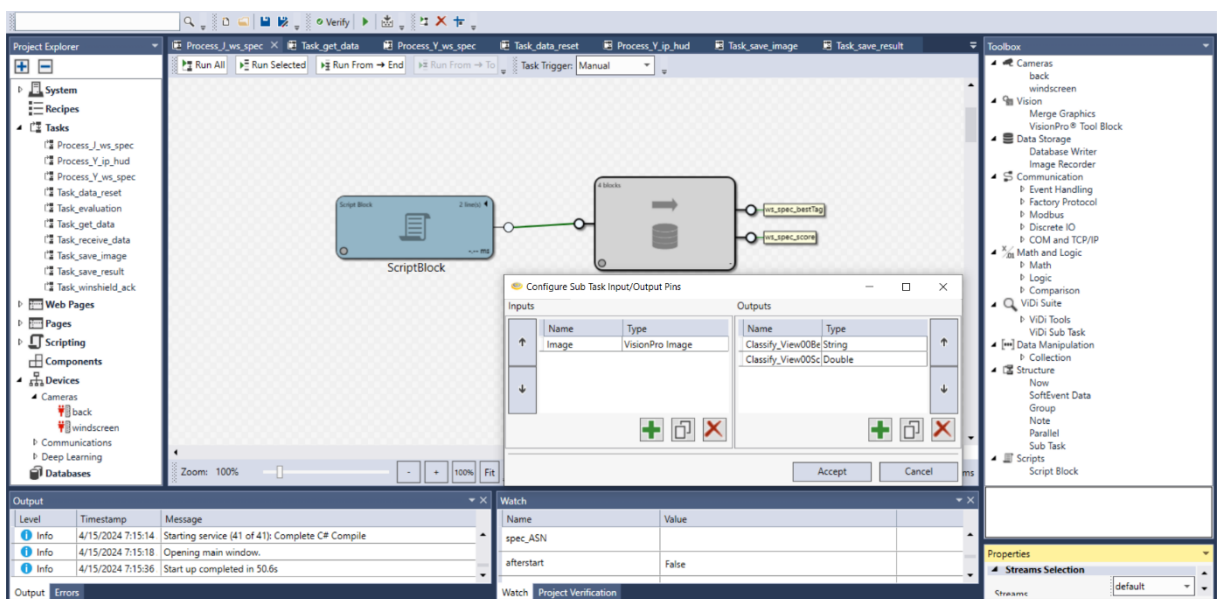
Nástroj Red Analyze je určen k detekci anomálií v obraze na základě identifikace odlišných částí fotografie. Nástroj může pracovat ve dvou režimech. V Supervised režimu jsou natrénovány fotografie bez defektů a zároveň i fotografie s defekty, což umožňuje modelu spolehlivě rozpoznat sebemenší odchylky v obraze. V režimu Unsupervised lze trénovat pouze fotografie bez defektů a spoléhat, že model bude schopný rozpoznat anomálie sám.

Trénink nástroje probíhá tak, že se vybere ROI pro rozpoznávání. U snímků se nastavuje zelená značka pro bezchybný snímek a červená pro defektní v případě Supervised režimu. V defektních snímcích se vyznačí štětcem konkrétní anomálie a po natrénování nástroj určí procentuálně bezchybné a defektní snímky.

3.3.3 Designer Software

Designer Software je kompletní vývojové prostředí pro vytváření PC kamerových aplikací. Prostředí nabízí rozsáhlé možnosti skriptování, programování, komunikace, tvorby HMI a nástrojů strojového vidění. Využít lze v jedné aplikaci několika kamer [19].

Designer ve svém prostředí využívá části nástroje VisionPro pro konfiguraci kamer, práci se snímky a je plně kompatibilní s knihovnou Vision nástrojů založených na pravidlech. V rámci pluginů může být aplikace rozšířena o knihovnu ViDi pro integraci Deep Learning modelů, nebo komunikační rozšíření průmyslových protokolů ModBus, ProfiNET, OPC UA a TwinCAT. Standartně prostředí nabízí komunikaci TCP/IP.



Obrázek 15 – Vývojové prostředí Designer

Hlavním ovládacím prvkem prostředí je nabídka *Explorer* napravo. V záložce *Devices* se konfiguruje kamera, komunikační protokoly a I/O karty. Záložka *Databases* umožňuje vytvoření SQL databáze, nebo se připojit ke vzdálené. Záložka *Scripting* slouží k vytváření skriptů v jazyce C#. Na výběr je vytvoření speciálních skriptů *OnStartup* a *OnShutdown*, které se vykonají při spuštění nebo ukončení aplikace a *Data Change Skripty*, které se spustí při změně hodnoty navázané globální proměnné. Záložka *System* obsahuje nastavení týkající se běhu programu a správce globálních proměnných *Tag Manager*. V záložce *Tasks* jsou vytvářeny základní části logiky programu *Task*. *Tasky* se editují v hlavním okně uprostřed a skládají se z funkčních bloků. Výčet funkčních bloků, které lze do *Tasku* vložit se nachází v nabídce *Toolbox* vlevo.

Pro import a použití nástrojů VisionPro slouží *VisionPro Block* a uvnitř nabízí plnohodnotné funkce nástroje. Import Deep Learning modelů probíhá pomocí *ViDi Sub Tasku* a taktéž uvnitř nabízí kompletní projekt s natrénovanými nástroji a náhled jejich vazby s možností navázat jejich výstupy na globální proměnné.

V *Tasku* je možné napsat skript v jazyce C# pomocí *Script Blocku*. *Script Block* může pracovat s lokálními i globálními proměnnými. Ke globálním proměnným se ve skriptu přistupuje pomocí uvozovacího znaménka „\$“. Funkční bloky v *Tasku* jsou spouštěny v pořadí zleva do prava a lze mezi nimi navazovat vstupy a výstupy. I/O funkčního bloku je konfigurovatelné a navázat lze i globální proměnné z *Tag Manageru*. Funkční bloky uvnitř *Tasku* lze také různě seskupovat do *Group* nebo *Sub Tasku*. *Task* má různé možnosti běhu, buď může být spuštěn manuálně zavoláním z jiného *Tasku* a *Scriptu*, nebo může běžet nepřetržitě v kontinuálním režimu. Pro ladění *Tasku* se používají tlačítka nad hlavním oknem. Při ladění je vhodný panel *Watch List* dole, do kterého je možné přidat libovolné globální proměnné a sledovat jejich hodnoty v reálném čase. Pro vizuální výstup aplikace a ovládání se v záložce *Pages a Web Pages* dají vytvořit *HMI* pro zobrazení na monitoru nebo na webu. *HMI* se dají libovolně upravovat. Finální aplikace se následně vyexportuje do *Runtime* verze a otevírá se jako samostatný program.

3.3.4 Industriální kamery Cognex

Cognex pro účely počítačové kamerové inspekce nabízí svou řadu kamer CIC. Kamery disponují komunikačním protokolem GigE Vision a k počítači se připojují pomocí ethernetového kabelu a grabovací karty. Napájení je řešeno pomocí protokolu PoE (IEEE 802.3af) po ethernetovém kabelu.



Obrázek 16 – Industriální kamera CIC 5000, detail snímače a zadních konektorů

Kamery disponují I/O piny pro externí spoušť nebo přisvětlení. V nabídce jsou modely s rozlišením od 1,3 do 31 MP, s monochromatickým i barevným snímáním a s globální nebo postupnou závěrkou [20].

Software Cognex je kompatibilní i s kamerami jiných výrobců, které využívají pro komunikaci protokol GigE, USB a Camera Link. Seznam podporovaných kamer a výrobců je spravovaný na stránkách Cognex a zahrnuje známé výrobce jako Basler, FLIR, SICK atd... [21]

3.3.4.1 Protokol GigE Vision

GigE Vision je standardní protokol pro přenos obrazových dat a ovládacích signálů přes Gigabit Ethernet (GigE) v průmyslových kamerových systémech. Tento protokol byl vyvinut a je udržován organizací AIA (Automated Imaging Association) a definován v normě GigE Vision Standard [22]. Protokol definuje komunikační architekturu pro streamování obrazových dat pomocí UDP/IP a ovládací zprávy pomocí TCP/IP, využívající standardní Ethernetové technologie a infrastrukturu. GigE Vision také poskytuje strukturu zpráv pro přesnou komunikaci mezi kamerou a hostitelským zařízením, včetně ovládacích funkcí pro konfiguraci kamer jako nastavení expozice, rozlišení, rychlosti přenosu dat a dalších parametrů. Tím umožňuje spolehlivý a efektivní přenos obrazových dat v průmyslových aplikacích.

3.3.4.2 Protokol PoE

Protokol PoE (Power over Ethernet) umožňuje přenos elektrické energie pomocí Ethernetového kabelu společně s daty. PoE se často používá pro napájení zařízení jako jsou IP kamery, bezdrátové přístupové body a další síťová zařízení, což zjednodušuje jejich instalaci a umožňuje flexibilnější umístění bez nutnosti přídavných napájecích kabelů [23].

Pasivní PoE obvykle využívá pouze dva páry vodičů v kabelu Ethernetu. Jedná se o jednodušší přístup, kde jsou napájecí proudy vloženy přímo do těchto vodičů. Protože pasivní PoE nevyžaduje aktivní řízení napájení, není potřeba využívat všechny čtyři páry vodičů.

IEEE 802.3af (PoE) využívá všech čtyř párů vodičů v kabelu Ethernetu. Z těchto čtyř párů jsou dva použity k přenosu dat a zbývající dva páry jsou k přenosu napájení. Tento standard používá metodu nazývanou "phantom power", která umožňuje vkládat napájecí proud do stávajících datových vodičů bez rušení datové komunikace. Maximální výkon na zařízení je 15,4 wattů.

