



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

## ÚSTAV AUTOMATIZACE A INFORMATIKY

INSTITUTE OF AUTOMATION AND COMPUTER SCIENCE

# VIZUÁLNÍ INSPEKCE POVRCHOVÉ ÚPRAVY S VYUŽITÍM STROJOVÉHO VIDĚNÍ

VISUAL INSPECTION OF SURFACE TREATMENT USING MACHINE VISION

## BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

## AUTOR PRÁCE

AUTHOR

Matsvei Tsarykau

## VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. Pavel Škrabánek, Ph.D.

BRNO 2024



# Zadání bakalářské práce

Ústav: Ústav automatizace a informatiky  
Student: **Matsvei Tsarykau**  
Studijní program: Strojírenství  
Studijní obor: Aplikovaná informatika a řízení  
Vedoucí práce: **doc. Ing. Pavel Škrabánek, Ph.D.**  
Akademický rok: 2023/24

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách a se Studijním a zkušebním řádem VUT v Brně určuje následující téma bakalářské práce:

## Vizuální inspekce povrchové úpravy s využitím strojového vidění

### Stručná charakteristika problematiky úkolu:

Vizuální inspekce povrchové úpravy je typickým problémem, který lze s využitím strojového vidění plně automatizovat. Volbou vhodné přístrojové techniky a jejím vhodným rozmístěním lze zajistit vysokou přesnost a robustnost takto vytvořeného systému strojového vidění. Oba tyto faktory také do značné míry ovlivňují časovou náročnost zpracování obrazových dat.

### Cíle bakalářské práce:

Student analyzuje zadaný problém. Na základě této analýzy navrhne, implementuje a otestuje systém strojového vidění. Součástí návrhu tohoto systému bude výběr vhodné přístrojové techniky, návrh jejího rozmístění vůči snímanému objektu, a návrh algoritmu pro zpracování obrazových dat zachycených tímto systémem. Součástí testu takto vytvořeného systému bude i hodnocení kvality klasifikace testovaných objektů.

### Seznam doporučené literatury:

GONZALEZ, Rafael C. a Richard E. WOODS. Digital image processing. Fourth edition. New York: Pearson, [2018]. ISBN 978-0133356724.

BATCHELOR, Bruce G. Machine vision handbook: with 1295 figures and 117 tables [online]. 1. London: Springer, [2012] [cit. 2019-02-19]. ISBN 978-1-84996-169-1. Dostupné z: <https://link.springer.com/referencework/10.1007%2F978-1-84996-169-1>

Termín odevzdání bakalářské práce je stanoven časovým plánem akademického roku 2023/24

V Brně, dne

L. S.

---

ředitel ústavu

---

doc. Ing. Jiří Hlinka, Ph.D.  
děkan fakulty

## **ABSTRAKT**

Automatizovaná vizuální inspekce povrchových úprav představuje základní výzvu, která je řešitelná integrací systémů strojového vidění. Tato práce si klade za cíl analyzovat, navrhnout, implementovat a otestovat takový systém. Navržený systém zahrnuje výběr vhodného hardwaru, návrh jeho umístění vzhledem k cílovému objektu a formulaci algoritmu pro zpracování obrazových dat, která jsou systémem zachycena. Kromě toho tvoří nedílnou součást testovací fáze hodnocení kvality klasifikace objektů.

## **ABSTRACT**

Automated visual inspection of surface finishes is a fundamental challenge that can be solved by integrating machine vision systems. This work aims to analyze, design, implement and test such a system. The proposed system includes the selection of suitable hardware, the design of its placement relative to the target object, and the formulation of an algorithm for processing the image data captured by the system. In addition, it forms an integral part of the testing phase to evaluate the quality of object classification.

## **KLÍČOVÁ SLOVA**

Vizuální inspekce, Výběr hardwaru, Cognex, Strojové vidění, Algoritmy zpracování obrazových dat, Klasifikace.

## **KEYWORDS**

Visual inspection, Hardware selection, Cognex, Machine vision, Image processing algorithms, Classification.





ÚSTAV AUTOMATIZACE  
A INFORMATIKY



2024

## BIBLIOGRAFICKÁ CITACE

MATSVEI, Tsarykau. *Název studentské práce*. Brno, 2024. Dostupné také z: <https://www.vut.cz/studenti/zav-prace/detail/157282>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav automatizace a informatiky, Vedoucí práce: doc. Ing. Pavel Škrabánek, Ph.D





## ČESTNÉ PROHLÁŠENÍ

Prohlašuji, že tato bakalářská práce je mým původním dílem, vypracoval jsem ji samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury.

Jako autor uvedené práce dále prohlašuji, že v souvislosti s vytvořením této práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků.

V Brně dne 24. 5. 2024

.....

Tsarykau Matsvei



## **PODĚKOVÁNÍ**

Děkuji vedoucímu práce doc. Ing. Pavlu Škrabánkovi, Ph.D. za podporu, vedení a rady při zpracování této bakalářské práce. Výrazně děkuji společnosti SmartView za poskytnuté vybavení a cenné rady. Dále bych chtěl poděkovat své rodině za pochopení a podporu při studiu a během psaní bakalářské práce.



# OBSAH

<b>1</b>	<b>ÚVOD</b> .....	<b>17</b>
<b>2</b>	<b>ANALÝZA PROBLÉMU</b> .....	<b>19</b>
<b>3</b>	<b>KAMERA</b> .....	<b>21</b>
3.1	Typy kamer .....	21
3.1.1	Plošné kamery .....	21
3.1.2	Řádkové kamery .....	21
3.1.3	Černobíle a barevné kamery .....	21
3.2	Inteligentní kamery .....	22
3.3	CCD and CMOS senzory .....	23
3.3.1	CCD .....	23
3.3.2	CMOS .....	24
3.4	Hlavní parametry kamer .....	25
3.4.1	Zorné pole (FOV) .....	25
3.4.2	Rozměr snímače .....	25
3.4.3	Rozlišení .....	25
<b>4</b>	<b>OBJEKTIV</b> .....	<b>27</b>
4.1	Standardní objektiv .....	28
4.2	Telecentrický objektiv .....	28
4.3	Hypercentrický objektiv .....	28
4.4	Parametry .....	29
4.4.1	Ohnisková vzdálenost .....	29
4.4.2	Pracovní vzdálenost .....	30
4.4.3	Hloubka ostrosti .....	30
4.4.4	Clonové číslo .....	30
4.5	Uchycení objektivu .....	31
4.5.1	C-Mount .....	31
4.5.2	CS-Mount .....	31
4.5.3	S-Mount .....	31
<b>5</b>	<b>OSVĚTLENÍ</b> .....	<b>33</b>
5.1	Osvětlovací techniky .....	33
5.1.1	Přední osvětlení s jasným obrazovým polem (Front bright-field lighting) .....	33
5.1.2	Přední osvětlení s temným zorným polem (Front dark-light lighting) .....	34
5.1.3	Zadní osvětlení (Back light) .....	34
5.1.4	Přední osvětlení s plně jasným obrazovým polem (Front full bright-field lighting) .....	34
5.2	Barevnost .....	35
5.3	Vlnové délky světel .....	35

5.4	Základní typy světel .....	36
5.4.1	Kruhové osvětlovače .....	36
5.4.2	Plošné osvětlení .....	37
5.4.3	Backlight (Zadní rozptýlené světlo) .....	37
5.4.4	Kopulovité osvětlovače .....	38
5.4.5	Osvětlovač DOAL .....	38
5.4.6	Speciální typy osvětlení .....	39
5.4.7	Lineární osvětlení .....	39
<b>6</b>	<b>ZPRACOVÁNÍ OBRAZOVÝCH DAT</b>	
	<b>V OBLASTI DETEKCE DEFEKTŮ .....</b>	<b>41</b>
6.1	Předzpracování obrazu .....	41
6.1.1	Prahování (Thresholding) .....	41
6.1.2	Morfologické metody .....	43
6.2	Deskriptor .....	44
6.2.1	HOG .....	45
6.2.2	SIFT .....	45
6.3	Machine Learning .....	45
6.3.1	Princip analýzy metod strojového učení .....	45
6.3.2	Klasifikátor .....	46
6.3.3	DNN .....	47
6.3.4	Vyhodnocení výsledků (Evaluace) .....	50
<b>7</b>	<b>VÝBĚR A ROZMÍSTĚNÍ INSTALACE .....</b>	<b>53</b>
7.1	Kamera a objektiv .....	53
7.2	Rozdělení povrchu snímaného objektu .....	53
7.3	Zorné pole a rozlišení .....	55
7.4	Pracovní vzdálenost .....	55
7.5	Osvětlení .....	56
7.5.1	Ploché světlo .....	57
7.5.2	Kupolové světlo .....	57
7.6	Rozmístění .....	58
<b>8</b>	<b>VYHODNOCENÍ EXPERIMENTU</b>	
	<b>S INSTALACÍ .....</b>	<b>61</b>
<b>9</b>	<b>NÁVRH A IMPLEMENTACE ALGORITMU ZPRACOVÁNÍ</b>	
	<b>DAT .....</b>	<b>65</b>
9.1	Zpracování dat .....	65
9.2	Sběr dat .....	65
9.3	Trénování neuronové sítě .....	66
9.4	Vyhodnocení .....	69
<b>10</b>	<b>VÝSLEDKY .....</b>	<b>71</b>

<b>11</b>	<b>DISKUZE</b> .....	<b>73</b>
<b>12</b>	<b>ZÁVĚR</b> .....	<b>75</b>
	<b>SEZNAM POUŽITÉ LITERATURY</b> .....	<b>77</b>
	<b>SEZNAM ZKRATEK A SYMBOLŮ</b> .....	<b>81</b>
	<b>SEZNAM OBRÁZKŮ</b> .....	<b>83</b>
	<b>SEZNAM TABULEK</b> .....	<b>85</b>
	<b>SEZNAM PŘÍLOH</b> .....	<b>87</b>
<b>A</b>	<b>Příloha Cognex ViDi Suite</b> .....	<b>89</b>





# 1 ÚVOD

V současném průmyslovém prostředí se stále více prosazuje využití systémů strojového vidění pro automatizaci procesů a zlepšení kontroly kvality výrobků. Přesná kontrola povrchů může ovlivnit celkovou spokojenost zákazníka a zajištění jeho bezpečnosti. Tradiční metody inspekce povrchů často zahrnují ruční zkoušení, což může být časově náročné, nepřesné a náchylné k lidské chybě. S vývojem technologií strojového vidění se však otevírá možnost automatizace tohoto procesu s vysokou přesností a účinností.

Tato bakalářská práce se zaměřuje na problematiku vizuální inspekce povrchové úpravy s využitím strojového vidění. Jedná se o typický problém, který lze díky moderním technologiím plně automatizovat. Cílem této práce je analyzovat tento problém a navrhnout, implementovat a otestovat systém strojového vidění, který bude schopen efektivně a spolehlivě provádět inspekci povrchů a klasifikovat výsledky.

Volba vhodné přístrojové techniky a její optimální rozmístění je klíčová pro dosažení vysoké přesnosti a robustnosti systému strojového vidění. Kromě toho tyto faktory také výrazně ovlivňují časovou náročnost zpracování obrazových dat, což je další důležitý aspekt, který bude v této práci zkoumán.

Hlavním cílem této práce je tedy analýza zadaného problému, návrh, implementace a testování systému strojového vidění. Součástí tohoto procesu bude výběr vhodné přístrojové techniky, návržení jejího optimálního rozmístění vzhledem k snímanému objektu a vytvoření algoritmu pro zpracování obrazových dat zachycených tímto systémem. Důležitou součástí testování bude i hodnocení kvality klasifikace testovaných objektů, které poskytne informaci o efektivitě navrženého systému.

V dalších sekcích této práce budou podrobněji probírány jednotlivé kroky analýzy, návrhu, implementace a testování systému strojového vidění pro vizuální inspekci povrchové úpravy. Cílem je vytvořit robustní a efektivní systém, který bude přinášet významné vylepšení ve srovnání s tradičními metodami inspekce povrchů.




## 2 ANALÝZA PROBLÉMU

Problematika se týká detekce škrábanců a defektů na laku na přístrojích vyráběných firmou Rohde & Schwarz.

Předmětem kontroly je generátor signálu, avšak monitorována bude jeho horní část na základě zadaného úkolu. Geometrický tvar horního krytu je jednoduchý obdélník o rozměrech 450 mm x 360 mm. Charakteristickým rysem horního krytu je absence perforace, což usnadňuje kontrolu. Barva snímaného objektu je jasně modrá a nanášena práškovací metodou.

Během kontroly bude objekt umístěn nepohyblivě na jednom konkrétním místě v speciálně vyvinuté AOI robotické buňce.



Obr. 1: Ukázka robotické buňky

Z obrázku (1) je patrné, že robotická buňka obsahuje průmyslového robota umístěného nahoře na konstrukci. Přímo pod robotem se nachází snímaný objekt, který určuje omezení pro návrh a implementaci kamery a osvětlení. Kvůli těmto omezením byl původní limit pracovní vzdálenosti stanoven na cca 300 mm s ohledem na pracovní a manipulační schopnosti robota.

Při návrhu vhodných komponent je důležité vzít v úvahu, že snímaný objekt bude umístěn v temné komoře uvnitř buňky. Společnost spolupracuje s firmou Cognex a podmínkou je dodržování prostředí specifického pro Cognex. Tyto podmínky stanovují další omezení pro osvětlení a kamerový systém. Pro provádění potřeb-

ných úkolů je k dispozici vysoce produktivní počítač s konfigurací zahrnující vysoce výkonný centrální procesor (CPU) a grafický procesor (GPU).

Hlavním úkolem algoritmu pro zpracování a analýzu obrazu je konečná klasifikace obrazu do dvou hlavních tříd: vadné (NOK) a správné (OK). Navrhovaný algoritmus musí provést všechny potřebné operace a označit poškozený kus jako konečný výsledek.