IEEE 802.3at (PoE+) také využívá všech čtyř párů vodičů v kabelu Ethernetu, ale oproti IEEE 802.3af může poskytovat vyšší výkon až 30 wattů na zařízení. Tento standard umožňuje přenos dat a napájení přes všechny čtyři páry vodičů, což zlepšuje výkon a efektivitu PoE.

4 PARAMETRY PRO VÝBĚR KAMERY A OBJEKTIVU

Pro správný výběr kamery a objektivu pro kamerovou inspekci je potřeba určit základní obrazové parametry pro konkrétní aplikaci. Vhodné je dopředu zjistit, v jaké vzdálenosti bude kamera od snímaného objektu umístěna, jaké bude požadované zorné pole a velikost nejmenší rozpoznávané vlastnosti v obraze. Z těchto parametrů lze vybrat kameru s dostatečným rozlišením senzoru a vhodný objektiv dle zorného pole [24].

4.1 Rozlišení senzoru

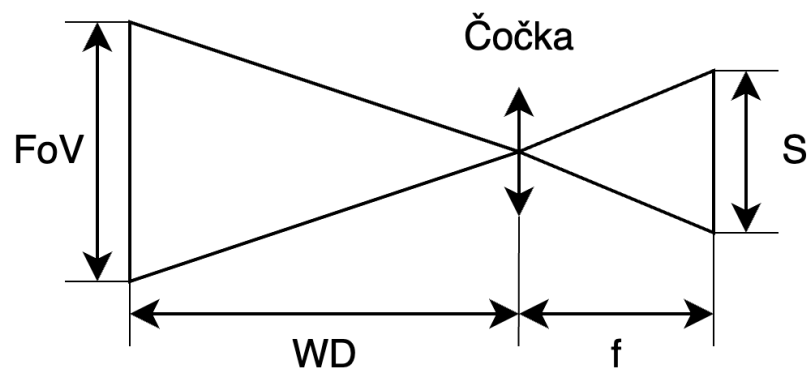
Rozlišení odpovídá počtu pixelů, který snímek obsahuje. Rozlišení se udává ve dvou rozměrech, a to počet pixelů horizontálně a vertikálně. Rozlišení lze počítat pro každý rozměr zvlášť, ale pro zjednodušení je možné využít jeden rozměr, z pravidla ten větší. Rozlišení kamery by mělo být takové, aby nejmenší rozpoznávaná vlastnost snímku byla zachycena nejméně dvěma pixely jak horizontálně, tak vertikálně. Z této skutečnosti vychází výsledná rovnice:

$$R = 2 * \left(\frac{FoV}{S} \right) \quad (4.1)$$

Výsledné rozlišení R tedy odpovídá dvojnásobku poměru mezi rozměrem FoV (Field of View, zorné pole) a rozměrem nejmenší rozpoznávané vlastnosti S . Výsledné rozlišení udává počet pixelů, z kterého lze určit požadované rozlišení senzoru kamery.

4.2 Ohnisková vzdálenost

Pro výpočet ohniskové vzdálenosti pro výběr objektivu kamery využijeme podobnost trojúhelníků. Mějme obrazovou rovinu kamery, objekt a ohniskovou vzdálenost. Označme f jako ohniskovou vzdálenost, S jako velikost senzoru a WD jako pracovní vzdálenost a FoV jako snímanou plochu.



Obrázek 17 – Princip objektivu kamery, podobnost trojúhelníků

Podobnost trojúhelníku můžeme z **Obrázek 17** vyjádřit následovně:

$$\frac{f}{WD} = \frac{S}{FoV} \quad (4.2)$$

Nyní můžeme tento vztah upravit pro získání ohniskové vzdálenosti f :

$$f = \frac{S * WD}{FoV} \quad (4.3)$$

Se znalostí ohniskové vzdálenosti a typu kamery je možné vybrat vhodný objektiv.

5 KAMEROVÁ INSPEKCE

Tato část práce bude věnována využití teoretických poznatků pro vývoj řešení kamerové inspekce specifikací čelního skla a částí přístrojového panelu vozidla. Praktická část byla zpracována v rámci stáže ve společnosti Toyota Motor Manufacturing Czech s.r.o., která sídlí v Ovčárech u Kolína [25].

V automobilovém závodu TMMCZ se v současné chvíli vyrábí dva druhy osobních automobilů, a to model Toyota Yaris a Toyota Aygo X. Jedná se o kompaktní vozy nižší třídy, které jsou ale koncepčně odlišná a provedení kontrolovaných položek se liší. Zároveň i požadavek pro kontrolu přístrojového panelu platí pouze pro model Yaris. Inspekční položky jsou v současnosti kontrolovány operátorem linky Assembly Inspection.

5.1 Výrobní prostředí

Aplikace bude umístěna na bránu určenou pro kamerovou inspekci, která se nachází před procesem Assembly Inspection (AI). Tento proces spadá pod oddělení kontroly kvality a má na starosti kontrolu interiéru a exteriéru hotových vozidel. Operátoři zde kontrolují správnost a bezchybnost dílů exteriéru, interiéru a případné defekty zapisuje do databáze vozidel pomocí terminálu. Provádí se zde také automatizované diagnostické testy vnitřních jednotek vozidla. Brána kamerové inspekce zde slouží jako nástroj pro automatizovanou inspekci vybraných částí vozidla, který má za cíl rozpoznat správnost namontovaných dílů a ulehčit tak práci operátorů linky AI a celkově tento proces urychlit a zpřesnit.

V současné chvíli se na bráně nachází jedna chytrá kamera Cognex In-Sight D900 pro inspekci částí nárazníku společně s trojicí kamer In-Sight 2800, dvě kontrolující specifikaci pneumatik a jednu pro kontrolu specifikace antény a spoileru. Pro kontrolu boků vozidla byl použit počítačový systém složený ze dvou párů 5MP kamer Cognex CAM-CIC-5000-20-GC založený na softwaru Designer a ViDi. Vrchní dvojice kamer snímá trojici snímků pro vyhodnocení specifikace světlometů a částí dveří. Druhá dvojice kontroluje specifikace disků kol a přítomnost matic na dvojici snímků. Dalším rozšířením systému bude kontrola položek interiéru skrz boční okna a položky zadních dveří a blatníku.

Kamerová brána je zhotovena z hliníkových profilů od výrobce item, konkrétně se jedná o systém D30. Brána obepíná boky a střechu vozidla, její výška činí 172 cm a vnitřní šířka 280 cm. Délka prostoru pro kamerovou kontrolu je 470 cm a vozidla se procesem pohybují po pásovém dopravníku na který jsou s pevnou roztečí vykládány z výtahu. Pro osvětlení vozidla jsou v úrovni oken a dveří na bráně z obou stran zavěšeny dvojice světelných panelů Trilux


Siella, každý se světelností 3600 lm a teplotou barvy 4000 K. Od brány vede kabelový žlab do rackové skříně, ve které je nainstalován počítač pro běh aplikace.

5.2 Specifikační štítek čelního skla

Specifikační štítek čelního skla se zpravidla nachází ve spodním pravém rohu při pohledu zvenčí vozidla. Štítek v sobě nese informaci o výrobcí a další parametry jako typ skla a jeho specifikace, homologační značku, kód vozidla, datum výroby a piktogram pro značení výbavy.

Pro identifikaci skla ve výrobním procesu se pro oba modely vozidel využívá dvojmístné označení složené z písmene a čísla. U modelu Yaris je navíc i ve formě čárového kódu. Pro spolehlivé čtení symbolů je třeba určit tloušťku fontu. Tato informace bude sloužit pro výpočet rozlišení kamery, vzhledem k tomu, že se jedná o nejmenší rozpoznávanou vlastnost inspekce.


Kamerová kontrola specifikačního štítku skla by měla přinést zjednodušení procesu kontroly zevnějšku vozidla pro operátora, pro kterého je štítek obtížně čitelný kvůli tmavému pozadí přístrojové desky, malé velikosti znaků a odrazu světla zářivkového tunelu.



Obrázek 18 – Detail štítku čelního skla pro model Aygo (vpravo), Yaris (vlevo)

5.3 Přístrojový panel

Inspekce přístrojového panelu se bude týkat pouze modelu Yaris, kde se v závislosti na stupni výbavy značně mění instalované položky. Panel je skrz čelní sklo dobře viditelný a položky, které budou v rámci jeho inspekce kontrolovány jsou head-up displej, mřížka reproduktoru a kryt kapličky přístrojů. Tyto položky jsou operátorem kontrolovány pohledem při kontrole interiéru vozidla. Kamerová inspekce by měla přispět k lepší ergonomii operátora a snížení počtu inspekčních položek kontrolovaných uvnitř vozidla.



Obrázek 19 – Detail kontrolované části přístrojové desky modelu Yaris

5.3.1 Head-up displej

Head-up v autě funguje tak, že zobrazovací jednotka generuje na displej klíčové informace, jako je rychlost a navigační pokyny, které jsou následně promítány pomocí optiky na čelní sklo před řidičem. Tímto způsobem řidič může snadno sledovat důležité údaje bez toho, aby musel odvádět pohled ze silnice.

Head-up displej se u modelu Yaris nachází ve vrchní části panelu přístrojové desky, naproti volantů ve výhledu řidiče (viz. **Obrázek 19**). Existují dvě možné specifikace, a to s head-up displejem a bez. Vzhledově jsou specifikace jednoznačně rozlišitelné, jelikož v případě nainstalovaného displeje se do vozidla instaluje přístrojový panel s patřičným výřezem. V případě specifikace bez displeje je přístrojová deska bez výřezu. Typy přístrojové desky jsou teoreticky zaměnitelné a v případě použití desky s výřezem, bez instalace head-up displeje, by byl operátor schopný defekt zaznamenat. V opačném případě by byl head-up displej zakryt deskou a operátor by mohl defekt přejít.

5.3.2 Mřížka reproduktoru

Mřížky reproduktoru se nachází párově v rozích přístrojového panelu. Pro účely této inspekce z důvodu omezení zorného pole kamery bude kontrolována pouze levá mřížka (viz. obrázek 18). Mřížka plní estetickou funkci a chrání reproduktor před mechanickým poškozením.

Instalovaný typ reproduktorové mřížky u modelu Yaris se odvíjí od stupně výbavy audio systému. Specifikace existují právě tři a v nejnižší výbavě se mřížka na přístrojovém panelu nenachází. V ostatních dvou výbavách se mřížka instaluje a je totožná. Specifikace se liší v osazení dodatečných výškových reproduktorů do „A“ sloupků, které nejsou při pohledu skrz čelní sklo patrné. Tudíž budou tyto dvě specifikace klasifikovány jako stejné.

5.3.3 Kryt sdružených přístrojů

Sdružené přístroje je označení pro panel obsahující tachometr, otáčkoměr, stav palivové nádrže, indikátory světel, stavové a výstražné kontrolky. Panel sdružených přístrojů je zpravidla uložen pod clonícím krytem, který zvyšuje čitelnost panelu na přímém slunci.

Specifikace krytu se odlišuje v závislosti na typu výbavy, kdy vyšší výbava má povrch potažený měkčenou imitací kůže (viz. **Obrázek 19**) a nižší výbava pouze hrubý plast. Rozdíly v panelu jsou čistě estetické a záměna nemá vliv na funkčnost sdružených přístrojů. Kryt je skrz čelní sklo dobře viditelný a rozdíly v provedení budou možné klasifikovat díky rozdílnému tvaru.

5.4 Výběr a montáž kamery

Z obrázku specifikačního štítku čelního skla pro model Yaris (viz. **Obrázek 18**) byla digitálně určena tloušťka fontu textu. Jedná o nejmenší rozpoznávanou vlastnost inspekce. Ke štítku bylo přiloženo kalibrované měřítko a bylo podle něj zjištěno, že 0,5 mm odpovídá 18 pixelům v obraze. Šířka fontu textu odpovídá 9 pixelům a po přepočtení tedy 0,25 mm. Snímaná plocha byla určena optimálně 500 x 500 mm. Po dosazení naměřené tloušťky fontu textu štítku čelního skla $S = 0,25$ mm a rozměru snímané plochy $H = 300$ mm do rovnice (4.1) vychází:

$$R = 2 * \left(\frac{500}{0,25} \right) = 4000 \text{ pixelů} \quad (5.1)$$

Nejbližší běžně používané rozlišení snímače odpovídá 12MP - 4112 x 3008 pixelů. Řada Cognex Industrial Camera bohužel nenabízí model s tímto rozlišením, a tak byl vybrán model kamery od výrobce Basler. Konkrétní model, který splňuje požadavky pro aplikaci, a to využití komunikačního protokolu GigE Vision, odpovídá model acA4112-8gm řady ace L. Kamera disponuje čipem Sony IMX304LLR s monochromatickým snímáním a maximální snímkovací frekvencí 9,4 fps, Napájení kamery je řešeno pomocí PoE. Kamera disponuje opticky odděleným vstupem a výstupem a univerzálním GPIO pinem a závit objektivu je typu C [26].

Pro výběr objektivu je třeba znát parametr ohniskové vzdálenosti, pro kterou byla určena rovnice 4.2 v předchozí kapitole, vycházející z principu podobnosti trojúhelníků. Vzdálenost kamery od čelního skla byla určena změřením výšky specifikačního štítku od země, což vychází

110 cm pro model Aygo a 105 cm pro Yaris. Odečtením od výšky brány 172 cm vychází pro model Yaris pracovní vzdálenost 67 cm. Použitá kamera Basler acA4112-8gm disponuje čipem o formátu 1.1" a z toho využitelných 17,6 mm diagonálně bude dosazeno za S, pracovní vzdálenost $WD = 670$ mm a výška objektu H bude dosazena jako jeden z rozměrů zorného pole 500 mm.

$$f = \frac{17,6 * 670}{500} = 23,584 \text{ mm} \quad (5.2)$$

Pro konkrétní výběr objektivu s ohniskovou vzdáleností blízkou 23,584mm byl využit nástroj přímo od výrobce kamery, a to Basler Lens Selector. Na webové stránce pouze stačí zadat konkrétní model kamery a parametr ohniskové vzdálenosti, případně si nechat přímo tento parametr vypočítat. Stránka následně vylistuje dostupné objektivy pro konkrétní model kamery splňující požadované parametry [27].

Nejbližší běžně používanou ohniskovou vzdáleností je 16 mm a nejrozzumnější volbou dle konfiguratoru vychází objektiv Basler Lens C11-1620-12M-P f16mm. Objektiv má pevnou ohniskovou vzdálenost 16 mm, nastavitelnou clonu v rozmezí hodnot F2.0 po F16 a manuálním zaostřením od vzdálenosti 0,1 m [28].

Pro montáž kamery na inspekční bránu byl použit držák složený z upevňovacího prvku s kulovým kloubem Transverse Fastener D30, který dovoluje natočení kamery do libovolného úhlu. Pro aretaci kamery k držáku je využit Adapter 8 D30. Skrz montážní otvor adaptéru je kamera uchycena šroubem M3 s podložkou, který je zašroubován do závitu ve spodní části kamery. Samotný držák byl upevněn v prostřední části vrchního rámu brány (viz. obrázek 20).



Obrázek 20 – Finalní montáž kamery Basler ace L na inspekční bránu

5.5 Nastavení obrazu kamery

Pro nalezení pozice kamery, úpravu světelných podmínek a nastavení objektivu je potřeba kameru připojit k počítači, nakonfigurovat síťové parametry a pomocí živého náhledu z kamery provádět úpravy parametrů.

Pro tento účel byl využit provizorně laptop, do kterého se kamera připojila pomocí PoE Injektoru, který ji napájel. Laptop byl umístěn na konstrukci brány, aby bylo možné sledovat výstup z kamery a nastavovat parametry. Využit byl bezplatný software od výrobce Basler, konkrétně Pylon Viewer, který je určen ke konfiguraci a náhledu obrazu kamery [29]. Na nastavení byl omezený čas jedné obědové pauzy, kdy byl dopravník nestandardně zastaven s vozidlem tak, aby se čelní sklo nacházelo přímo pod branou inspekce.

Úhel natočení kamery byl nastaven tak, aby se světelný panel v obraze odrážel dostatečnou plochou v místě specifikačního štítku čelního skla. Zároveň bylo potřeba objektiv přesně zaostřit na text štítku, aby byl co nejlépe čitelný. Objektiv byl konkrétně nastaven na světelnost F2.8, zaostření 0,5mm.

Po nalezení vhodných parametrů objektivu byla upravena délka expozice. V softwaru Pylon Viewer je po prvotním připojení kamery nastavena hodnota expozice 3ms. Při pohledu na živý obraz z kamery bylo patrné, že nebude možné všechny inspekční položky vyhodnotit z jediného snímku. Ve chvíli, kdy odraz světelného panelu podkresluje text specifikačního štítku skla, pozadí přístrojové desky s mřížkou reproduktoru zaniká. Zároveň v této pozici, která je optimální pro viditelnost štítku skla, není zcela vidět kryt přístrojů. Hodnota expozice, kdy lze číst štítek skla je taktéž pro vyhodnocení přístrojové desky nevhodná, jelikož pohled do interiéru je tmavý a zašuměný.



Obrázek 21 – Finální nastavení obrazu pro štítek čelního skla modelu Aygo a Yaris

Expozice v případě skla hraje velkou roli na viditelnost specifikačního štítku. Čím nižší expozice je nastavena, tím je odražené světlo LED panelu méně intenzivní. Při hodnotách expozice nižších než 2 ms začíná být obraz velmi tmavý a text není v odraze jednoznačně čitelný. Při hodnotách expozice vyšších než 6 ms je oblast LED panelu přesvícená a specifikační štítek nelze vidět. Po dlouhodobějším testování vychází nejlépe hodnota expozice 4 ms, kdy je text specifikačního štítku dobře čitelný a nedochází k přexponování oblasti LED panelu (viz. **Obrázek 21**). Štítek je u obou modelů dobře viditelný na shodné pozici dopravníku.



Obrázek 22 – Finální nastavení obrazu pro přístrojovou desku modelu Yaris

V případě přístrojové desky musí být hodnota expozice vyšší, aby byl pohled do interiéru jasnější. Pozice pro zachycení snímku musí být posunuta vzhledem k tomu, aby odraz LED panelu nezasahoval do vyhodnocovaných oblastí. Hodnota expozice byla testována v rozmezí od 10 ms do 20 ms. Při hodnotách vyšších 15 ms začíná být obraz lehce rozmazaný a ztrácí se detaily přístrojové desky. Jako finální hodnota byla vybrána expozice 12 ms, kdy je obraz dostatečně jasný a zároveň neztrácí ostrost (viz. **Obrázek 22**).

Po úspěšném nastavení kamery a otestování viditelnosti inspekčních položek bylo na řadě připojit kameru k pracovní stanici kamerové kontroly. Pomocí softwaru Cognex Designer nejprve vytvořit jednoduchý program pro nasbírání snímků, následně využít nástroje strojového vidění Cognex ViDi k naučení modelů pro rozpoznávání obrazu a implementovat je do finální podoby inspekční aplikace prostředí Designer.