## 3 KAMERA

Kamera je klíčovou součástí v oblasti strojového vidění. Je to zařízení, které zahrnuje zachycení snímku senzorem kamery a jeho převod do digitální podoby. Přesnost, rychlost a specifické požadavky aplikace hrají klíčovou roli při výběru kamery [1].


### 3.1 Typy kamer

#### 3.1.1 Plošné kamery

U kamer s plošným skenováním zachycuje obraz v jednom snímku snímač obdélníkového tvaru (obr. 2). Výsledný obraz má šířku a výšku, která přímo odpovídá počtu pixelů na snímači. Mezi výhody plošných kamer patří schopnost získat kompletní obrazová data jedním snímkem, což usnadňuje analýzu a zpracování obrazu [2, 1].

#### 3.1.2 Řádkové kamery

Kamery s řádkovým snímáním jsou vybaveny jednou řadou pixelů, což jim umožňuje rychlé snímání dat. Software rekonstruuje získaná data v kompletní obraz řádek po řádku (obr. 2). Řádkové kamery jsou nejčastěji používány v aplikacích, kde je potřeba rychle zachytit obraz objektů pohybujících se v jednom směru, například na výrobních linkách nebo dopravních pásích. Jsou ideální pro inspekci a kontrolu kontinuálních materiálů nebo výrobků [2, 1].



Obr. 2: Srovnání principů práce liniového a plošného skenování [1]

#### 3.1.3 Černobílé a barevné kamery

- **Jednočipové monochromatické kamery** mají integrovaný jeden čip, který slouží k detekci světla a převodu ho na digitální obraz. Tyto kamery mohou snímat obrazy pouze ve stupních šedi a nemají schopnost zaznamenávat barevné informace. Možnost pořizovat černobílé snímky je velmi výhodná pro aplikace kde je důležitá vysoká citlivost na světlo a rozlišení detailů [3].

- **Jednočipové barevné kamery** jsou schopny zachytit barevné obrazy pomocí barevných filtrů umístěných přímo na senzoru. Princip činnosti je založen na umístění šachového políčka před pixely snímače. Tento systém často využívá barevný systém RGB, kde se problém s konfigurací do matice řeší pomocí barevných filtrů, obvykle tzv. Bayerova filtru a získává informace o barvě pomocí interpolačních algoritmů. Ve srovnání s tříčipovým řešením spočívá výhoda jednočipového řešení v nižší ceně, velikosti a hmotnosti. Nevýhodou je nižší citlivost a nutnost interpolace. Jednočipová konfigurace však postačuje pro většinu průmyslových aplikací vyžadujících snímání obrazu v barevném měřítku [3].
- **Tříčipové barevné kamery** jsou založeny na rozdělení bílého denního světla na základní barvy: červenou (R), zelenou (G) a modrou (B). Toto rozdělení se provádí pomocí optických hranolů se dvěma polopropustnými (dichromatickými) zrcadly s aplikovanými barevnými filtry. Každá ze tří barevných složek je pak snímána samostatným snímačem, které zachycují jednotlivé barevné složky obrazu. Výsledkem je trojrozměrná matice o třech úrovních. Výhodou tohoto řešení je, že poskytuje snímky RGB s plným rozlišením a vysokou citlivostí, což vede k mnohem přirozenějšímu zobrazení obrazu než u jednočipových systémů. Jasnou nevýhodou je však vysoká cena, velikost a hmotnost. [3].

## 3.2 Inteligentní kamery

Inteligentní kamery kombinují řídicí, vyhodnocovací a komunikační jednotky pro kompaktní a efektivní provoz. Skládají se z několika základních částí: prvků pro zachycení obrazu a digitalizaci, výpočetní části, vstupů, výstupů a komunikačních rozhraní.

Inteligentní kamery nejmodernějšího typu však nabízejí rozlišení až do 5 Mpx. Výrobci inteligentních kamer vybavují své kamery integrovaným kruhovým světlem (vhodným pouze pro základní úlohy zpracování obrazu) a také umožňují výměnu objektivu, čímž rozšiřují aplikační potenciál těchto zařízení [2].

V dnešní době lze většinu aplikací v průmyslové praxi řešit pomocí těchto kamer. Výhodou těchto kamer není to, že jsou nejlevnějším řešením, ale jejich kompaktnost a jednoduchá implementaci [3].

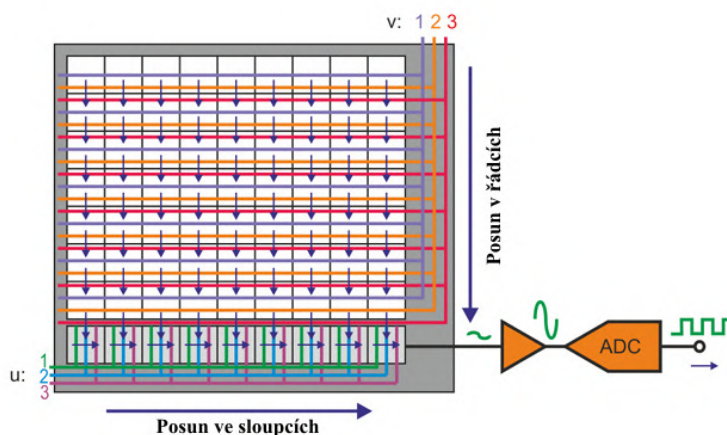
### 3.3 CCD and CMOS senzory

Technologie obrazových senzorů CCD (Charge-Coupled Device) a CMOS (Complementary Metal-Oxide-Semiconductor) je zásadní pro snímání obrazu. Tyto senzory přeměňují optické signály na elektrické signály. Nicméně tyto dva typy čipů používají odlišné metody a prostředky při přenosu těchto informací a jejich návrhy jsou zcela odlišné.

#### 3.3.1 CCD

CCD senzor se skládá z velkého počtu jednotlivých miniaturních polovodičových buněk, z nichž každá zachycuje světlo nezávisle.

Funguje to tak, že během fáze expozice na pixely senzoru CCD dopadají světelné fotony, generující elektrický náboj, po expozici je celý snímek přenesen do čtecího registru. Poté, během fáze přenosu, jsou náboje přenášeny z buňky do buňky v podobě „kolony“ až jsou uloženy u zesilovačů signálu, kteří zesilují signál a předávají jej analogově-digitální převodník (ADC) [4].



Obr. 3: Princip činnosti plošného CCD snímače [5]

Výhodami tohoto detektoru oproti typu CMOS je lepší světelná citlivost, což se projeví v lepší kvalitě obrazu při špatném osvětlení. CCD senzory také dosahují vyšší rychlosti převodu signálu a výsledný obraz vykazuje relativně nízký šum [2].

- **Full Frame snímač** - je nejjednodušší formou snímače, u kterého dopadají přicházející fotony na celý povrch světlocitlivého snímače. Pro čtení snímače je pak třeba nahromaděný náboj posunout vertikálně po řádcích do sériového výstupního registru a pro každý řádek je třeba posunout čtecí registr horizontálně, aby bylo možné přečíst každý jednotlivý pixel. Tomuto postupu se říká „progresivní čtení“. Nevýhodou plného snímku je rozmazání náboje způsobené

světlem dopadajícím na snímač při přenosu signálu akumulovaného náboje do čtecího registru. Aby se tomu zabránilo, používají někdy zařízení mechanickou clonu, která zakrývá snímač během procesu čtení. Mechanické clony však mají problémy s životností a jsou relativně pomalé [3].

- **Frame snímač** - využívá dvoudílný snímač, kde je jedna polovina paralelního pole použita jako paměťová oblast a je chráněna před světlem světlotěsnou maskou. Příchozí fotony mohou dopadat na nezakrytou část pole a nahromaděný náboj je pak rychle (řádově v milisekundách) přesunut do maskované paměťové oblasti pro přenos náboje do sériového výstupního registru. Uložený náboj se odečítá při integraci signálu na světlocitlivé části snímače [3].  
Zařízení s přenosem náboje mají obvykle rychlejší snímkovou frekvenci než zařízení s plným snímkem a jejich výhodou je velké množství pracovních cyklů. Nevýhodou této architektury je rozmazávání náboje při přenosu ze světlocitlivých do maskovaných oblastí CCD, i když je tento jev výrazně méně patrný než u full frame zařízení [3].
- **Interline snímač** - obsahuje kanály pro přenos náboje, které se nazývají meziřádkové masky. Ty jsou umístěny bezprostředně vedle každé fotodiody, aby se nahromaděný náboj mohl po dokončení snímání rychle přenést do kanálů. Velmi rychlé pořízení obrazu prakticky eliminuje rozmazání obrazu. Změnou napětí na fotodiodě tak, aby se generované náboje vstříkávaly do substrátu, místo aby se přesouvaly do přenosových kanálů, lze CCD s meziřádkovým přenosem elektronicky uzavřít. Nevýhodou meziřádkových zařízení je, že meziřádková maska účinně zmenšuje světlocitlivou plochu snímače [3].

### 3.3.2 CMOS


Buňky tohoto snímače rovněž využívají fotoefekt a v tomto ohledu je jejich struktura podobná struktuře snímačů CCD. Na rozdíl od CCD snímačů se však buňka čte přímo. Každý čip světlocitlivé buňky (každý pixel) má svůj vlastní zesilovač a lze jej přímo adresovat a číst jeho souřadnice X,Y. To zvyšuje rychlost čtení obrazu a snižuje spotřebu energie. Snímače CMOS se snadněji vyrábějí a používají se ve velkých i extrémně malých velikostech. Dalším pozitivním aspektem je, že technologie CMOS jsou rozšířené, relativně levné a umožňují vybavit čip dalšími prvky nezbytnými pro získání obrazu, jako jsou řídicí obvody a systémy digitalizace obrazu. Na druhou stranu má umístění zesilovače na každé buňce za následek menší celkovou světlocitlivou plochu. Menší světlocitlivá buňka vyžaduje větší zesílení, což zvyšuje šum obrazu [4, 6].



## 3.4 Hlavní parametry kamer

### 3.4.1 Zorné pole (FOV)


Zorné pole (FOV), znázorněné na obrázku 4, je důležitým parametrem při návrhu a konfiguraci systému strojového vidění, je maximální pozorovatelná oblast, kterou lze v daném okamžiku vidět přes optické zařízení a ovlivňuje, kolik informací může kamera zachytit a zpracovat [2].



Obr. 4: Zorné pole (FOV) [5]

### 3.4.2 Rozměr snímače

Velikost aktivní plochy kamerového snímače je důležitá pro určení zorného pole (FOV) a primárního zvětšení. Tradičně kamery používají čipy s malou plochou (snímače s úhlopříčkou 1/4 až 1/2 palce). Na obrázku 5 můžeme pozorovat, že existuje několik standardních velikostí snímačů pro plošné snímání [7].



Obr. 5: Běžné formáty snímačů pro kamery strojového vidění [8]

### 3.4.3 Rozlišení


Rozlišení je klíčovým parametrem určujícím možnosti systému strojového vidění. Počet pixelů v daném poli snímačů CCD nebo CMOS určuje rozlišení obrazu kamery i udává se jako počet pixelů na osách X a Y (obr. 6). Obecně platí, že větší počet

pixelů je lepší a poskytuje lepší přesnost snímaného obrázku [7]. Pro výpočet rozlišení kamery a prostorového rozlišení můžeme využít následující vztahy:

$$R_s = \frac{FOV}{R_c} = \frac{Sf}{Nf} \quad (1)$$

$$R_c = FOV \cdot \frac{Nf}{Sf} \quad (2)$$


- $R_s$  je prostorové rozlišení,
- $R_c$  je rozlišení kamery,
- $FOV$  je zorné pole objektivu,
- $Nf$  je počet pixelů přiřazené nejmenšímu prvku,
- $Sf$  je velikost nejmenšího prvku.



Obr. 6: Rozlišení obrazu, faktor měřítka a hustota pixelů [9]

## 4 OBJEKTIV

Objektiv je jednou z hlavních součástí vizuálního systému. Spolu se snímačem obrazu kamery určuje pracovní vzdálenost a pole záběru, které zahrnuje scénu. Clonové číslo objektivu určuje, kolik světelné energie dosáhne na snímač obrazu, což ovlivňuje expozici a jasnost výsledného obrazu. Objektiv také ovlivňuje hloubku ostrosti, tedy rozsah vzdáleností, které jsou v zaostření, a úroveň detailů, které jsou rozlišeny v optickém obraze promítaném na snímač obrazu.



Obr. 7: Rozdíl ve snímání pomocí standardního, telecentrického a hypercentrického objektivu [3]

## 4.1 Standardní objektiv

Standardní objektivy (obr.7) jsou nejběžnějším typem objektivů. První čočka, nazývaná objektivní čočka, sbírá světlo z objektu a zaostřuje ho do tzv. mezipředmětné roviny. Tato čočka mění směr světelných paprsků tak, aby se setkaly v jednom bodě. Poté druhá čočka, nazývaná okulární čočka, přijímá světlo z mezipředmětné roviny a zaostřuje ho na snímací plochu kamery, kde vytváří ostrý obraz [3].

Tyto objektivy jsou navrženy tak, aby poskytovaly vyvážený kompromis mezi různými vlastnostmi, jako je ohnisková vzdálenost, rozlišení a clonové číslo. To znamená, že jsou vhodné pro širokou škálu aplikací, například kontrolu kvality, čtečky čárových kódů, počítání objektů, sledování a monitorování [3].

## 4.2 Telecentrický objektiv

Telecentrické objektivy (obr.7) jsou často používány v aplikacích, kde je klíčové zachovat konstantní velikost obrazu nezávisle na vzdálenosti nebo poloze objektu ve zorném poli.

Klíčovou vlastností telecentrických objektivů je udržování konstantního úhlu paprsků vstupujících do objektivu přes celé zorné pole. To znamená, že paprsky světla vstupují do objektivu kolmo na snímací plochu, bez ohledu na jejich vzdálenost od objektivu a bez ohledu na jejich polohu ve zorném poli. Tato vlastnost zajišťuje konzistentní velikost obrazu a minimální zkreslení, což je důležité zejména pro přesné měření a inspekci [3].