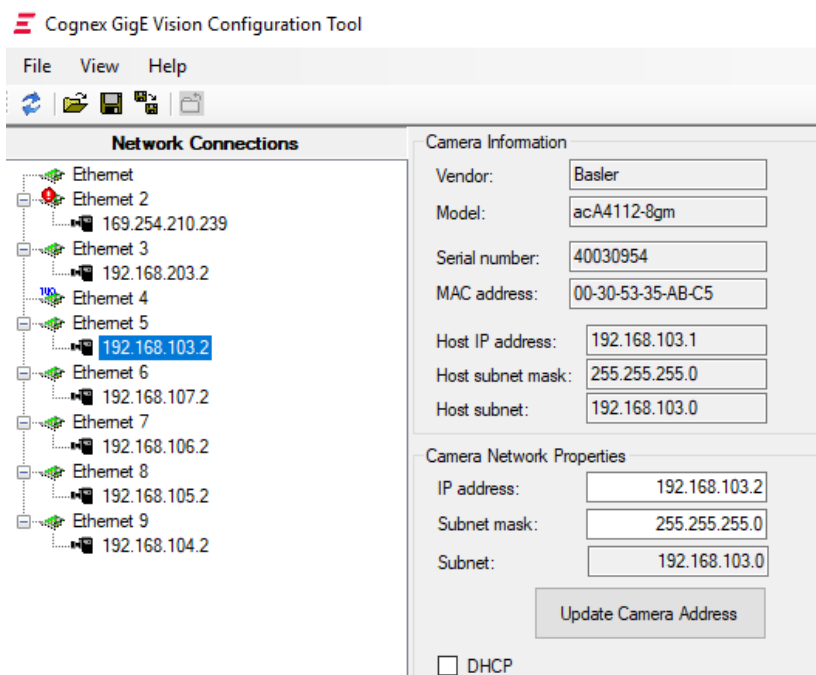
5.6 Příprava pracovní stanice

Pracovní stanice se od inspekční brány nachází zhruba ve vzdálenosti 2 m uvnitř průmyslové rackové skříně. Kabeláž je k bráně vedena kabelovým žlabem a následně pomocí stahovacích pásek vede po rámu brány k příslušné kameře. Po připočítání výšky brány 1,72 m a poloviny její šířky 1,4 m, vychází požadovaná délka kabelu 5,12m. Využit byl FTP Patch kabel se stíněním kategorie Cat.7 o délce 10 m.

K vývoji a běhu kamerové inspekce byla použita pracovní stanice značky HP, přesněji model Z4 G4. Stanice disponuje 18 jádrovým procesorem Intel Core i9 10980XE, 32 GB operační paměti RAM, 1 TB SSD diskem a grafickou kartou NVIDIA RTX A4000 s 16 GB paměti a 6144 jádry. Pro připojení kamery je do PCIe slotu připojena grabovací karta Adlink PCIe-GIE74P, která disponuje čtveřicí ethernetových portů a interním Molex konektorem pro připojení dodatečného napájení z PC zdroje, aby bylo zajištěno adekvátní PoE napájení kamer.

Na stanici byl nainstalován systém Microsoft Windows 10 Enterprise LTSC 2019 a software Cognex Designer ve verzi 4.4.3, Cognex VisionPro verze 9.20 a VisionPro ViDi verze 4.1.3. Pro vývoj a běh aplikace byly využity Cognex USB licenční klíče Training a Runtime.

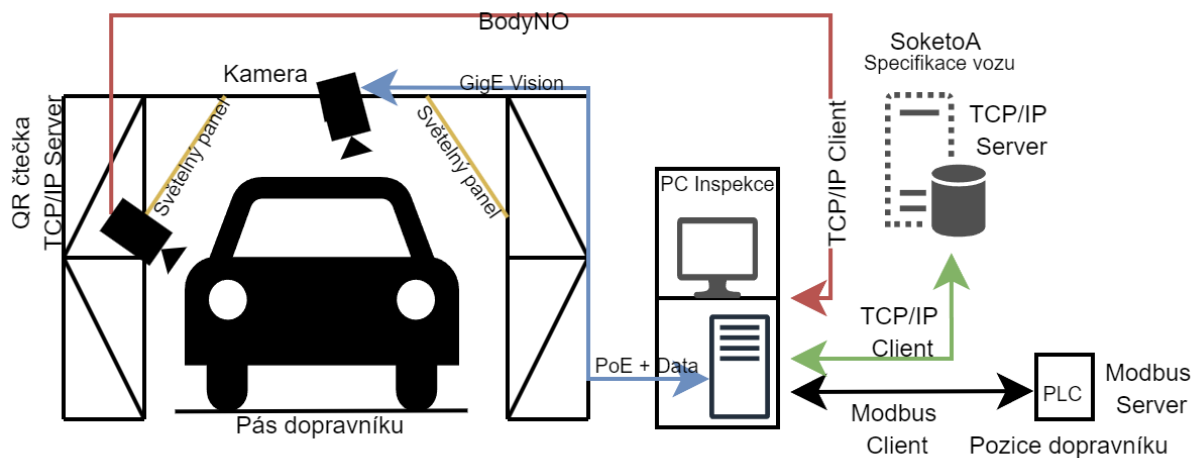
Před samotným navázáním kamery do projektu v softwaru Designer bylo nutné nastavit její připojení k ethernetovému adaptéru. K tomuto účelu je určen nástroj GigE Configurator a umožňuje nastavení správné IP adresy v rámci subnetu adaptéru (viz. **Obrázek 23**).



Obrázek 23 – Nastavení IP adresy kamery v GigE Vision Configurator

Taktéž je třeba si určit zdroj pro získání aktuální pozice vozidla na dopravníku. Vzhledem k tomu, že aplikace poběží na počítači, který nedisponuje instalovanou I/O kartou s diskretními vstupy, nebude možné využít tradičních způsobů spouště, např. optické závory. Pro účely počítačové kamerové inspekce je využito PLC Siemens LOGO, které z ovládacího systému dopravníku s enkodérem dostává informaci o aktuální poloze vozidla v rámci vyhrazeného prostoru inspekční brány. Poloha je dána počtem centimetrů z délky vozidla, která již zasahuje do prostoru brány o délce 470 cm. Tato informace je distribuována po výrobní síti pomocí protokolu Modbus, kdy PLC v roli serveru poskytuje informaci klientům, kteří se v určitém časovém intervalu dotazují.

Pro získání informací o aktuálním vozidle je využívána čtečka Cognex DataMan DM280, která načítá z QR kódu umístěného na pravém předním blatníku číselný identifikátor vozidla a jako TCP/IP server tuto informaci poskytuje na výrobní síti. Inspekční aplikace se následně musí dotázat TCP/IP serveru *SoketoA*, který poskytuje informace z databáze vozidel. Odesláním očekávané zprávy s číselným identifikátorem vozidla *BodyNo* a svým identifikátorem. Odpovědí budou specifikace kontrolovaných položek pro konkrétní vůz.

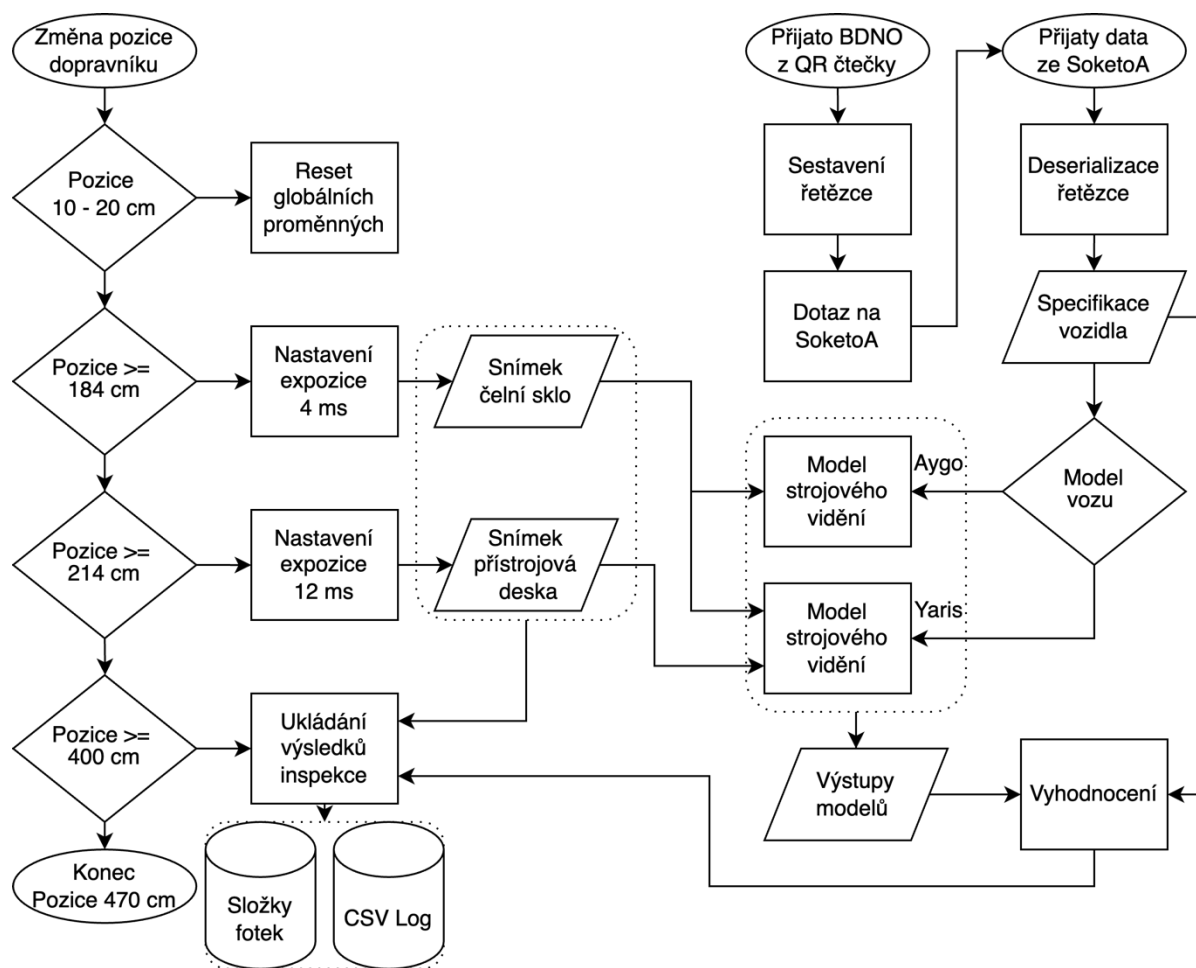


Obrázek 24 – Principiální schéma zapojení inspekční aplikace

5.7 Vývojový diagram

Zjednodušená logika je popsána vývojovým diagramem (viz. **Obrázek 25**) a kompletní projekt Cognex Designer je přílohou práce (**Příloha B**).