## 4.3 Hypercentrický objektiv

Na rozdíl od telecentrických objektivů, hypercentrické objektivy (obr.7) mají schopnost se soustředit na jeden bod nebo bodový zdroj světla ve scéně a zaostřit jej na snímací plochu bez ohledu na jeho polohu. Tato schopnost je užitečná v aplikacích, které vyžadují vysokou hloubku ostrosti nebo potřebují získat jasný obraz objektu. Hypercentrické objektivy jsou často používány v aplikacích jako měření tloušťky materiálů nebo inspekce trhlin a defektů ve strukturách. Díky své schopnosti zachytit ostrý obraz při různých vzdálenostech a polohách jsou hypercentrické objektivy ceněny pro svou všestrannost a přesnost v aplikacích, kde je kritické získat spolehlivé a přesné obrazové informace [3].

## 4.4 Parametry

### 4.4.1 Ohnisková vzdálenost

Ohnisková vzdálenost je jedním z hlavních parametrů objektivu, tento parametr lze popsat jako vzdálenost mezi optickým středem objektivu a rovinou, na které objektiv dokáže zaostřit snímaný objekt tam, kde se protínají všechny paprsky světla, které prochází objektivem [7].

$$\frac{1}{f'} = \frac{1}{a} + \frac{1}{a'} \quad (3)$$

Vzorec (3) popisuje vztah mezi vzdáleností objektu  $a$ , vzdáleností obrazu  $a'$  a ohniskovou vzdáleností čočky  $f'$ . Je základem pro výpočet, jakým způsobem čočka zaostřuje obraz.

$$\beta = \frac{y'}{y} = \frac{a'}{a} = -\frac{Vs}{FOV} = -\frac{Rs \cdot Vp}{FOV} \quad (4)$$

Vzorec (4) vypočítá zvětšení objektu, tedy poměr velikosti obrazu  $y'$  k velikosti objektu  $y$ . To je užitečné pro určení, jak moc bude obraz zvětšený nebo zmenšený ve srovnání s originálním objektem.

$$y' = \frac{f'}{a - f'} \cdot y \quad (5)$$

Vzorec (5) vypočítá velikost obrazu v závislosti na ohniskové vzdálenosti čočky  $f'$ , vzdálenosti objektu  $a$  a velikosti objektu  $y$ . To pomáhá při plánování, jakým způsobem bude obraz vykreslen čočkou.

- $f'$  je ohnisková vzdálenost,
- $a$  je vzdálenost objektu od objektivu,
- $a'$  je vzdálenost obrazu od objektivu,
- $y$  je velikost objektu,
- $y'$  je velikost obrazu,
- $Vs$  je velikost senzoru,
- $Vp$  je velikost pixelu kamery.

Na základě ohniskové vzdálenosti se objektivy dělí do základních skupin:

- Střední (základní) ohniska (30-100 mm) – základní objektivy, přirozené zobrazení, vhodné pro strojové vidění
- Normální objektiv (50 mm) - odpovídá zornému úhlu lidského oka, v provozu může kamera s tímto objektivem nahradit lidskou obsluhu

- Teleobjektivy (100-300 mm) – velké přiblížení, malý úhel záběru; ve strojovém vidění pro aplikace, kde sledujeme malý objekt z větší vzdálenosti

Menší ohnisková vzdálenost znamená širší zorné pole, naopak větší ohnisková vzdálenost znamená užší zorné pole. Tím pádem má ohnisková vzdálenost významný dopad na vlastnosti obrazu, který objektiv vytváří [10].

#### 4.4.2 Pracovní vzdálenost

Pracovní vzdálenost je klíčovým parametrem při návrhu optických systémů, zejména v aplikacích, kde je třeba přesné zaostření na vzorek nebo objekt. Definuje se jako vzdálenost mezi vzorkem a povrchem optického prvku, při které je vzorek stále správně zachycen a zaostřen.

Někdy se pracovní vzdálenost označuje jako rozsah vzdálenosti objektu, což naznačuje, že vyjadřuje vzdálenost, ve které může být objekt umístěn a stále bude zachycen a zaostřen optickým systémem. Tato vzdálenost se obvykle vyjadřuje v milimetrech (mm), což umožňuje přesné plánování a nastavení optických systémů v různých aplikacích [7, 5, 10].

#### 4.4.3 Hloubka ostrosti

Hloubka ostrosti ve fotografii vyjadřuje rozsah vzdáleností, ve kterých jsou objekty v obraze stále ostře viditelné. Když se zaměříte na jeden objekt, mohou být zachyceny ostře i další objekty v různých vzdálenostech od toho, na který jste zaměřeni. Tím můžete zachytit ostré detaily nejen u hlavního objektu, ale i ve vzdálených či blízkých částech scény. Hloubku ostrosti lze měnit pomocí různých parametrů, jako je clonové číslo, ohnisková vzdálenost objektivu a zaostřovací vzdálenost [5].

#### 4.4.4 Clonové číslo


Clona je speciální mechanismus umístěný v těle objektivu, který cloní světlo procházející objektivem. Uzavřením a otevřením clony se mění velikost otvoru pro průchod světla. Velikost clony udává clonové číslo, například f/2,8.

Clonové číslo ovlivňuje hloubku ostrosti a expozici. Nižší clonová čísla (otevřená clona) vytvářejí mělkou hloubku ostrosti a vyšší clonová čísla (uzavřená clona) zvyšují hloubku ostrosti [7]. Clonové číslo se počítá pomocí jednoduchého vzorce:

$$F = \frac{f}{d} \quad (6)$$

- $F$  je ohnisková vzdálenost,
- $f$  je ohnisková vzdálenost objektivu,
- $d$  je průměr otvoru clony,

## 4.5 Uchycení objektivu



Obr. 8: Znárodnění montážního závitu, polohy snímače, mechanické zadní strany a zadní strany příruby [3]

### 4.5.1 C-Mount

Standard C-Mount je jedním z nejběžnějších typů objektivových uchycení ve strojovém vidění. Standard C-Mount má závit o průměru 1 palec s 32 závity na palec (TPI). Ohnisková vzdálenost držáku C-Mount je 17,526 mm. Je ideální pro mnoho průmyslových aplikací, protože závitový držák poskytuje robustní, řízené rozhraní mezi kamerou a objektivem (viz obrázek 8) [7].

### 4.5.2 CS-Mount

Tento typ uchycení objektivu je o něco méně běžný, ale stále se často používá v průmyslovém vidění. Hlavní rozdíl spočívá v kratší ohniskové vzdálenosti stěny, takže budete možná potřebovat adaptér, pokud bude používána kamera vhodná pro objektivu typu C-uchycení [7].

### 4.5.3 S-Mount

Tento typ uchycení objektivu je vzácnější a vhodný pro velmi malé konfigurace objektivů, často používané v kombinaci s kompaktními kamerami pro vizuální systémy s malým otiskem, například s deskovými kamerami. Tyto jsou zcela nekompatibilní s C- a CS-uchycení [7].






## 5 OSVĚTLENÍ

Osvětlení ve strojovém vidění zahrnuje použití různých zdrojů světla a technik osvětlení k optimalizaci obrazových podmínek pro snímání scény nebo objektu. Jeho cílem je zvýšit kontrast, odstranit stíny a zajištění konzistence obrazových dat.

### 5.1 Osvětlovací techniky

Osvětlovací techniky ve strojovém vidění (obr. 9) se používají k osvětlení objektů a scén v průmyslových prostředích. Každá z technik má své vlastní výhody a použití závisí na konkrétních požadavcích aplikace a podmínkách prostředí. V oblasti strojového vidění, na základě různých polohových vztahů mezi světelným zdrojem, objektem a kamerou, lze osvětlení rozdělit na přední a zadní osvětlení [5].



Obr. 9: Základní osvětlovací techniky používaná při návrhu řešení strojového vidění [3]

#### 5.1.1 Přední osvětlení s jasným obrazovým polem (Front bright-field lighting)

Světlo se odrazí z povrchu pozorovaného objektu přímo do objektivu kamery, což umožňuje dobrou viditelnost a detekci povrchových detailů. Tato technika používá difúzní světlo ve spojení s cíleným světlem za účelem vytvoření kontrastů založených na různé absorpci. Směrové světlo se také používá, avšak mnohem méně a slouží k vytvoření kontrastu lesklých povrchů [11, 5].

### 5.1.2 Přední osvětlení s temným zorným polem (Front dark-light lighting)


Temné zorné pole se vytvoří tak, že osvětlovač svítí na objekt z takového úhlu, při kterém nedochází k přímému odrazu světla do snímače kamery – tato vlastnost byla základem pro název. Perfektně rovný povrch se jeví jako tmavý a pouze vyvýšeniny nebo vrypy odrážejí světlo jiným směrem. Tato technika se používá směrové osvětlení a využívá se pro zvýraznění strukturálních vad, kontur, tvarů, nebo hran [11, 5].

### 5.1.3 Zadní osvětlení (Back light)

Zadní osvětlení promítá rovnoměrné osvětlení zezadu cíle, což zdůrazňuje siluetu. Tento typ osvětlení se používá k detekci přítomnosti/absence otvorů nebo mezer, měření nebo ověření tvaru obrysu cíle, stejně jako zvýraznění trhlin, bublin a škrábanců na čistých částech cíle. Upozorňuje se, že povrchové detaily jsou s tímto typem osvětlení ztraceny [11, 5].

### 5.1.4 Přední osvětlení s plně jasným obrazovým polem (Front full bright-field lighting)

Přední osvětlení s plně jasným obrazovým polem (obr. 10) je metoda osvětlování, která je charakterizována intenzivním světlem směřujícím zepředu na zkoumaný objekt. Tato technika využívá nasvícení objektu ze shora nebo z přední části, čímž vytváří jasný a vyvážený obraz s vysokým kontrastem. Technika s plně jasným obrazovým polem je obzvláště užitečná pro vytváření měkkého a rozptýleného osvětlení, protože napodobuje způsob, jakým se světlo chová v reálném prostředí. Přesným modelováním rozptylu světla v rámci struktury kopule je možné dosáhnout realistických světelných efektů, jako je okolní osvětlení, měkké stíny a jemné změny jasu napříč scénou [12].



Obr. 10: Princip fungování předního osvětlení s plně jasným obrazovým polem [3]

## 5.2 Barevnost

Barevnost světla a objektů se týká interakce mezi světlem různých barev a povrchy objektů. Tato interakce je důležitá pro vnímání a rozpoznávání barev v oblasti vizuálního zpracování a analýzy obrazu [3].



Obr. 11: Komplementární barvy [3]

Když světlo dopadá na povrch objektů, různé materiály a pigmenty v povrchu mohou pohlcovat některé z těchto barevných složek a odrážet ostatní. To vede k vnímání různých barev objektů, které vidíme. Například červený objekt pohlcuje většinu modré a zelené složky světla a odrazuje červenou složku, což vede k tomu, že objekt vypadá červeně. Naopak, modrý objekt pohlcuje většinu červené a zelené složky a odrazuje modrou složku, což vede k vnímání modré barvy. Dany jev popisuje základní principy absorpce světla [3].

## 5.3 Vlnové délky světla


- **Bílé světlo** je složené ze světla více vlnových délek a obsahuje celou škálu barev z viditelného spektra. Vysoce jasný bílý zdroj světla je vhodný pro fotografování barevných obrazů, protože umožňuje zachytit široký rozsah barev a detailů s vysokou přesností a konzistencí [13, 14].
- **Modré světlo** má vlnovou délku mezi 430 a 480 nm a často se používá jako zdroj kontrastního osvětlení při kontrole a inspekci různých povrchů a materiálů. Použití modrého světla umožňuje lépe identifikovat defekty, protože některé materiály mají specifickou interakci s modrým světlem, což může zvýraznit určité vlastnosti nebo nedostatky [13, 14].

- **Červené světlo** má typicky vlnovou délku mezi 600 a 720 nm a může procházet tmavými objekty. Často se používá jako zdroj kontrastního osvětlení pro zvýraznění určitých detailů a v aplikacích, kde je potřeba snímat v nízkých světelných podmínkách nebo v prostředí s omezenou viditelností [13, 14].
- **Zelené světlo** má vlnovou délku mezi 510 a 530 nm a leží mezi vlnovými délkami červeného a modrého světla. Zelený světelný zdroj se používá především jako zdroj kontrastního osvětlení pro lepší identifikaci a analýzu různých prvků na površích zkoumaných objektů a analýze povrchových defektů, jako jsou škrábance, nerovnosti nebo kontaminace [13, 14].
- **Infrčervené světlo (IR)** má vlnovou délku 780–1400 nm a nachází se mimo viditelný rozsah lidského oka. Infračervené světlo není viditelné lidským okem, protože oči nejsou schopné zachytit světlo s tak dlouhou vlnovou délkou [15].
- **Ultrafialové světlo** má krátkou vlnovou délku 190–400 nm . UV světlo je schopné detekovat určité materiály, které reagují na UV záření. Například určité látky, barvy nebo pigmenty vykazují fluorescenční vlastnosti. Tento princip fluorescence může být velmi přínosný pro průmyslové aplikace [16].

## 5.4 Základní typy světelných zdrojů

### 5.4.1 Kruhové osvětlovače


Kruhový osvětlovač (obr. 12) poskytuje více rozptýlené světlo směřující od objektivu kamery. Jedná se o světelný zdroj ve tvaru kruhu, který obklopuje čočku nebo objektiv kamery. Je to jeden z nejběžnějších typů osvětlení a lze jej integrovat do kamerových senzorů, ale není ideální vzhledem k tomu, že je obtížné dosáhnout rovnoměrnosti osvětlení [17, 3].



Obr. 12: Schema kruhového osvětlovače a ukázka světla firmy SmartView [3, 18]

### 5.4.2 Plošné osvětlení


Plošné osvětlení (obr. 13) se často používá jako zdroj směrového světla pro osvětlení v tmavém poli. Světlo rovnoměrně rozptýleno nebo rozprostřeno po celém objektu nebo scéně, vytváří měkké a rovnoměrné osvětlení bez tvrdých stínů nebo ostrých kontrastů. V jednodušších aplikacích lze tento světelný zdroj použít místo drahých systémů s jasným polem a rozptýleným světlem. Může být plošné osvětlení využíváno pro kontrolu kvality, měření rozměrů a další inspekční účely, kde je důležité získat vysoce kvalitní a konzistentní obraz [17].



Obr. 13: Schema plošného osvětlovače a ukázka světla firmy SmartView [3, 18]

### 5.4.3 Backlight (Zadní rozptýlené světlo)


Zadní rozptýlené světlo (obr. 14) je často používané k vytvoření kontrastního obrazu objektu, kde jsou detaily na povrchu objektu zvýrazněny předním světlem na tmavém pozadí. Významným rysem je, že může zvýraznit stín neprůhledných objektů nebo pozorovat vnitřek průhledných objektů. Jeho výhodou je, že může jasně obrysovat okraj měřeného objektu. Často se používá při detekci tvaru objektu [17].



Obr. 14: Schema zadního osvětlovače a ukázka světla firmy SmartView [3, 18]

#### 5.4.4 Kopulovitě osvětlovače


Kopulovitě osvětlovače (obr. 15) se používá k osvětlení světlem s jasným obrazovým polem. Světlo produkované světelným zdrojem se rozptýlí na vnitřních stěnách kupole a poté se rovnoměrně rozptýlí na scéně, což vytváří měkké a rovnoměrné osvětlení bez tvrdých stínů nebo odlesků, tomu se někdy říká bezestínové osvětlení. Často se používá pro aplikace, kde je důležitá rovnoměrná osvětlenost scény, jako je například inspekce povrchu, rozpoznávání tvarů nebo čtení čárových kódů [17].



Obr. 15: Schema kopulovitěho osvětlovače a ukázka světla firmy SmartView [3, 18]

#### 5.4.5 Osvětlovač DOAL


Osvětlovač DOAL (Diffused On Axis Lighting) poskytuje specifický typ osvětlení, které vytváří jasné obrazové pole a zároveň rozptyluje světlo. Díky konstrukci s polopropustným zrcadlem je světlo rovnoměrně rozptýlené z celé plochy nad objektem, včetně prostoru před objektivem kamery. Princip DOAL (obr. 16) spočívá v použití speciálních optických prvků, které eliminují tvrdé stíny a odlesky. Výhodou je možnost konfigurovat osvětlovače pro různé úhly a intenzity osvětlení, nevýhodou však je omezené zorné pole [17].



Obr. 16: Schema DOAL osvětlovače a ukázka světla firmy SmartView [3, 18]

### 5.4.6 Speciální typy osvětlení

Speciální typy osvětlení představují kombinaci různých metod osvětlení. Například multi-axiální osvětlení, jak je znázorněno na obrázku 17, kombinuje difuzní osvětlení na ose s nízkoúhlovým osvětlením. Tento typ osvětlení kombinuje rozptýlené světlo s jasným polem a tmavým polem. Dalším příkladem jsou čtvercové spojitý difúzní iluminátory (SCDI), jak je znázorněno na obrázku 17. Tyto iluminátory jsou vylepšenou verzí axiálního difuzního osvětlení, které poskytuje lepší rozptyl světla. Tyto kombinované osvětlovací konfigurace umožňují dosáhnout vyššího kontrastu a lepší kvality obrazu [3].



Obr. 17: Speciální typy osvětlení: Čtvercový spojitý difúzní iluminátor (SCDI) a Multi-axiální osvětlení

### 5.4.7 Lineární osvětlení

Lineární osvětlení se používá hlavně jako směrové osvětlení pro liniové skenovací kamery, kde se světlo s válcovou čočkou používá k vytvoření tenké linie světla pro zorné pole kamery. Tento typ osvětlení se používá i v jiných případech, např. při osvětlení okrajů předmětu z průhledného materiálu. V takovém případě může světlo na okraji předmětu a na okrajích za určitých podmínek jasně zářit [17, 3].





## 6 ZPRACOVÁNÍ OBRAZOVÝCH DAT V OBLASTI DETEKCE DEFEKTŮ

Zpracování obrazových dat ve strojovém vidění je proces, při kterém se digitální obrazy analyzují a interpretují pomocí algoritmů a technik umělé inteligence. Cílem je extrahovat užitečné informace z obrazů, jako jsou objekty, vzory, barvy nebo textury, a použít je k automatizaci procesů, rozpoznávání objektů nebo detekci vad. Obrázek (18) znázorňuje blokové schéma zpracování obrazu v rámci klasifikace a ukazuje tok zpracování od vstupu obrazu až po konečnou klasifikaci, zdůrazňující jednotlivé kroky [19].



Obr. 18: Schéma zpracování obrazu

- $I$  je vstupní obraz,
- $I_s$  je segmentovaný obraz,
- $\mathbf{x}$  je vektor příznaku,
- $y$  je odhadovaná třída obrazu.

### 6.1 Předzpracování obrazu

Předzpracování obrazu je proces, který spočívá v rozdělení obrazu na několik specifických a jedinečných oblastí (segmenty) podle určitého kritéria. Tímto kritériem může být: barva, intenzita nebo textura. Hlavním účelem segmentace obrazu je předpovědět kategorii každého pixelu a přiřadit takzvané markery, což zjednoduší reprezentaci obrazu a usnadní jeho analýzu [8]. Existuje mnoho různorodých segmentačních metod ale níže budou uvedeny ty nejobvyklejší a nejpoužívanější.

#### 6.1.1 Prahování (Thresholding)

Prahování je jednou z technik segmentace, která generuje binární obraz (binární obraz je takový, jehož pixely mají pouze dvě hodnoty - 0 a 1, a proto vyžaduje pouze jeden bit pro ukládání intenzity pixelu) z daného obrazu šedé úrovně tím, že jej rozdělí do dvou oblastí na základě prahové hodnoty. Pixely s intenzitními hodnotami


vyššími než zadaná práhová hodnota budou výstupním obrazem považovány za bílé nebo 1 a ostatní budou černé nebo 0 [8].

- **Binární obrazy**

Tato metoda se nazývá binarizace

$$g(m, n) = \begin{cases} 1 & \text{if } f(m, n) \geq T, \\ 0 & \text{if } f(m, n) < T, \end{cases}$$

kde  $g(m, n)$  je hodnota pixelu,  $f(x, y)$  je hodnota intenzity pixelu a výsledkem je obvykle binární obraz.



Obr. 19: Binární obraz [20]

Existují tedy dvě hlavní skupiny pixelů - jedna skupina se skládá z pixelů s tmavším odstínem a ostatní mají světlejší odstín než práhová hodnota. Na obrázku (19) je vidět jeden pík v blízkosti úrovně 0-10 a druhý na úrovni 30-150. V pozadí tedy může být nastaven objekt zájmu. Pokud použijeme vhodnou prahovou hodnotu, řekněme 20, rozdělí se celý obrázek na dvě odlišné oblasti. Zvolený práh závisí spíše na tom, zda je naším cílem identifikovat celou oblast, nebo spíše jen nejtmaší [10, 20].

- **Globální prahování**

Nejjednodušší metoda transformace obrazu v úrovni šedi na dvouúrovňový obraz. Při globálním prahování se používá jedna hodnota prahu pro celý obraz. Typickým způsobem volby prahu  $T$  je využití vrcholů a údolí v histogramu obrazu, kde algoritmy obvykle směřují k volbě  $T$  v údolích. Základní algoritmus globálního prahování se dá popsat následujícím způsobem [10]:

1. Zvolte počáteční odhad prahu  $T$ .
2. Segmentujte obraz pomocí prahu  $T$  tak, abyste vytvořili dvě skupiny  $G1$  a  $G2$ :
  - $G1$  se skládá ze všech pixelů s hodnotami intenzity  $> T$
  - $G2$  se skládá ze všech pixelů s hodnotami intenzity  $\leq T$

3. Vypočítejte průměrné hodnoty intenzity  $m_1$  a  $m_2$  pro skupiny  $G_1$  a  $G_2$ .
4. Vypočítejte novou hodnotu prahu

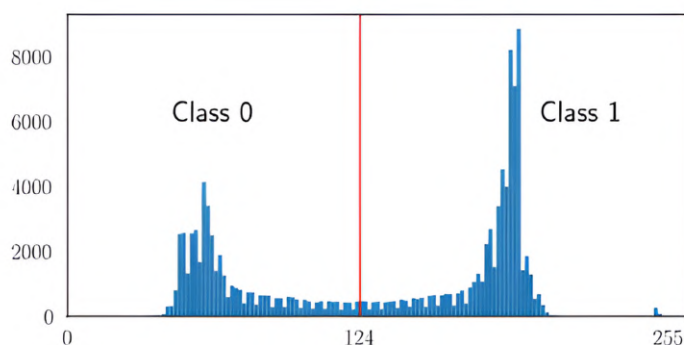
$$T = \frac{m_1 + m_2}{2} \quad (7)$$

5. Opakujte kroky 2 až 4, dokud rozdíl následných hodnot  $T$  není menší než předem definovaná hodnota  $\delta$ .

- **Otsuova metoda**

Otsuova metoda [21], zavedená v roce 1979 se stala velmi oblíbeným přístupem ke stanovení prahové hodnoty a otevřela možnost automatizovat proces pro definování prahové hodnoty, ať se jedná o jakýkoli obrázek, který se má segmentovat.

Princip Otsuovy metody spočívá v maximalizaci separace mezi dvěma třídami pixelů v histogramu obrazu (obvykle objekty a pozadí). Cílem je nalézt prah, který minimalizuje rozptyl uvnitř každé třídy a současně maximalizuje rozdíl mezi nimi [22, 20].




Obr. 20: Histogram separace mezi dvěma třídami pixelů [20]

Výpočet prahu pomocí Otsuovy metody v podstatě zahrnuje sečtení rozptylu pixelů pozadí s rozptylem pixelů popředí pro všechny možné prahy. Vybere se ten prah, pro který je součet rozptylů nejmenší [22, 20].

### 6.1.2 Morfologické metody

Morfologické zpracování obrazu [2] se skutečně zaměřuje na tvary a struktury objektů v obraze, a nikoli na jejich číselné hodnoty pixelů. Morfologické operace pracují pouze s relativním uspořádáním hodnot pixelů a využívají se zejména pro zpracování binárních obrazů, kde jsou pixely reprezentovány jako černé (0) nebo bílé (1) [23, 10].

Tyto operace jsou navrženy tak, aby prováděly manipulace s obrazem na základě topologických vlastností, jako jsou hranice, tvary a struktury objektů. Morfologické techniky zkoumají obraz pomocí malého tvaru nebo šablony nazývané strukturující prvek. Strukturující prvek se umístí na všechna možná místa v obraze a porovná se s odpovídajícím okolím pixelů. Některé operace testují, zda se prvek „vejde“ do sousedství, zatímco jiné testují, zda „zasáhne“ nebo protne sousedství, což je vidět na obrázku (21) [10].



Obr. 21: A: Strukturální prvek se vejde do obrazu, B: Strukturální prvek zasahuje (intersectuje) obraz, C: Strukturální prvek se ani nevejde, ani nezasáhne obraz [24]

- **Eroze a dilatace**

Eroze a dilatace jsou základními stavebními kameny morfologického zpracování obrazu. Obě tyto operace jsou aplikovány na obrázky za účelem manipulace s jejich strukturou a jsou využívány pro odstranění šumu a zlepšení kvality obrazu [23, 25].

**Eroze** je morfologická operace, která smršťuje hranice objektu na obrázku. To se provádí konvolucí obrazu se strukturálním prvkem, který určuje velikost a tvar eroze. Výstupem operace eroze je nový obraz, kde jsou pixely v původním obrazu erodovány nebo smrštěny [23, 25].

**Dilatace** je morfologická operace, která rozšiřuje hranice objektu na obrázku. To se provádí konvolucí obrazu se strukturálním prvkem, který určuje velikost a tvar dilatace. Výstupem operace dilatace je nový obraz, kde jsou pixely v původním obrazu rozšířeny nebo dilatovány [23, 25].

## 6.2 Deskriptor

Deskriptor v kontextu strojového učení je matematickým modelem nebo funkcí, která převádí složité vstupní data na kompaktní reprezentaci, která zachycuje důležité vlastnosti dat. Deskriptory se používají k extrakci vlastností z dat, které mají různé formáty nebo dimenze, aby bylo možné provést analýzu nebo klasifikaci.

### 6.2.1 HOG

Histogram orientovaných gradientů (HOG) [26] je deskriptor příznaků, který se používá v počítačovém vidění a zpracování obrazu za účelem detekce objektů. Tato technika počítá výskyt orientace gradientu v lokalizovaných částech obrazu. Deskriptor HOG se zaměřuje na strukturu nebo tvar objektu a je efektivnější než běžné deskriptory hran, protože k výpočtu rysů používá jak velikost, tak úhel gradientu. Pro jednotlivé oblasti obrazu vytváří histogramy na základě velikosti a orientace gradientu, což umožňuje přesnější popis a rozpoznávání objektů.[27]

### 6.2.2 SIFT

Škálově invariantní vlastnostní transformace (SIFT) [28] je algoritmus používaný pro detekci a popis místních rysů v obrazech. Dokáže dosáhnout spolehlivého porovnávání rysů v různých perspektivách tím, že extrahuje jedinečné invariantní rysy z obrazů. Extrahované rysy jsou invariantní vůči změnám měřítka (přiblížení), rotaci, šumu a změnám osvětlení. Deskriptor SIFT prokázal dobré výkony a je široce používán pro detekci a popis místních rysů v různých aplikacích, včetně porovnávání a rozpoznávání obrazů [29].