Programu staví na využití *Data Change Scriptu*, což je skript, který je navázaný na proměnnou nesoucí informaci o aktuální pozici dopravníku a je spuštěn při každé její změně. Uvnitř skriptu jsou definovány podmínky pro volání dílčích *Tasků*.



Obrázek 25 – Vývojový diagram inspekční aplikace

5.8 Získávání dat a sběr fotek

Prvním *Taskem* je *Data reset*. Jeho funkcí je na pozici dopravníku 10 až 20 cm provést reset veškerých globálních proměnných využívaných v rámci programu. Ve skriptu jim je přiřazena výchozí hodnota a tím jsou přepsány hodnoty z předchozí inspekce.

Zhruba na pozici 30 cm čtečka DM280 naskenuje QR kód (viz. **Obrázek 8**). Při přijetí dat z čtečky je v programu zavolán *Task Receive data*. Do globální proměnné je instancí čtečky propsán číselný identifikátor vozidla *BodyNo* a v následném skript bloku se s proměnou dále pracuje tak, že je doplněna o pevný řetězec ve formátu JSON:

```
{"RequestHeader":{"termName":"QCTOPCAM","task":"getVehicleSpecData"},"RequestData":{"bdno":"$vstup"}}
```

QC-TOPCAM je identifikátorem pro tuto inspekci a požaduje se zaslat konkrétní specifikační data vozu k číslu, které je definováno jako *vstup* uvnitř datové části. Tento řetězec požadavku je dále navázán na instanci TCP/IP serveru *SoketoA* a odesílá se.

Obratem program dostává od serveru *SoketoA* odpověď, která je spouštěčem *Tasku Get data*. Instance zařízení do globální proměnné zapíše řetězec odpovědi. Odpověď je taktéž ve formátu JSON a má následující tvar:

```
{"ResponseHeader":{"termName":"TOPCAM","task":"getVehicleSpecData"},"ResponseData":{"bdno":"68707","VehSpec":{"ASN":"622","MODEL_ID":"J","WINDSHIELD":"H9","HEADUP_DISPLAY":"X","JBL":"X"},"Status":"OK"}}
```

Pro deserializaci dat a přiřazení informací o specifikaci do patřičných proměnných je využita knihovna *JavaScriptSerializer*. Deserializací a vytvořením slovníku pro část *ResponseData* se přistoupuje k identifikátoru *BodyNo* a další část zprávy *VehSpec* musí být opětovně deserializována a ve slovníku jsou uloženy specifikační informace. Do globálních proměnných se následně specifikace přiřadí voláním slovníku s požadovaným klíčem, který vrací požadovanou hodnotu. Následující tabulka je přehledným soupisem přijatých specifikací k inspekci:

Tabulka 1 – Souhrn přijatých specifikací inspekce

Položka	Popis	Specifikace	Typ
MODEL_ID	Model vozu	J	Aygo
		Y	Yaris
Specifikace pro vyhodnocení štítu čelního skla			
WINDSHIELD	Štítek čelního skla	H1	Aygo
		H2	Aygo
		H9	Aygo
		A9	Yaris
		B0	Yaris
		F3	Yaris
		F7	Yaris
		F9	Yaris
Specifikace pro vyhodnocení přístrojové desky – Yaris			
HUD	Head-up displej	B	S
		I	Bez
JBL	Mřížka reproduktoru	C	Bez
		D	Bez
		E	S
METERCLUSTER	Kryt združ. přístrojů	B	Plast
		C	Kůže

Pro zachycení snímků je spouštěn *Task Windshield Ack*, pokud je aktuální pozice dopravníku vyšší než 184 cm pro štítek čelního skla a 214 cm pro přístrojovou desku a konkrétní snímek ještě nebyl zachycen. Tyto pozice byly experimentálně nalezeny dlouhodobým během aplikace

a uvnitř podmínek je taktéž měněna expozice kamery ze 4 na 12 ms. Instance kamery uvnitř *Tasku* vrací dvakrát snímek, který je navázán na vstup skriptu bloku a ten jej přiřadí do správné proměnné dle pořadí volání.

Pro ukládání snímků na uložení počítače je pevně na pozici 400 cm dvakrát volán *Task Save image*. Skript blok uvnitř *Tasku* v závislosti na modelu vozu a snímku přiřazuje proměnným požadované názvy snímků s aktuálním datem, časem a specifikací inspekčních položek. Blok *Image Recorder* má na vstup tyto proměnné a snímky přivedeny a ukládá do adresářů fotografie ve formátu PNG.


Po nasbírání dostatečného počtu snímků byl vybrán trénovací set fotek pro účely vytvoření nástrojů pro rozpoznávání specifikací. V této části budou popsány a porovnány modely, vytvořené v prostředí Cognex VisionPro ViDi, s různými přístupy klasifikace a jejich spolehlivost bude ověřena na rozsáhlém testovacím setu fotek. Report o tréninku modelů vyexportovaný z prostředí ViDi je přílohou práce (**Příloha A**).

5.9 Vyhodnocení štítku čelního skla

Pro vyhodnocení štítku čelního skla byly pro oba modely vozu využity tři různé přístupy volby ROI a kombinace nástrojů Blue Locate s nástrojem Green Classify nebo Blue Read. Pro každý model vozu byl vzhledem k odlišným štítkům učen samostatný model. Od každé specifikace bylo do projektu nahráno 96 snímků, což dělá 288 a 480 celkových snímků v projektu pro modely Aygo a Yaris. Počty použitých snímků pro trénování je uveden u každého modelu zvlášť. Zbylé snímky sloužily jako ověřovací při tréninku.

5.9.1 Klasifikace bez lokalizace

Pro tyto modely byl využit pouze nástroj Green Classify přes co nejmenší okolí štítku vzhledem k variaci v poloze vozu při focení obrazu.



Obrázek 26 – ROI pro klasifikaci štítku čelního skla bez lokalizace


Tabulka 2 – Parametry tréninku klasifikace štítku čelního skla bez lokalizace

Nástroj Classify		Trénováno pro model Aygo	
Parametry	Hodnota	Specifikace	Počet snímků
Velikost vlastnosti	35 pixelů	H1	48
Počet epoch	250	H2	48
Hustota vzorkování	3	H9	48
		Celkem	144
Nástroj Classify		Trénováno pro model Yaris	
Parametry	Hodnota		
Velikost vlastnosti	25 pixelů	A9	24
Počet epoch	250	B0	24
Hustota vzorkování	3	F3	24
		F7	24
		F9	24
		Celkem	120

Pro tyto modely bylo potřeba trénovat desítky fotografií a s velkou hloubkou detailu. I přes to, díky nestabilní pozici štítku v obrazu a učení nepodstatných detailů okolo, stále vykazoval nízké skóre a záměny kategorií. Pro úspěšné natrénování a přesnost blížící se následujícím modelům by bylo třeba trénovat stovky fotek od každé kategorie, což je neefektivní.

5.9.2 Lokalizace rohu čelního skla

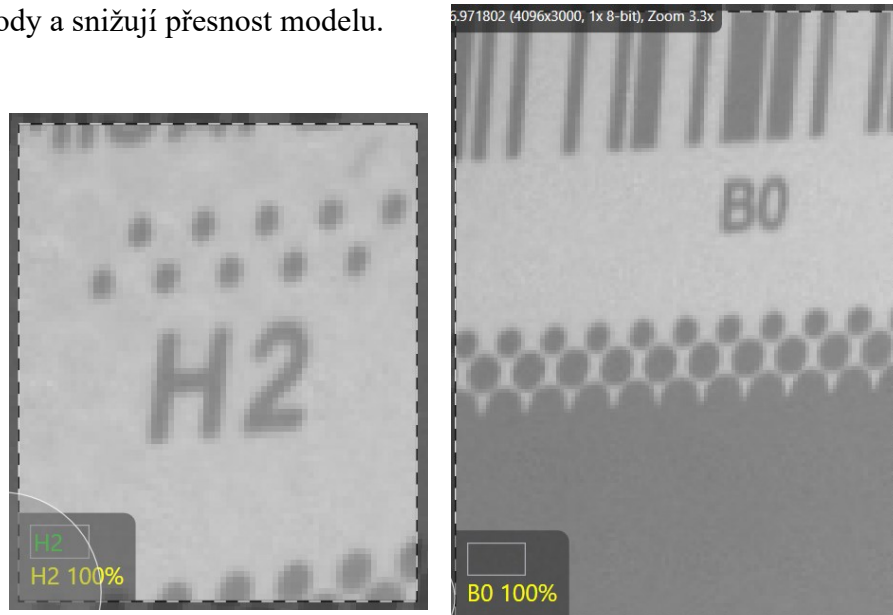
Dalším přístupem je využití nástroje Blue Locate k nalezení rohu čelního skla v menším ROI a od této pevné pozice navázat nástroj Green Classify nebo Blue Read. Díky pevnému zacílení lokalizací navázané nástroje lépe sledují pozici štítku a lze učit pouze malý výřez jeho okolí.