## 6.3 Machine Learning

### 6.3.1 Princip analýzy metod strojového učení

- **S učitelem (Supervised)**

Učení s učitelem je přístup v oblasti strojového učení, kde jsou algoritmy trénovány na označených vstupně-výstupních dvojicích. Tyto dvojice jsou obvykle nezávisle a identicky distribuovány z nějaké distribuce. Počet vstupních atributů ovlivňuje časovou a prostorovou složitost trénovacího algoritmu a předpovědní funkce. Každé pozorování může zahrnovat numerické hodnoty, kategoriální hodnoty nebo jejich kombinaci. Během procesu učení algoritmus obecně predikuje nové příklady nebo klasifikuje data na základě vytvořeného modelu. Systém měří svou přesnost a průběžně se zlepšuje. V klasifikaci přiřazuje klasifikátor objektu třídu, příkladem klasifikačního algoritmu je algoritmus KNN. Učení s učitelem je ideální pro rozhodovací stromy, binární klasifikaci, klasifikaci s více třídami, regresní modelování, ačkoliv seskupování (clustering) je typicky úloha učení bez učitele [30, 31].

- **Bez učitele (Unsupervised)**

Učení bez učitele je oblast, ve které není potřeba žádný trenér ani tréninková data. Neoznačená data jsou analyzována a seskupována na základě vlastní zkušenosti stroje, přičemž algoritmus identifikuje seskupení dat a základní vzory

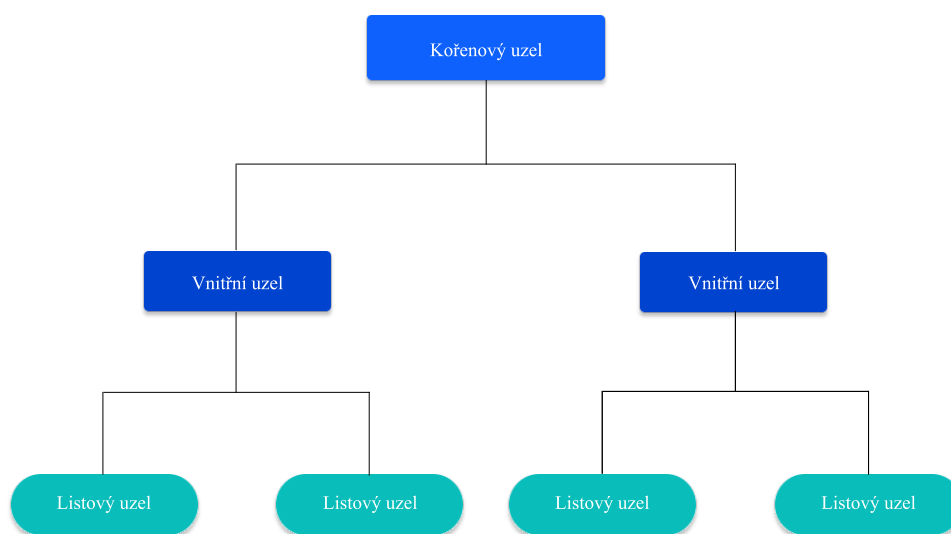
podobných atributů. Modely jsou využívány pro tři hlavní úkoly - shlukování, asociaci a redukci dimenzionality. Shlukování zahrnuje seskupování podobných dat v datasetu, kde lze nalézt společné vlastnosti mezi podobnými skupinami. Jedním z nejoblíbenějších technik analýzy shlukování je k-means shlukování, kde je hledáno k shluků ve vzorku. Nesupervizované učení je méně často používáné než učení s učitelem [30].

### 6.3.2 Klasifikátor

Klasifikátor je algoritmus, který se používá k automatickému přiřazování datových bodů do různých kategorií nebo tříd. Existuje mnoho různých algoritmů klasifikátorů, které se liší v metodách, jak identifikují a generalizují vzory v datech.

- **Rozhodovací stromy**

Rozhodovací strom je neparametrický algoritmus učení s učitelem (Supervised), který se používá pro klasifikační i regresní úlohy. Má hierarchickou stromovou strukturu, která se skládá z kořenového uzlu, větví, vnitřních uzlů a listových uzlů [32].



Obr. 22: Rozhodovací strom [33]

Jak je vidět z výše uvedeného obrázku 22, rozhodovací strom začíná kořenovým uzlem, který nemá žádné příchozí větve. Z kořenového uzlu pak vycházejí odbočky do vnitřních uzlů, známých také jako rozhodovací uzly. Na základě dostupných funkcí provádějí oba typy uzlů vyhodnocení a vytvářejí homogenní podmnožiny, které se označují jako listové uzly nebo terminální uzly. Listové uzly představují všechny možné výsledky v rámci souboru dat [32].

- **SVM (Support Vector Machine)**

Support Vector Machine (SVM) [34] je výkonný algoritmus strojového učení, který se používá pro klasifikační, regresní a detekční úlohy. Jeho hlavním cílem je nalézt optimální hyperplochu mezi různými třídami dat. Tato hranice je definována tak, aby co nejlépe rozdělovala trénovací data do příslušných tříd. Princip fungování SVM spočívá v nalezení optimální hyperplochy, která nejlépe odděluje data ve vícerozměrném prostoru. Tato hyperplocha je definována pomocí tzv. podpůrných vektorů, což jsou body v prostoru dat, které jsou nejbližší k hyperploše [35].

**Lineární SVM** používají lineární rozhodovací hranici k oddělení datových bodů různých tříd. Pokud lze data přesně lineárně oddělit, jsou lineární SVM velmi vhodné. To znamená, že jediná přímka (ve 2D) nebo hyperplocha (ve vyšších dimenzích) může zcela rozdělit datové body do příslušných tříd. Hyperrovina, která maximalizuje rozpětí mezi třídami, je rozhodovací hranicí [35].


**Nelineární SVM** lze použít ke klasifikaci dat, pokud je nelze rozdělit do dvou tříd přímkou (v případě 2D). Pomocí funkcí jádra mohou nelineární SVM zpracovávat nelineárně separovatelná data. Původní vstupní data jsou těmito jádrovými funkcemi transformována do prostoru příznaků vyšší dimenze, kde lze datové body lineárně oddělit. Lineární SVM se používá k nalezení nelineární rozhodovací hranice v tomto upraveném prostoru [35].

- **Nárůst počtu obrázků (Image augmentation)** je technika používaná k umělému rozšíření trénovacího datasetu obrázků. Parametry rozšíření obrazu, které se obecně používají ke zvýšení počtu datových vzorků, jsou zoom, střih, rotace, předzpracování funkce atd. Použití těchto parametrů vede při trénování modelu hlubokého učení ke generování obrázků s těmito atributy. Tento článek [36] demonstruje výhody rozšíření dat v klasifikačních systémech. Vzorky obrázků vygenerované pomocí augmentace obrázků obecně vedou k téměř 3x až 4x většímu nárůstu stávajícího souboru vzorků dat [37].

Cílem je zvýšit rozmanitost dat trénovacího datasetu a zlepšit robustnost a výkon modelů strojového učení, které se učí z těchto dat. Je to klíčový nástroj pro dosažení lepších výsledků při trénování modelů, zejména v případech, kdy je k dispozici omezený trénovací dataset [37].

### 6.3.3 DNN

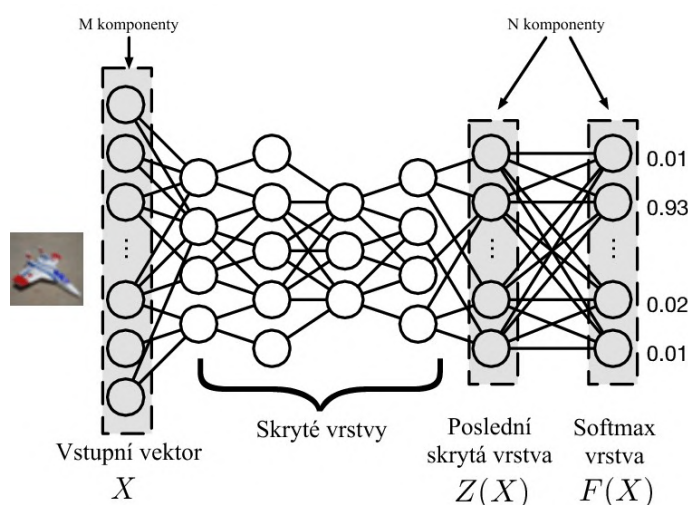
Hluboké neuronové sítě (Deep Neural Networks), známé také jako modely hlubokého učení (Deep Learning), jsou podmnožinou technik strojového učení (Machine Learning), což je znázorněno na obrázku (23).



Obr. 23: Strokové učení, neuronové sítě a hluboké neuronové sítě [38]

Tyto sítě se skládají z mnoha vrstev neuronů, které jsou propojeny, a jejich hlavním cílem je přijímat sadu vstupů, provádět na nich postupně složité výpočty a poskytovat výstupy pro řešení reálných problémů, jako je klasifikace. Neuronové sítě se hojně využívají v problémech učení s učitelem (Supervised). Tyto sítě jsou založeny na souboru vzájemně propojených vrstev, většinou nelineárních a může jejich být řekněme kolem 1000 [38, 39].

- **Architektura DNN** se skládá z několika klíčových komponent, včetně vstupní vrstvy, skrytých vrstev a výstupní vrstvy, což je vidět na obrázku 24.



Obr. 24: Přehled architektury DNN [39]

Vstupní vrstva je první vrstvou DNN a slouží jako vstupní bod pro vstupní data. Skryté vrstvy DNN jsou leží mezi vstupní a výstupní vrstvou. V těchto vrstvách probíhá většina výpočtů, protože provádějí transformace vstupních dat za účelem získání příslušných funkcí a reprezentací. Počet skrytých vrstev a počet neuronů v každé vrstvě jsou hyperparametry, které lze upravit na základě složitosti úlohy. Výstupní vrstva je poslední vrstvou DNN a vytváří



předpovědi nebo výstupy modelu. Počet neuronů ve výstupní vrstvě závisí na povaze úlohy [38, 39].

- **Učení neuronové sítě DNN** je výpočetně velmi náročný proces. Síť poskytne vstupní data a na jejich základě se pomocí čtených maticových násobení předpoví správný nebo nesprávný výstup. Na základě výstupu se do sítě vrací zpětná vazba, systém se učí úpravou svých vah mezi vrstvami. Tento proces se nazývá zpětné šíření (Backpropagation) [38].
- **Ztrátová funkce** slouží k vyhodnocení rozdílu mezi předpovídanými výstupy modelu a skutečnými hodnotami. Minimalizace této funkce při trénování neuronové sítě vede k optimalizaci a zlepšení výkonu [40].  
Křížová entropie (Cross-Entropy Loss) a střední kvadratická chyba (MSE) jsou dva hlavní typy ztrátových funkcí, které se používají při trénování modelů neuronových sítí.  
Hlavním úkolem metody křížové entropie je vyhodnocení rozdílu mezi předpovídanými pravděpodobnostmi tříd a skutečnými třídami ve vstupních datech pro klasifikační úlohy. Střední kvadratická chyba měří průměrné kvadratické odchylky mezi předpovídanými a skutečnými hodnotami, také se často používá pro regresní úlohy, kde je cílem předpovídat numerické hodnoty [40].
- **Ztrátové funkce a vykazovaná výkonnost modelu**  
Dobrym rozdělením, které je třeba zvážit, je použití ztráty k vyhodnocení a diagnostice toho, jak dobře se model učí. To zahrnuje všechny úvahy o optimalizačním procesu, jako je například konvergence. Poté lze zvolit alternativní metriku, která má pro zúčastněné strany projektu význam jak pro hodnocení výkonnosti modelu, tak pro provádění výběru modelu [40].
- **Zpětné šíření (Backpropagation)** je klíčový algoritmus používaný k trénování DNN modelu s cílem minimalizovat ztrátovou funkci. Systém je trénován metodou učení pod dohledem, kdy je chyba mezi výstupem systému a známým očekávaným výstupem předložena systému a použita k úpravě jeho vnitřního stavu. Použitím gradientního sestupu nebo jeho variant se upravují váhy a předpětí sítě tak, aby se minimalizovala ztrátová funkce a zlepšil výkon modelu na trénovacích datech [41].

Po natrénování dobře sestavené hluboké neuronové sítě mohou dosáhnout požadovaných výsledků s vysokou přesností v různých úlohách, jako klasifikace a detekce objektů [42].

### 6.3.4 Vyhodnocení výsledků (Evaluace)

Vyhodnocení výsledků je pro určení, jak dobře model nebo algoritmus plní své úkoly, jako je rozpoznávání objektů, detekce hran, klasifikace obrazů, a další. Existuje několik metod a metrik pro evaluaci výkonnosti modelů. Níže jsou některé z hlavních přístupů:

- **Matice záměn (Confusion matrix)**

Matice záměn je měření výkonu pro klasifikační problém strojového učení, jehož výstupem mohou být dvě nebo více tříd. Jedná se o tabulku, která ukazuje počet správně a nesprávně klasifikovaných instancí pro každou třídu v klasifikačním problému a obsahuje čtyři základní hodnoty [43]:

**True Positives |TP|:** Počet případů, kdy model správně klasifikoval instanci jako pozitivní.

**True Negatives |TN|:** Počet případů, kdy model správně klasifikoval instanci jako negativní.

**False Positives |FP|:** Počet případů, kdy model nesprávně klasifikoval instanci jako pozitivní, když ve skutečnosti byla negativní (falešně pozitivní).

**False Negatives |FN|:** Počet případů, kdy model nesprávně klasifikoval instanci jako negativní, když ve skutečnosti byla pozitivní (falešně negativní).

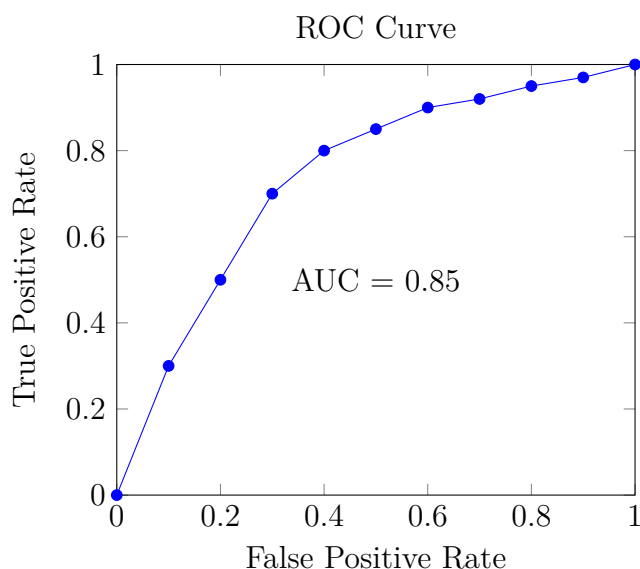
		Predikovaná	
		P'	N'
Skutečná	P	TP	FN
	N	FP	TN

Obr. 25: Matice záměn [43]

- **ROC a AUC křivka**

Zobrazena na grafu ROC (Receiver Operating Characteristic) křivka je vyhodnocovací metrikou pro binární klasifikační problémy, představena grafickou reprezentací vztahu mezi citlivostí (True Positive Rate) a specifíčností (False Positive Rate) klasifikačního modelu při různých prahových hodnotách [44].

AUC je plocha pod ROC křivkou a poskytuje kvantitativní míru výkonnosti klasifikačního modelu. Hodnota AUC se pohybuje mezi 0 a 1, kde hodnota 1 znamená dokonalý model, tím padem čím vyšší je hodnota AUC, tím lepší je výkon klasifikačního modelu [44].



Obr. 26: ROC (Receiver Operating Characteristic) křivka a AUC plocha

- **Přesnost (precision)** je poměr skutečných pozitivních předpovědí k celkovému počtu pozitivních předpovědí. Měří přesnost pozitivních předpovědí [44].

$$Precision = \frac{|TP|}{|TP| + |FP|} \quad (8)$$

- **Preciznost (recall)** je poměr pravdivě pozitivních předpovědí k celkovému počtu skutečně pozitivních případů. Měří schopnost modelu identifikovat všechny pozitivní případy [44].

$$Recall = \frac{|TP|}{|TP| + |FN|} \quad (9)$$

- **F1 Score**

Skóre F1 je harmonický průměr mezi přesností (precision) a precizností (recall). Rozsah skóre F1 je [0, 1]. Vypovídá o tom, jak přesný je váš klasifikátor (kolik případů klasifikuje správně) a také jak je robustní (nevynechá významný počet případů). Čím vyšší je skóre F1, tím lepší je výkonnost našeho modelu [44].

$$F1 = 2 \times \frac{precision \times recall}{precision + recall} \quad (10)$$



## 7 VÝBĚR A ROZMÍSTĚNÍ INSTALACE

Jednou z hlavních částí práce je návrh vhodných komponent pro řešení problému detekce povrchových vad. Pro řešení tohoto problému byly využité dostupné komponenty v rámci firmy SmartView.

### 7.1 Kamera a objektiv

- **Cognex In-Sight 7802M**

Rozlišení:	1600 x 1200; 800 x 600 (Při slabém osvětlení)
Poměr stran:	4:3
Typ senzoru:	CMOS, Monochromaticky
Velikost senzoru:	1/1.8-inch
Uchycení objektivu:	C-Mount

Tab. 1: Parametry kamery

- **Objektiv Cognex LEC-33303**


Typ objektivu:	Objektiv s pevnou ohniskovou vzdáleností
Ohnisková vzdálenost:	12 mm
Formát snímače:	1/1.8-inch
Pracovní vzdálenost:	od 100 mm
Uchycení:	C-Mount
Clona:	f/1.8 - f/11

Tab. 2: Parametry objektivu


### 7.2 Rozdělení povrchu snímaného objektu

Při návrhu instalace bylo zohledněno omezení pracovní vzdálenosti výšky mezi robotem a snímaným objektem - 300 mm. Kvůli tomu omezení není možné zachytit celou plochu objektu. Na základě těchto faktorů bylo rozhodnuto rozdělit povrch snímaného objektu na několik stejných částí.


Na základě rozměrů snímaného objektu (450 mm x 360 mm) bylo rozhodnuto najít nejlepší řešení mezi rozdělením na 2, 4, 6 a 9 částí. Cílem tohoto experimentu je nalézt optimální řešení, které bude odpovídat parametrům dané kamery.




Obr. 27: Rozdělení na 2 částí (Metoda 1), rozměry jsou uvedeny v mm



Obr. 28: Rozdělení na 4 částí (Metoda 2), rozměry jsou uvedeny v mm



Obr. 29: Rozdělení na 6 částí (Metoda 3), rozměry jsou uvedeny v mm



Obr. 30: Rozdělení na 9 částí (Metoda 4), rozměry jsou uvedeny v mm

### 7.3 Zorné pole a rozlišení

Dalším krokem po rozdělení povrchu snímaného objektu je výpočet zorného pole a rozlišení. Tato data jsou nezbytná pro ověření vhodné vybrané kamery.

Výše uvedené velikosti na obrázcích 27, 28, 29 a 30 zobrazují zorné pole pro každý typ rozdělení. Pro přesné určení zorného pole je nezbytné převést získaná data podle poměru stran senzoru kamery, který je zde použitý 4:3. Zatím byla spočítána hodnota požadovaného rozlišení kamery pro každý případ jako:

$$Rch = FOV \cdot \frac{Nf}{Sf} = 225 \cdot \frac{1}{0.1} = 2250 \text{ pixelů} \quad (11)$$

$$Rcv = FOV \cdot \frac{Nf}{Sf} = 180 \cdot \frac{1}{0.1} = 1800 \text{ pixelů} \quad (12)$$

- $Rch$  je horizontální rozlišení kamery,
- $Rcv$  je vertikální rozlišení kamery,
- $FOV$  je zorné pole objektivu,
- $Nf$  je ohnisková vzdálenost objektivu.
- $Sf$  je velikost pixelu.

Tabulka 3 uvádí vypočítané parametry rozlišení pro každou z metod rozdělení hlavního snímaného objektu. Data jsou převedena do formátu příslušného senzoru kamery, který má poměr stran 4:3.

Metoda 1 :	3600 x 2700 px
Metoda 2:	2250 x 1680 px
Metoda 3:	1800 x 1350 px
Metoda 4:	1600 x 1200 px

Tab. 3: Výsledné rozlišení pro každou metodu rozdělení

Ze získaných dat vyplývá, že rozdělení podle čtvrté metody nepřekračuje maximální rozlišení kamery Cognex In-Sight 7802M, což v daném případě znamená nejlepší řešení.

### 7.4 Pracovní vzdálenost

Pracovní vzdálenost je důležitým parametrem, protože je nutné vzít v úvahu přibližně stanovený rozměr pracovní vzdálenosti s ohledem na pracovní a manipulační schopnosti robota - 300 mm. S pomocí dat z tabulky 2 parametrů daného objektivu a rozměrů zorného pole 160 mm × 120 mm lze vypočítat pracovní vzdálenost nad snímaným objektem.

$$\beta = -\frac{Vs}{FOV} = -\frac{1600 \cdot 0,0045}{160} = -0,045 \quad (13)$$

- $\beta$  je zvětšení objektu,
- $Vs$  je výška senzoru,
- $FOV$  je zorné pole objektivu.

Pro výpočet rozlišení podle rovnic (1) a (2) bylo potřeba přiřadit nejmenšímu prvku hodnotu 1 pixel, kde velikost pixelu je 0,1 mm.

Pomocí rovnic (3) a (4) se dalo spočítat parametr vzdálenosti objektu od objektivu

$$a = f' \cdot \frac{1 - \beta}{\beta} = 12 \cdot \frac{1 + 0,045}{-0,045} = -279 \text{ mm} \quad (14)$$

- $a$  je vzdálenost objektu od objektivu,
- $\beta$  je zvětšení objektu,
- $f'$  je ohnisková vzdálenost objektivu.

Negativní hodnota pracovní vzdálenosti naznačuje, že objektiv musí být umístěn před snímaným objektem.

Objektiv Cognex LEC-33303 s pevnou ohniskovou vzdáleností 12 mm poskytuje pracovní vzdálenost přibližně 279 mm při zorném poli o rozměrech 160 x 120 mm. Získaná pracovní vzdálenost se nachází v stanovených mezích (do 300 mm), což znamená, že tento objektiv je vhodný pro tento úkol.

## 7.5 Osvětlení

Výběr vhodného osvětlení je klíčovým faktorem pro úspěch celého systému strojového vidění, neboť má významný vliv na kvalitu a konzistenci získaných obrazů kamerou.

Nejprve bylo nutné před výběrem vhodného osvětlení zohlednit, že instrumentace musí být umístěna na robotu a měření budou prováděna v temné prostředí. Následně byla provedena volba techniky osvětlení povrchu. Vzhledem ke všem omezujícím faktorům je v tomto případě použití techniky „Přední osvětlení s plně jasným obrazovým polem“ nejvhodnější volbou. Jiné techniky, jako například „Přední osvětlení s temným zorným polem“ nebo „Zadní osvětlení“, by vyžadovaly umístění osvětlení mimo kameru, což v tomto případě není možné.

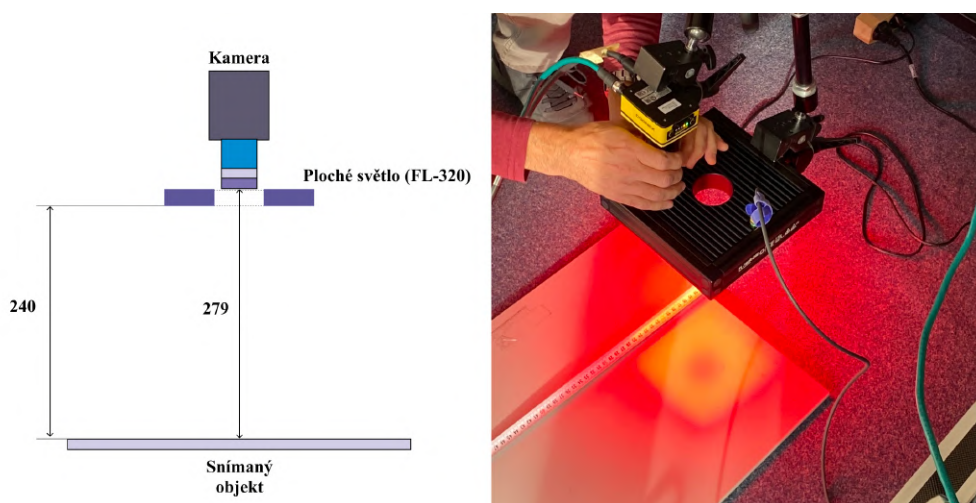


### 7.5.1 Ploché světlo

První testy osvětlení začaly s plochého světla. Tento typ lamp byl k dispozici v červené a bílé barvě. Experimenty s tímto typem lampy byly provedeny ve vzdálenosti 240 mm od snímaného povrchu ke světelnému zdroji. Poloha kamery a objektivu zůstala nezměněna, a to 279 mm nad snímaným objektem.

Kamera :	Cognex In-Sight 7802M
Objektiv:	LEC-33303
Zorné pole:	160 mm x 120 mm
Světlo:	Ploché světlo SmartView (FL-320)
Barva světla:	Bílá a červená
Vzdálenost do světla:	240 mm
Vzdálenost do kamery:	279 mm

Tab. 4: Parametry snímání pro ploché osvětlení



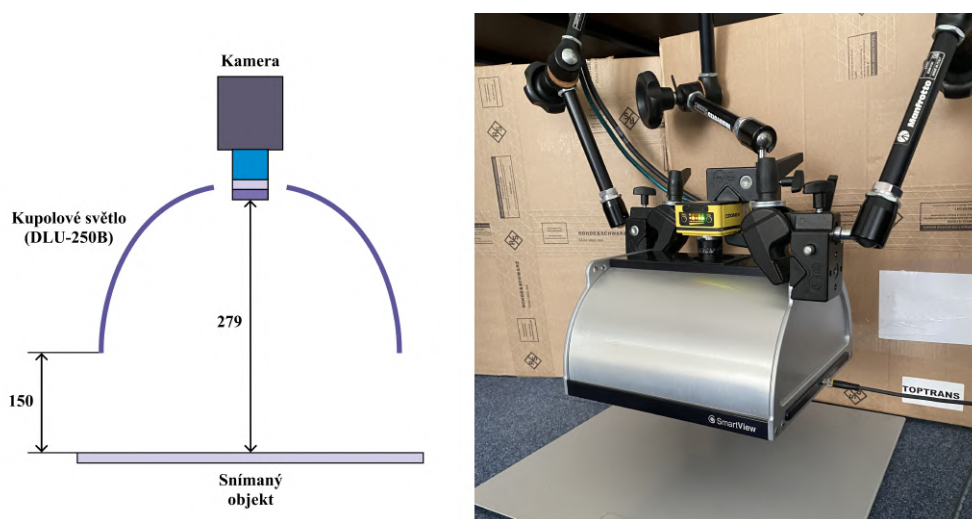
Obr. 31: Schéma a obrázek provedení experimentu s použitím plochého osvětlení, uvedené rozměry jsou v mm

### 7.5.2 Kupolové světlo

Následující test byl proveden pomocí kupolového světla. Pro tento test byla použita lampa s vlnovou délkou modré barvy, protože teoreticky může být vhodná pro dosažení optimálního kontrastu a rozlišení ve snímcích. Při měření byla vzdálenost mezi světelným zdrojem a snímaným objektem 150 mm. Vzdálenost kamery zůstala stejná jako v minulých testech - 279 mm.

Kamera :	Cognex In-Sight 7802M
Objektiv:	LEC-33303
Zorné pole:	160 mm x 120 mm
Světlo:	Kupolové světlo SmartView (DLU-250B)
Barva světla:	Modra
Vzdálenost do světla:	150 mm
Vzdálenost do kamery:	279 mm

Tab. 5: Parametry snímání pro kupolové osvětlení



Obr. 32: Schéma a obrázek provedení experimentu s použitím kupolového osvětlení, uvedené rozměry jsou v mm

## 7.6 Rozmístění


Kamera s objektivem a kopulovitá lampa jsou komponenty které je důležité správně umístit nad snímaným objektem. Jak už bylo řečeno vzdálenost od robotické ruky do povrchu objektu je nejomezenějším místem. Společně s technikami firmy Rohde&Schwarz byla stanovena optimální výška umístění všech komponentu tak, aby se robot pohyboval bez omezení, což je cca 400 mm.