Obrázek 27 – Lokalizace rohu čelního skla

5.9.2.1 Klasifikace


Nástroj Green Classify byl v tomto případě trénován na podstatně menším ROI a díky tomu byly učeny jen podstatné rysy. I tak je referenční bod lokalizace poměrně vzdálený štítku a při změně perspektivy kvůli nestabilní pozici vozu se do ROI dostávají další části štítku, zaschlé kapky vody a snižují přesnost modelu.



Obrázek 28 – ROI pro klasifikaci štítku čelního skla s lokalizací v rohu skla

5.9.2.2 Čtení

Nástroj Blue Read byl trénován na shodném ROI jako Classify a trpí obdobným problémem. Ve vstupujících anomáliích do ROI nástroj kromě textu specifikace nachází další znaky. Dvojice specifikačních znaků je tedy pevně svázána do uzlového modelu s pořadím očekávaných znaků a čísel. Tímto se na výstupu modelu nemůže objevit nic jiného.



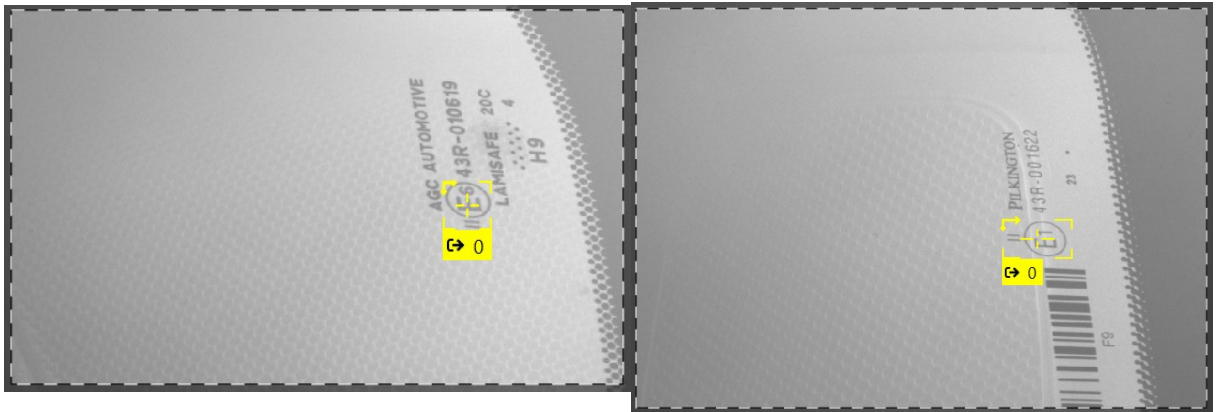
Obrázek 29 – Čtení štítku čelního skla s lokalizací v rohu skla

Tabulka 3 – Parametry tréninku nástrojů s lokalizací v rohu čelního skla

Nástroj Locate		Trénováno pro model Aygo	
Parametry	Hodnota	Specifikace	Počet snímků
Velikost vlastnosti	185x147 pixelů	-	8
Počet epoch	50		
Hustota vzorkování	2		
Nástroj Classify			
Parametry	Hodnota		
Velikost vlastnosti	35 pixelů	H1	13
Počet epoch	50	H2	13
Hustota vzorkování	3	H9	13
		Celkem	39
Nástroj Read			
Parametry	Hodnota		
Velikost vlastnosti	17 pixelů	H1	2
Počet epoch	50	H2	2
Hustota vzorkování	4	H9	2
Rozsah natočení	[-10°, 10°]	Celkem	6
Nástroj Locate		Trénováno pro model Yaris	
Parametry	Hodnota	Specifikace	Počet snímků
Velikost vlastnosti	214x170 pixelů	-	10
Počet epoch	50		
Hustota vzorkování	2		
Nástroj Classify			
Parametry	Hodnota	A9	6
Velikost vlastnosti	25 pixelů	B0	6
Počet epoch	50	F3	6
Hustota vzorkování	3	F7	7
		F9	8
		Celkem	33
Nástroj Read			
Parametry	Hodnota		
Velikost vlastnosti	15 pixelů	A9	2
Počet epoch	50	B0	2
Hustota vzorkování	4	F3	2
Rozsah natočení	[-10°, 10°]	F7	2
		F9	2
		Celkem	10

5.9.3 Lokalizace části štítku


Posledním přístupem je využití nástroje Blue Locate přímo v místě štítku pro hledání kruhové značky. ROI je podobně velké jako v předchozím případě a navázané nástroje mají díky lokalizaci, přímo v místě klasifikace, velmi přesný referenční bod.



Obrázek 30 – Lokalizace části štítku

5.9.3.1 Klasifikace


Nástroj Green Classify byl v tomto případě trénován na ROI o přesném výřezu okolo specifikačních znaků. Pozice byla velmi stabilní díky blízkému referenčnímu bodu a stačilo trénovat jednotky snímků od každé kategorie.



Obrázek 31 – ROI pro klasifikaci štítku čelního skla s lokalizací části štítku

5.9.3.2 Čtení

Nástroj Blue Locate byl využit se stejným ROI jako nástroj Classify. Díky stabilní pozici a přesnému ořezu okolo čtených znaků podával model ihned téměř stoprocentní výsledky. Znaky jsou taktéž svázaný do uzlového modelu, ale model v tomto případě znaky v okolí nenajde.



Obrázek 32 – Čtení štítku čelního skla s lokalizací části štítku

Tabulka 4 – Parametry tréninku nástrojů s lokalizací části štítku


Nástroj Locate		Trénováno pro model Aygo	
Parametry	Hodnota	Specifikace	Počet snímků
Velikost vlastnosti	55,5x55,2 pixelů	-	6
Počet epoch	50		
Hustota vzorkování	2		
Nástroj Classify			
Parametry	Hodnota		
Velikost vlastnosti	35 pixelů	H1	13
Počet epoch	50	H2	11
Hustota vzorkování	3	H9	13
		Celkem	37
Nástroj Read			
Parametry	Hodnota		
Velikost vlastnosti	17 pixelů	H1	2
Počet epoch	50	H2	2
Hustota vzorkování	4	H9	2
Rozsah natočení	[-10°, 10°]	Celkem	6
Nástroj Locate		Trénováno pro model Yaris	
Parametry	Hodnota	Specifikace	Počet snímků
Velikost vlastnosti	84,3x47,6 pixelů	-	10
Počet epoch	50		
Hustota vzorkování	2		
Nástroj Classify			
Parametry	Hodnota	A9	6
Velikost vlastnosti	25 pixelů	B0	6
Počet epoch	50	F3	6
Hustota vzorkování	3	F7	8
		F9	8
		Celkem	34
Nástroj Read			
Parametry	Hodnota		
Velikost vlastnosti	17 pixelů	A9	2
Počet epoch	50	B0	2
Hustota vzorkování	4	F3	2
Rozsah natočení	[-10°, 10°]	F7	2
		F9	2
		Celkem	10

5.10 Vyhodnocení částí přístrojové desky

Přístrojová deska bude kontrolována pouze pro model Yaris. K vytvoření modelu bude použita kombinace nástroje Blue Locate pro určení referenčního bodu a následně navázané nástroje Green Classify ke klasifikaci přítomných specifikací.

5.10.1 Lokalizace


Jako pevný referenční bod této inspekce byla zvolena vlastnost zhruba uprostřed obrazu, konkrétně spára mezi plastovými díly přístrojové desky. ROI pro hledání bylo nastaveno vzhledem k nestabilní pozici vozidla poměrně velké. Kvůli odrazu zhaslé zářivky na čelním skle v místě spáry bylo nutné trénovat větší množstvím snímků s variací pozice.



Obrázek 33 – Lokalizace referenčního bodu přístrojové desky

5.10.2 Klasifikace head-up displeje


Pro klasifikaci specifikace head-up displeje je ROI nástroje Green Classify nastaven zhruba přes polovinu výřezu v přístrojové desce, a především je zaměřen na tvar okraje. V obraze se poměrně silně odráží přes čelní sklo část konstrukce nad linkou a odraz rozsvícené zářivky. Tyto vlivy se v rozpoznávání povedlo eliminovat učením snímků s variací pozice tohoto odrazu.



Obrázek 34 – ROI pro klasifikaci head-up displeje

5.10.3 Klasifikace mřížky reproduktoru


V případě mřížky reproduktoru bylo ROI zaměřeno na celou její šířku. Rozdíl mezi vzorem mřížky a plochou bez ní je zcela jednoznačně rozeznatelný. Jediným nežádoucím vlivem byl intenzivní odraz zářivky v čelním skle, jehož dopad na přesnost se podařilo odstranit naučením snímků s odrazem v rozdílných pozicích.



Obrázek 35 – ROI pro klasifikaci mřížky reproduktoru

5.10.4 Klasifikace krytu sdružených přístrojů

Kryt sdružených přístrojů se ve specifikacích odlišuje použitým materiálem. Tento detail však v obraze není zcela patrný a daleko lépe odlišitelnou vlastností je rozdíl ve tvaru krytu. Nástroj Green Classify je zde použit s ROI, který je zaměřen na část rohu krytu a vzhledem k odrazu konstrukce nad linkou bylo nutné učít snímky s variací polohy, aby došlo k zpřesnění výsledků.