Kamera:	35.7 mm
Objektiv:	35.2 mm (maximální)
Světlo:	150 mm

Tab. 6: Výška všech komponent

Tabulka 6 obsahuje údaje o maximální výšce jednotlivých komponent. Pro výpočet výšky budeme potřebovat sečíst hodnoty pracovní vzdálenosti kamerového

systemu (279 mm) a jeho výšku (70,9 mm). Při provádění primárních testů je obtížné dosáhnout přesných výsledků, přesto výsledná hodnota vyšla kolem 350 mm, což je pod uvedeným limitem.



Obr. 33: Výška všech komponent



## 8 VYHODNOCENÍ EXPERIMENTU S INSTALACÍ

Experiment s rozdělením objektu na 9 částí ukázal jako optimální volba vzhledem k rychlosti a účinnosti shromažďování dat. Navíc tato strategie umožňuje budoucí zvýšení počtu snímků pro detailnější analýzu, což může vést k vylepšení výsledků kontroly povrchových vad.

Dosažené výsledky výpočtů zorného pole, rozlišení a pracovní vzdálenosti potvrzují, že zvolena kamera a objektiv splňují požadavky původního zadání. Splnění těchto kritérií zajišťuje, že zařízení bude schopno spolehlivě a přesně detekovat a analyzovat vady na snímaném objektu.

Analýza efektivity osvětlení je zásadním krokem při návrhu. Proto byly provedeny testy s různými typy osvětlení. Během testů bylo ploché světlo zkoušeno ve dvou variantách: s bílým a s červeným světlem. Dále bylo testováno kupolové světlo s modrou barvou.

- **Bílé ploché světlo**


Výsledky testů jsou zobrazeny na obrázku 34. V případě bílého světla je jasně vidět, že scéna je silně osvětlena a světlo se odráží jako jasný odlesk od povrchu krytu. V této situaci lze odvodit, že tato metoda zesvětlení nebude fungovat, protože odlesky mohou snižovat kontrast a zhoršovat schopnost kamery detekovat a rozlišit detaily scény.



Obr. 34: Výsledek osvětlení bílým plochým světlem

- **Červené ploché světlo**


Přes to, že teoreticky vlnová délka červené barvy měla vytvořit největší kontrast, v praxi není výsledek ideální. Na obrázku 35 je vidět nedostatečné osvětlení na okrajích scény a výrazný stín výřezu pro kameru uprostřed snímku, což snižuje oblast detekce vad a komplikuje zpracování dat.



Obr. 35: Výsledek osvětlení červeným plochým světlem

- **Modré kupolové světlo**

Výsledek zobrazený na obrázku 36 ukazuje vynikající výsledek rovnováhy mezi osvětlením scény, rozlišením obrazu a viditelností defektů na povrchu. Můžeme tedy konstatovat, že tento typ osvětlení je vhodný pro řešení úkolu kontroly v našich podmínkách.



Obr. 36: Výsledek osvětlení modrým kupolovým světlem

Důležitým aspektem při provedení výše zmíněných testů je dodržení konzistence v použitém vybavení. Všechny testy byly prováděny se stejnou kamerou a objektivem, které byly umístěny ve stejné poloze nad snímaným objektem.






## 9 NÁVRH A IMPLEMENTACE ALGORITMU ZPRACOVÁNÍ DAT

### 9.1 Zpracování dat

Rozhodnutí zvolit softwarový balík Cognex ViDi Suite místo tradičního hlubokého učení bylo motivováno omezeným množstvím dostupných trénovacích dat. Celkem bylo k dispozici pět vzorků, z nichž dva byly nepoškozené a zbývající tři měly různé typy vad. V takových podmínkách bylo obtížné nasadit konvenční metody hlubokého učení, které vyžadují velké množství trénovacích dat k úspěšnému natrénování modelu.

Vzhledem k tomu, že se jedná o komerční produkt, utajená data o topologii a dalších algoritmech neposkytují možnost konkrétněji popsat použité techniky pro trénink neuronové sítě a další klasifikaci dat. Na základě dostupných informací lze fungování této neuronové sítě popsat pomocí obrázku 37.




Obr. 37: Princip činnosti Cognex ViDi Suite

### 9.2 Sběr dat

Pořízení snímků představovalo první krok. Celkem bylo k testování přiděleno 5 vzorků. Vzhledem k rozdělení povrchu každého vzorku na 9 částí bylo pro každý vzorek k dispozici 9 snímků. Tento počet snímků se jeví jako poměrně malý pro klasické metody hlubokého učení, které často vyžadují rozsáhlejší trénovací datasey.

Pro zachycení snímaného objektu byl využit specializovaný software Vision-Pro od společnosti Cognex, který umožnil komunikaci s kamerou a pořízení snímků. Komunikace mezi kamerou a počítačem byla realizována pomocí protokolu GigE Vision. Následně byly manuálně upraveny parametry jako expozice a citlivost (ISO) s cílem optimalizovat kvalitu snímků.



Obr. 38: Proces sběru dat

Kryt č.1:	9 snímků
Kryt č.2:	9 snímků
Kryt č.3:	9 snímků
Kryt č.4:	9 snímků
Kryt č.5:	9 snímků
Celkové:	45 snímků


Tab. 7: Výsledný počet pořízených snímků

Tento počet snímků představuje základní sadu dat, která bude použita pro analýzu a následné trénování algoritmů detekce vad.

### 9.3 Trénování neuronové sítě

Aplikace Cognex ViDi Suite nabízí širokou škálu nástrojů a funkcí, které umožňují provádět různé úlohy v oblasti kontrolního zpracování obrazu a inspekce produktů. Proces trénování neuronové sítě je v programu zcela automatický, je třeba pouze správně nastavit potřebné parametry. Právě o tom bude řečeno v této části.

Na obrázku 39 můžeme vidět, jak vypadá rozhraní softwaru Cognex ViDi Suite. V tomto kroku byl vytvořen projekt a vybrán jeden ze čtyř režimů činnosti programu - Analyzátor. Dále byl v režimu analyzátor vybrán velký model trénování sítě a také byl zvolen tréninkový režim s učitelem (Supervised). V této fázi byl rovněž nahrán obrázek s vadou, který se dostal do tréninkového setu.



Obr. 39: Rozhraní softwaru Cognex ViDi Suite.

Po nahrání vadného kusu následuje ruční označení vady pomocí přidání masky. Maska slouží jako povrchová vrstva, na které může uživatel pomocí speciálních nástrojů (obr. 40) označit červeným markerem všechny potřebné vady (obr. 41). Na konci tohoto kroku je třeba přijmout úpravy a označit tento kus za vadný.


Výchozí panel nástrojů Úpravy oblastí:



Panel nástrojů Úpravy oblastí v režimu Expert:

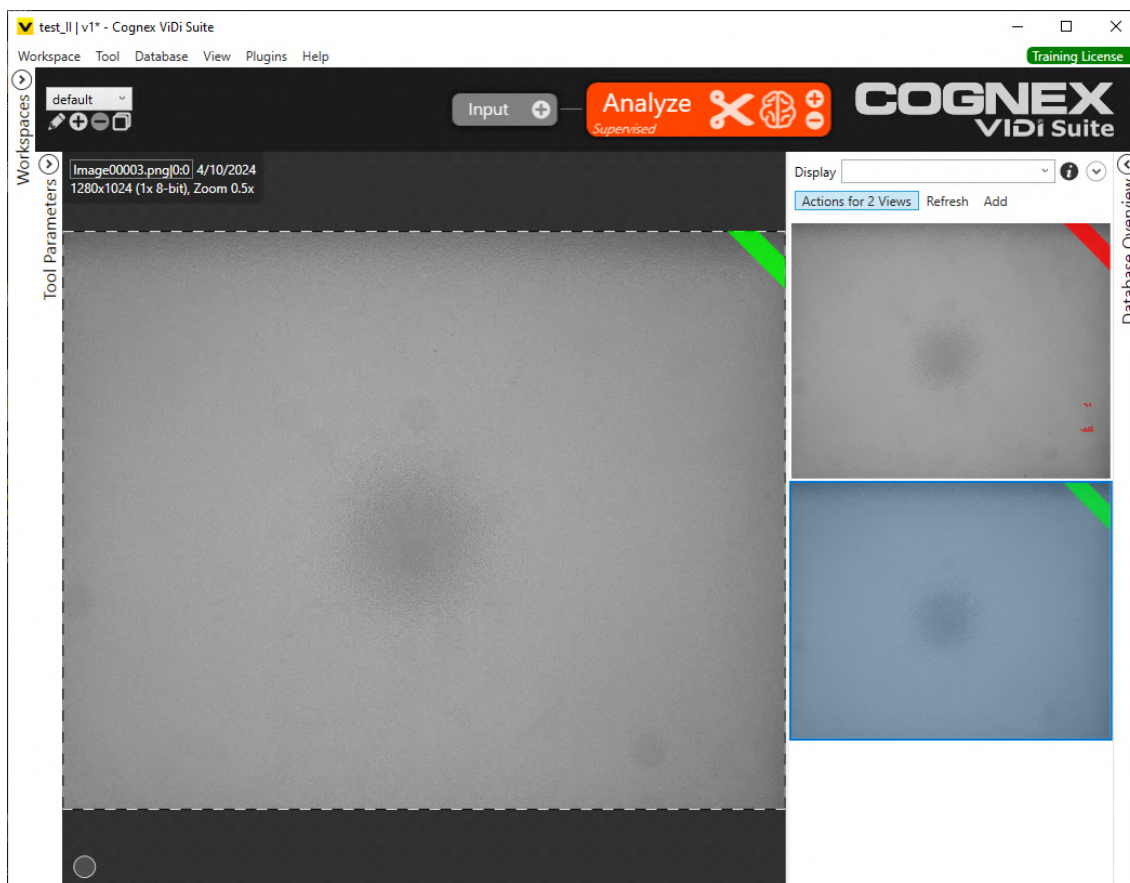


Obr. 40: Speciální nástroj na označení vad



Obr. 41: Označování vady pomocí speciálních nástrojů

Dalším důležitým krokem je přidání správného kusu do trénovacího setu a označení tohoto kusu jako správného. Nyní jsou na obrázku 42 vidět dva kusy, z nichž jeden je označen jako vadný a druhý jako správný. Do tréninku tak bylo přidáno vybraných 10 snímků, z toho 7 s různými typy poškození a zbývající 3 bez poškození.



Obr. 42: Správný a vadný kus

Ve fázi, kdy je tréninkový set vytvořen, se začíná trénování neuronové sítě. Tento proces vyžaduje obrovský výpočetní výkon počítače. V následující tabulce 8 jsou uvedeny parametry počítače, na kterém bylo realizováno trénování. Při této konfiguraci počítače trvalo trénování neuronové sítě přibližně 15 minut.

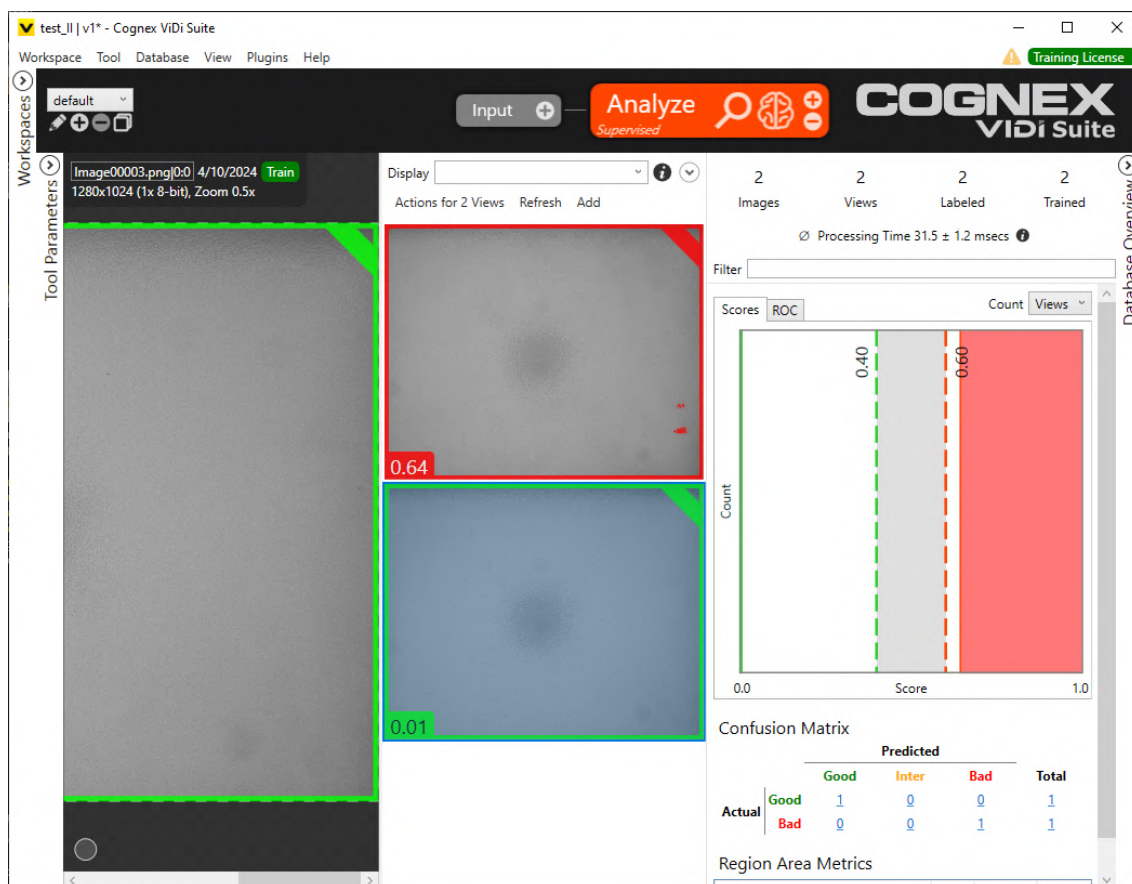
Procesor (CPU): AMD Ryzen 7 8700G  
 Grafická karta (GPU): NVIDIA GeForce 4060Ti  
 Paměť (RAM): 64 Gb

Tab. 8: Konfigurace počítače

## 9.4 Vyhodnocení

Posledním krokem je klasifikace výsledků a vyhodnocení výkonnosti klasifikačního modelu pomocí speciálních metrik.