Obrázek 36 – ROI pro klasifikaci krytu sdružených přístrojů

Tabulka 5 – Parametry tréninku nástrojů pro klasifikaci částí přístrojové desky

Nástroj Locate		Trénováno pro model Yaris	
Parametry	Hodnota	Specifikace	Počet snímků
Velikost vlastnosti	143x113 pixelů	-	20
Počet epoch	50		
Hustota vzorkování	2		
Nástroj Classify - Head-up disp.			
Parametry	Hodnota	B	4
Velikost vlastnosti	60 pixelů	I	4
Počet epoch	50	Celkem	8
Hustota vzorkování	3		
Nástroj Classify - Mřížka repro.			
Parametry	Hodnota	C/D	4
Velikost vlastnosti	60 pixelů	E	4
Počet epoch	50	Celkem	8
Hustota vzorkování	3		
Nástroj Classify - Kryt přístrojů			
Parametry	Hodnota	B	4
Velikost vlastnosti	300 pixelů	C	4
Počet epoch	100	Celkem	8
Hustota vzorkování	3		

5.11 Přesnost modelů

Pro finální určení nejpřesnějších modelů, které byly použity pro finální aplikaci se během období zhruba dvou měsíců sbíraly snímky. Využita byla základní část programu popsána v kapitole 5.8. Model Yaris se v tomto období vyráběl ve vyšším poměru než model Aygo. Finální počet snímků v testovacím setu pro model Yaris činí 14199 a 9357 pro model Aygo. Z testovacích setů byly vyfiltrovány fotografie použité pro trénink nástrojů.

Jednotlivé modely byly z nástroje ViDi vyexportovány a v prostředí Designer vytvořen jednoduchý program pro jejich otestování, který je součástí přílohy. Fotografie byly rozděleny do dvou složek pro snímky čelního skla modelu Yaris, Aygo a jedné složky pro snímky přístrojové desky pro model Yaris. Tyto složky byly přidány do projektu Designer jako zařízení typu kamera. Program obsahuje trojici *Tasku*, do kterých byly nahrány všechny modely pro konkrétní inspekce a přidány byly instance složek pro vstup snímků do nástrojů. Výsledky všech modelů jsou v každém *Tasku* pomocí skript bloku spojeny do formy řetězce odděleného čárkami a zapisovány pomocí systémové knihovny *StreamWriter* do trojice souborů typu CSV.

Každý záznam výsledků zpracovaná fotky je zapsán na nový řádek. *Tasky* jsou volány jednoduchým skriptem pomocí tří for cyklů, které *Task* spustí pro každou fotku ve složce.

Soubory CSV s výsledky úspěšnosti nástrojů pro jednotlivé fotografie jsou přílohou práce (**Příloha E**) a byla z nich vytvořena souhrnná tabulka s celkovou přesností každého modelu.

Tabulka 6 – Výsledky přesnosti modelů na testovacím datasetu

Inspekce štítku čelního skla					
Model	Klasifikace bez lokalizace	Lokalizace rohu čelního skla		Lokalizace části štítku	
		Klasifikace	Čtení	Klasifikace	Čtení
Aygo	80,517 %	97,895 %	99,605 %	99,989 %	100,000 %
Yaris	96,638 %	99,965 %	99,922 %	100,000 %	100,000 %

Inspekce částí přístrojové desky			
Model	Klasifikace head-up displeje	Klasifikace mřížky reproduktoru	Klasifikace krytu přístrojů
Yaris	99,993 %	99,993 %	99,979 %

Pro inspekci štítku čelního skla byly vybrány model s lokalizací části štítku a klasifikačním nástrojem. Model s nástrojem pro čtení sice vykazoval u modelu Aygo vyšší přesnost, ale pro finální inspekci je spíše nevhodný, protože nástroj Blue Read přečte i poškozený štítek, zatímco Green Classify obraz vyhodnotí s nízkým skóre a tím pádem správně jako defekt. Modely použité ve finální aplikaci jsou zvýrazněny žlutou barvou v **Tabulka 6**.

5.12 Vyhodnocení a zápis výsledku

Vybrané modely ViDi byly nahrány do trojice samostatných *Tasků Process* a na jejich vstupy jsou přivedeny zachycené snímky kamery. Dvojice *Tasků* s názvem *Process WS spec* obsahují samostatné zpracování snímků čelního skla pro oba modely vozu. *Task Process IP* zpracovává snímky přístrojové desky. Výsledky vyhodnocení modelu jsou navázány do globálních proměnných a obsahují název klasifikační kategorie a procentuální shodu. Název klasifikační kategorie v tomto případě model vrací pouze při procentuální shodě vyšší než 95 %. *Process tasky* jsou volány z *Tasku Evaluate*, který běží kontinuálně celou dobu a skript blok uvnitř něj spouští zpracování snímků, pokud ještě neproběhlo. Dále ve skript bloku probíhá finální vyhodnocení v rámci podmínek, porovnáním přijaté specifikace s výstupem modelů ViDi. V případě inspekce mřížky reproduktoru bylo třeba ošetřit případ, kdy model vrací pouze informaci o nepřítomnosti mřížky, ale existují dvě specifikace bez mřížky.

Záznam výsledků obstarává *Task Save Result*, ve kterém jsou výsledky kontroly a informace o přijaté specifikaci zapsány do CSV souboru na lokálním disku. Pro každé zkontrolované vozidlo je vytvořen řetězec, který nese identifikátor vozidla *BodyNo*, datum a čas inspekce, přijatá a nalezená specifikace, procentuální shoda a logická hodnota výsledku inspekce. Pro zápis je použita systémová knihovna *StreamWriter*, která řetězce vkládá na nové řádky. Zápis dat probíhá při pozici dopravníku 400 cm společně s ukládáním fotografií. Zápisy jsou z CSV souboru pomocí sdílené složky Windows čteny externí serverovou aplikací, která výsledky inspekce zapíše do databáze vozidel obdobně, jako operátor linky z terminálu. *Task Save image* je také ve skript bloku doplněn o výsledek inspekce, který je zapisován jako logická hodnota na prvním znaku názvu fotografie pro snadné filtrování.

5.13 HMI vizualizace

Pro vizualizaci běhu aplikace bylo vytvořeno jednoduché rozhraní HMI, které obsahuje základní informace o procesu inspekce. V horní části obrazu se nachází náhledy focených snímků s rámečky, které se zbarvují do zelené barvy v případě úspěšné inspekce a do červené v případě defektu. Pod snímky se nachází popisky kontrolovaných položek, které se taktéž zbarvují podle jejich výsledku. V dolní polovině vlevo rozhraní jsou uvedeny základní informace o kontrolovaném vozidle a pomocí posuvníku se zobrazuje aktuální pozice dopravníku. V pravé části jsou informace o aktuálním stavu inspekce.



Obrázek 37 – Vizualizace aplikace pomocí HMI, video (Příloha F)

5.14 Spolehlivost finální aplikace

Běh finální verze aplikace byl testován necelých pět dní a inspekci bylo zkontrolováno 4269 vozidel z toho 2415 model Yaris a 1855 model Aygo. Z nasbíraných dat ve formě CSV logu byla vytvořena souhrnná tabulka o přesnosti kontroly jednotlivých inspekčních položek.

Tabulka 7 – Výsledky přesnosti běhu finální aplikace

Model	Štítek čelního skla	Head-up displej	Mřížka reproduktoru	Kryt přístrojů	Celková inspekce
Aygo	99,784 %	-	-	-	99,784 %
Yaris	100 %	99,953 %	99,953 %	99,953 %	99,917 %
Celkem	99,906 %	99,953 %	99,953 %	99,953 %	99,859 %

Z výsledků testovacího běhu inspekce vychází, že aplikace je schopná běhu ve výrobním prostředí s dostatečnou přesností. Pro celkovou inspekci štítku čelního skla a přístrojového panelu vychází necelá dvě defektní vozidla, která budou muset být manuálně zkontrolována za předpokladu, že je průměrně za den vyrobeno tisíc vozů. Shodná procentuální přesnost inspekce položek přístrojového panelu u modelu Yaris vychází ze selhání lokalizačního nástroje, na který jsou navázány klasifikační nástroje pro jednotlivé položky. Pro eliminování tohoto jevu bude zapotřebí dotrénovat tento lokalizační nástroj na defektních snímcích a eliminovat tak jeho vliv na jinak spolehlivé klasifikační nástroje.

Potencionálním vylepšením finální aplikace by mohlo být rozšíření HMI o ovládací prvky inspekce, aby byl operátor schopný její části vypínat nebo zvolit jaké fotky se mají z inspekce ukládat a šetřit tak místo na disku. Také by bylo dobré například po straně zobrazovat poslední defekty v podobě fotek a informací o vozidle. Dále by bylo vhodné zjednodušit zápis výsledků do databáze vozidel a tuto část přímo zakomponovat do programu aplikace jako nové TCP/IP spojení a odesílat výsledky inspekce obdobně jako terminál, který používají operátoři linky.

ZÁVĚR

V rámci teoretické části práce bylo představeno využití kamerových systémů v průmyslu. Systémy byly rozděleny podle způsobu využití a dále bylo popsáno typy kamerové kontroly pro účely zajištění kvality. Pro automatické kamerové kontroly byl vysvětlen základní princip počítačového vidění a využití strojového učení s metodami hlubokého učení. Popsán byl základní princip konvolučních neuronových sítí a postup pro učení modelu pro potřeby rozpoznávání fotografií. Následně byly definovány prostředky strojového vidění, jejich rozdělení a možnosti jejich použití. Jako příklad byly uvedeny kamerové systémy Cognex a jejich podrobná rešerše. Nakonec teoretické části byly nalezeny patřičné parametry pro výběr vhodné kamery k účelům inspekce.

Praktická část práce byla zaměřena na uplatnění teoretických poznatků v prostředí automobilového závodu TMMCZ. Určeny byly základní požadavky pro kamerovou inspekci specifikačního štítku čelního skla, dílů přístrojového panelu a proběhlo seznámení s prostředím brány kamerové inspekce a přilehlého procesu Assembly Inspection. Po vydefinování konkrétních položek inspekce byl popsán proces výběru a instalace kamery společně s obslužným hardwarem a softwarem.

Finální část práce je zaměřena na vývoj samotné aplikace v prostředí Cognex Designer pro kamerovou inspekci. Popsány byly části logiky hlavního programu pro příjem dat a zachycení snímků k inspekci. Dále bylo vytvořeno několik modelů strojového učení s různými přístupy a nástroji vývojového prostředí Cognex ViDi. Pomocí testovacího setu fotografií byla ověřena spolehlivost jednotlivých modelů a vybrán ten nejvhodnější. Následně bylo navázáno popisem logiky pro vyhodnocení a zápis výsledků inspekce. Pro vizualizaci inspekce bylo vytvořeno HMI a závěrem byla funkčnost kompletní aplikace ověřena testovacím během.

POUŽITÁ LITERATURA

- [1] *Kamerový systém*. Online. In: Wikipedia: the free encyclopedia. San Francisco (CA): Wikimedia Foundation, 2001-. Dostupné z: https://cs.wikipedia.org/wiki/Kamerov%C3%BD_syst%C3%A9m. [cit. 2024-04-01].
- [2] KORIČANSKÁ, Marie a SÝKORA, Vít. *Kamerový záznam jako důkaz*. Online. In: Ekonom.cz. Dostupné z: <https://pravniciradce.ekonom.cz/c1-66969850-kamerovy-zaznam-jako-dukaz>. [cit. 2024-04-02].
- [3] GUEDRI, Naji a GHARBI, Rached. Bulk material flow measurement based only on a smart camera fixed above a moving belt conveyor. Online. *Multimedia Tools and Applications*. 2023, roč. 82, č. 9, s. 14077-14090. ISSN 1380-7501. Dostupné z: <https://doi.org/10.1007/s11042-022-13893-x>. [cit. 2024-04-02].
- [4] COGNEX CORPORATION. *Automated Sorting*. Online. Cognex.com. 2024. Dostupné z: <https://www.cognex.com/industries/consumer-products/distribution/automated-sorting>. [cit. 2024-04-02].
- [5] KAVIRAJU, R D a NIBEDITA. *Automated visual quality inspection using AI/ML in manufacturing industries that reduces scrap/rework costs*. Online. In: KR Architecture World. 2024. Dostupné z: <https://industry40.co.in/automated-visual-quality-inspection-using-ai-ml-in-manufacturing/>. [cit. 2024-04-28].
- [6] *Počítačové vidění*. Online. In: Wikipedia: the free encyclopedia. San Francisco (CA): Wikimedia Foundation, 2001-. Dostupné z: https://cs.wikipedia.org/wiki/Po%C4%8D%C3%ADta%C4%8Dov%C3%A9_vid%C4%9Bn%C3%AD. [cit. 2024-04-28].
- [7] *Umělá neuronová síť*. Online. In: Wikipedia: the free encyclopedia. San Francisco (CA): Wikimedia Foundation, 2001-. Dostupné z: https://cs.wikipedia.org/wiki/Um%C4%9Bl%C3%A1_neuronov%C3%A1_s%C3%AD%C5%A5. [cit. 2024-04-28].
- [8] NORDIN, Md Jan; XIN, Ooi Wei a AZIZ, Norshakirah. Food Image Recognition for Price Calculation using Convolutional Neural Network. Online. *Proceedings of the 2019 3rd International Conference on Digital Signal Processing*. 2019, s. 80-85. ISBN 9781450362047. Dostupné z: <https://doi.org/10.1145/3316551.3316557>. [cit. 2024-04-28].
- [9] VYŠKOVSKÝ, Roman. *Klasifikace dat pomocí konvoluční neuronové sítě*. Online. In: Informační systém Masarykovy univerzity. 2019. Dostupné z: https://is.muni.cz/el/sci/podzim2019/Bi0034/um/neuronove_site/KNS.pdf. [cit. 2024-04-28].

- [10] TYAGI, Piyush. *Work Flow in Machine Learning Project*. Online. In: Medium. 2018. Dostupné z: <https://medium.com/@pytyagi/work-flow-in-machine-learning-project-327eddb946b4>. [cit. 2024-04-28].
- [11] *Smart camera*. Online. In: Wikipedia: the free encyclopedia. San Francisco (CA): Wikimedia Foundation, 2001-. Dostupné z: https://en.wikipedia.org/wiki/Smart_camera. [cit. 2024-04-28].
- [12] Strojové vidění I: Principy a charakteristiky. Online. *Automa*. 2008, roč. 14, č. 1, s. 42-45. ISSN 1210-9592. Dostupné z: https://www.automa.cz/cz/casopis-clanky/strojove-videni-i-principy-a-charakteristiky-2008_01_36550_5518/. [cit. 2024-04-28].
- [13] COGNEX CORPORATION. *Company Overview*. Online. Cognex.com. 2024. Dostupné z: <https://www.cognex.com/en/company>. [cit. 2024-04-28].
- [14] COGNEX CORPORATION. *DataMan 280 Series*. Online. Cognex.com. 2024. Dostupné z: <https://www.cognex.com/products/barcode-readers/fixed-mount-barcode-readers/dataman-280-series>. [cit. 2024-04-28].
- [15] COGNEX CORPORATION. *In-Sight 2800 Vision System*. Online. Cognex.com. 2024. Dostupné z: <https://www.cognex.com/products/machine-vision/2d-machine-vision-systems/in-sight-2800>. [cit. 2024-04-28].
- [16] COGNEX CORPORATION. *In-Sight D900 Vision System*. Online. Cognex.com. 2024. Dostupné z: <https://www.cognex.com/products/machine-vision/2d-machine-vision-systems/in-sight-d900>. [cit. 2024-04-28].
- [17] COGNEX CORPORATION. *VisionPro Software*. Online. Cognex.com. 2024. Dostupné z: <https://www.cognex.com/en/products/machine-vision/vision-software/visionpro-software>. [cit. 2024-04-28].
- [18] COGNEX CORPORATION. *VisionPro Deep Learning*. Online. Cognex.com. 2024. Dostupné z: <https://www.cognex.com/products/machine-vision/vision-software/visionpro-deep-learning>. [cit. 2024-04-28].
- [19] COGNEX CORPORATION. *Cognex Designer Software*. Online. Cognex.com. 2024. Dostupné z: <https://www.cognex.com/products/machine-vision/vision-software/cognex-designer-software>. [cit. 2024-04-28].
- [20] COGNEX CORPORATION. *Cognex Industrial Cameras (CIC)*. Online. Cognex.com. 2024. Dostupné z: <https://www.cognex.com/products/machine-vision/vision-software/vision-accessories/cameras/cic-cameras>. [cit. 2024-04-28].
- [21] COGNEX CORPORATION. *Cognex Vision Software Supported Cameras*. Online. Cognex.com. 2024. Dostupné z: <https://www.cognex.com/products/machine-vision/vision-software/vision-accessories/cameras/other-cameras>. [cit. 2024-04-28].

- [22] *GigE Vision*. Online. In: Wikipedia: the free encyclopedia. San Francisco (CA): Wikimedia Foundation, 2001-. Dostupné z: https://en.wikipedia.org/wiki/GigE_Vision. [cit. 2024-04-28].
- [23] *PoE*. Online. In: Wikipedia: the free encyclopedia. San Francisco (CA): Wikimedia Foundation, 2001-. Dostupné z: https://cs.wikipedia.org/wiki/Power_over_Ethernet. [cit. 2024-04-28].
- [24] NATIONAL INSTRUMENTS CORP. *Calculating Camera Sensor Resolution and Lens Focal Length*. Online. Ni.com. 2020. Dostupné z: <https://www.ni.com/en/support/documentation/supplemental/18/calculating-camera-sensor-resolution-and-lens-focal-length.html>. [cit. 2024-04-28].
- [25] *Toyota Kolin*. Online. TMM CZ. 2024. Dostupné z: <https://www.toyotacz.com/onas/toyota-kolin/>. [cit. 2024-04-28].
- [26] BASLER AG. *AcA4112-8gm*. Online. Basler Product Documentation. 2024. Dostupné z: <https://docs.baslerweb.com/aca4112-8gm#>. [cit. 2024-04-28].
- [27] BASLER AG. *Lens Selector*. Online. Baslerweb.com. 2024. Dostupné z: <https://www.baslerweb.com/en/tools/lens-selector/>. [cit. 2024-04-28].
- [28] BASLER AG. *Basler Lens C11-1620-12M-P*. Online. Basler Product Documentation. 2024. Dostupné z: <https://docs.baslerweb.com/c11-1620-12m-p>. [cit. 2024-04-28].
- [29] BASLER AG. *Pylon Viewer*. Online. Baslerweb.com. 2024. Dostupné z: <https://www.baslerweb.com/en/software/pylon/pylon-viewer/>. [cit. 2024-04-28].

SEZNAM PŘÍLOH

Příloha A: Report tréninku modelů nástroje Cognex ViDi Suite

Příloha B: Projekt Cognex Designer pro hlavní program

Příloha C: Snímky obrazovky prostředí Cognex Designer

Příloha D: Obsah skript bloků v textovém souboru a seznam globálních proměnných

Příloha E: CSV výstupy logu pro ověření spolehlivosti modelů a testovací běh finální aplikace

Příloha F: Video zobrazující běh HMI