Klasifikace obrázků se provádí na základě analýzy skóru(score), které neuronová síť přiřadila každému obrázku během zpracování. Uživatel může nastavit potřebné limity pro klasifikaci, které jsou znázorněny na obrázku 43, a tím určit požadovanou přesnost klasifikace vzorku.



Obr. 43: Nastavení klasifikace

Na obrázku 43 je zobrazeno, jak neuronová síť označí vzorky, které překročily nastavené limity pro klasifikaci. Vzorky nad horní hranicí jsou označeny červeně, zatímco ty, které zůstávají v rámci limitu, jsou označeny zeleně. Vzorky mezi horní

a dolní hranicí limitu jsou považovány za ty, které vyžadují další úpravu parametrů nástroje.

Pro vyjádření výkonnosti klasifikačního modelu software Cognex vytváří tabulku matice záměn (Confusion matrix) a ROC graf (Receiver Operating Characteristic). Matice záměn poskytuje detailní přehled o schopnosti modelu klasifikovat data porovnáním skutečných a předpovězených hodnot, zatímco ROC graf poskytuje komplexní pohled na schopnost modelu rozlišovat mezi pozitivními a negativními případy při různých prahových hodnotách. Používání těchto nástrojů umožňuje uživatelů ViDi Suite efektivně vyhodnotit a porovnat výkonnost klasifikačního modelu.

## 10 VÝSLEDKY

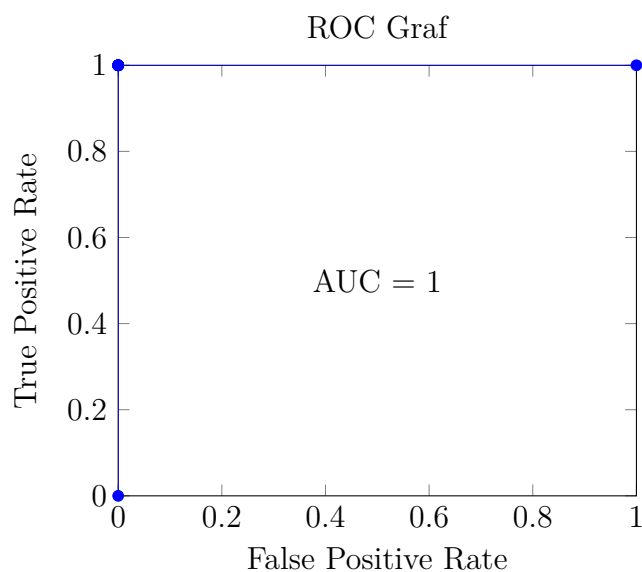
Testovací sada obsahovala 25 náhodně vybraných obrázků, které zahrnovaly jak plně dobré, tak vadné vzorky. Analýza této testovací sady byla provedena softwarem Cognex ViDi Suite a trvala průměrně 32,2 milisekundy s odchylkou 2,6 milisekundy.

Při volbě limitů v rozmezí 0,07 až 0,09 bylo cílem dosáhnout co nejpřesnějších výsledků klasifikace, tedy co nejnižšího počtu chyb, zatímco současně minimalizovat výskyt nezatříděných vzorků. Tímto způsobem se snažíme dosáhnout optimálního kompromisu mezi přesností klasifikace a minimalizací nepřesných výsledků.



Obr. 44: Výsledky klasifikace

V tomto konkrétním ROC grafu je křivka ideálního klasifikátoru zobrazena jako jedna krátká svislá čára od (0,1) do (1,1). AUC (Area Under the Curve) je potom rovna 1, což ukazuje, že model má perfektní výkonnost. To znamená, že model dokáže správně klasifikovat všechny pozitivní a negativní instance bez jakýchkoli chyb.



Obr. 45: Přesnost klasifikačního modelu pomoci ROC křivky a AUC plochy

Trénovací sada:	10 vzorců
Testovací sada:	15 vzorců
Počet případů:	25
Počet správných:	25
Přesnost:	100 %
Citlivost:	100 %
Specificita:	100 %
Chybějící pozitivní případy:	0
Chybějící negativní případy:	0

Tab. 9: Výsledky klasifikace

Výsledky klasifikace ukazují, že z celkového počtu 25 případů byly všechny klasifikovány správně, což odpovídá přesnosti 100%. Citlivost a specificita klasifikátoru také dosáhly 100%, což říká o schopnosti klasifikátoru správně identifikovat jak pozitivní, tak negativní případy. Důležitým aspektem je také to, že nebyly zaznamenány chybějící pozitivní ani negativní případy, což svědčí o vysoké spolehlivosti klasifikačního modelu.



## 11 DISKUZE

Tato bakalarska práce využila technologii strojového vidění spolu s umělou inteligencí Cognex ViDi Suite k posouzení kvality povrchů.

Výsledky prezentované v kapitole 10 zdůrazňují přesnost navrženého systému strojového vidění při identifikaci a klasifikace povrchových vad, jako jsou škrábance, dosahující úrovně 100% v parametrech přesnosti, citlivosti a specifické klasifikování. S pomocí pečlivé analýzy obrazových dat systém zručně rozlišuje mezi přijatelnými (OK) a vadnými (NOK) povrchy, což umožňuje rychlé procesy hodnocení kvality.

Navzdory povzbudivým výsledkům existuje několik omezení, která je třeba zvážit. Zejména závislost na kontrolovaných laboratorních podmínkách nemusí zcela napodobovat prostředí reálné výroby. Navíc proměnné jako jsou podmínky osvětlení a doba zachycení objektu mohou ovlivnit výkon systému strojového vidění. Jak je vysvětleno v kapitole 7.2, rozdělení snímaného objektu do devíti částí prodloužila dobu pořízení snímku, což zdůrazňuje potřebu optimalizace při praktickém provádění.

Pro řešení těchto omezení by se budoucí výzkum mohl zaměřit na chování systému za různých podmínek osvětlení nebo s různými zdroji osvětlení. Kromě toho optimalizace výběru komponentů by mohla urychlit proces zachycení dělením objektu na větší části. Takové snahy by zlepšily adaptabilitu a operační efektivitu systému v výrobním prostředí.

Implementace této technologie má pro společnost Rohde&Schwarz značný potenciál, nabízející cestu k minimalizaci výrobních chyb a zvýšení spokojenosti zákazníka prostřednictvím dodání nepoškozených produktů. Integrovaním této pokročile kontrolní systémy mohou výrobci zefektivnit procesy zajištění kvality a posílit celkovou operační efektivitu.



## 12 ZÁVĚR

Cílem této bakalářské práce bylo efektivně detekovat škrábance a defekty na laku přístrojů firmy Rohde&Schwarz. V rámci návrhu instrumentaci byla provedena pečlivá volba přístrojové techniky, s důrazem na kamery, objektivy a osvětlení, které jsou vhodné pro danou aplikaci. V této implementaci bylo strategicky zvoleno kupové osvětlení od firmy SmartView a kamera s objektivem od firmy Cognex. Tato kombinace poskytuje optimální světelné podmínky a obrazovou kvalitu pro účely vizuální inspekce povrchové úpravy. Díky preciznímu rozmístění těchto komponent vzhledem k snímanému objektu není omezen pohyb robota v pracovní buňce.

Klíčovou součástí celého systému je algoritmus zpracování obrazových dat, který byl vyvinut s využitím neuronových sítí Cognex ViDi Suite. Tento algoritmus je navržen tak, aby efektivně, spolehlivě a rychle klasifikoval obrazy do dvou hlavních tříd: vadné (NOK) a správné (OK). Výsledky testování potvrdily účinnost navrženého systému a jeho schopnost spolehlivě identifikovat a klasifikovat škrábance nebo jiné defekty na povrchu snímaného objektu.

Celkově lze konstatovat, že navržený, implementovaný a otestovaný systém strojového vidění splnil požadavky stanovené v zadání a představuje efektivní řešení pro detekci vad pro danou úlohu s využitím moderních technologií zpracování obrazu a strojového učení.



## SEZNAM POUŽITÉ LITERATURY

- [1] *Cognex* [<https://www.cognex.com/>].
- [2] HORNBERG, A. *Handbook of Machine Vision*. 1. vyd. Weinheim: WILEY-VCH Verlag GmbH & Co KGaA, 2006. ISBN 3-527-40584-4.
- [3] TUNÁK, M. *Introduction to Machine Vision, Fundamental Principles and Hardware*. Liberec, Czech Republic: Technical University of Liberec, 2017. ISBN 978-80-7494-391-1.
- [4] SZELISKI, R. Springer, 2010. ISBN 978-3030343712.
- [5] BATCHELOR, B. G. *Machine Vision Handbook: with 1295 Figures and 117 Tables*. London: Springer, 2012. ISBN 978-1-84996-169-1.
- [6] BIGAS, M., CABRUJA, E., FOREST, J. a SALVI, J. Review of CMOS Image Sensors. *Microelectronics Journal*. 2006, sv. 37, č. 5. ISSN 0026-2692.
- [7] DEMANT, C., STREICHER ABEL, B. a GARNICA, C. *Industrial Image Processing*. Berlin: Springer, 2013. ISBN 978-3-642-33905-9.
- [8] GONZALEZ, R. C. a WOODS, R. E. *Digital Image Processing*. 3rd. New York, NY: Pearson Education, 2007. ISBN 978-0-13-335672-4.
- [9] INC., A. *Human Interface Guidelines: Images*. 2024. Dostupné z: <https://developer.apple.com/design/human-interface-guidelines/images>.
- [10] QI, H. a SNYDER, W. E. *Machine Vision*. CRC Press, 2016.
- [11] *Components - Lighting* [<https://www.cognex.com/what-is/machine-vision/components/lighting>].
- [12] REN, Z., FANG, F., YAN, N. a WU, Y. State of the Art in Defect Detection Based on Machine Vision. *International Journal of Precision Engineering and Manufacturing-Green Technology*. 2022, sv. 9, č. 2. DOI: 10.1007/s40684-021-00343-6.
- [13] RYER, A. a LIGHT, V. *Light Measurement Handbook*. Newburyport, MA: International Light, 1997. ISBN 0-9658356-9-3.
- [14] BRAUN, D. a HEEGER, A. J. Visible light emission from semiconducting polymer diodes. *Applied Physics Letters*. 1991, sv. 58, č. 18. DOI: 10.1063/1.105039.

- [15] LEE, D.-J., SCHOENBERGER, R., ARCHIBALD, J. a MCCOLLUM, S. Development of a machine vision system for automatic date grading using digital reflective near-infrared imaging. *Journal of Food Engineering*. 2008, sv. 86, č. 3. DOI: 10.1016/j.jfoodeng.2007.10.021.
- [16] AL MALLAHI, A., KATAOKA, T., OKAMOTO, H. a SHIBATA, Y. Detection of potato tubers using an ultraviolet imaging-based machine vision system. *Biosystems Engineering*. 2010, sv. 105, č. 2. DOI: 10.1016/j.biosystemseng.2009.11.004.
- [17] HAVLE, O. Strojové vidění IV: Osvětlovače. *AUTOMA*. 2008, sv. 4, č. 4.
- [18] *Osvětlení strojového vidění* [<https://www.smartview.cz/c-osvetleni-strojoveho-videni>].
- [19] WEST, P. C. Image Processing for Machine Vision – How Did We Get Here? *Quality Magazine*. San Jose, CA: [b.n.]. May 4 2023.
- [20] MAZET, V. *Basics of Image Processing*. 2020–2024.
- [21] ZHANG, J. a HU, J. Image Segmentation Based on 2D Otsu Method with Histogram Analysis. In: *2008 International Conference on Computer Science and Software Engineering*. 2008, sv. 6. DOI: 10.1109/CSSE.2008.206.
- [22] SHA, C., HOU, J. a CUI, H. A Robust 2D Otsu's Thresholding Method in Image Segmentation. *Journal of Visual Communication and Image Representation*. 2016. DOI: 10.1016/j.jvcir.2016.10.013.
- [23] FISHER, R. et al. *Hypermedia Image Processing Reference (HIPR)* [<http://homepages.inf.ed.ac.uk/rbf/HIPR2/>]. Ongoing.
- [24] MALHI, A., GREWAL, R. a PANNU, H. Detection and diabetic retinopathy grading using digital retinal images. *International Journal of Intelligent Robotics and Applications*. 2023, sv. 7. DOI: 10.1007/s41315-022-00269-5.
- [25] LOTUFO, R. A., AUDIGIER, R., SAÚDE, A. V. a MACHADO, R. C. *Microscope Image Processing*. Second. 2023.
- [26] HALFAWY M. R., . H. J. Automated defect detection in sewer closed circuit television images using histograms of oriented gradients and support vector machine. *Automation in Construction*. 2014. DOI: 10.1016/j.autcon.2013.10.012.
- [27] HUSSAIN, S. ul. *Machine Learning Methods for Visual Object Detection*. Germany: Editions universitaires europeennes, 2012. ISBN 9783841790682, 3841790682.

- [28] DUNDERDALE, C., BRETTENNY, W., CLOHESSY, C. a DYK, E. E. van. Photovoltaic defect classification through thermal infrared imaging using a machine learning approach. *Progress in Photovoltaics: Research and Applications*. 2020. DOI: 10.1002/pip.3191.
- [29] LINDBERG, T. Scale invariant feature transform. *Scholarpedia*. 2012. DOI: 10.4249/scholarpedia.10491.
- [30] JOHNSTON, B., JONES, A. a KRUGER, C. *The Unsupervised Learning Workshop*. Packt Publishing, 2020.
- [31] LUN, H. et al. Machine-learning-based telemetry for monitoring long-haul transmission impairments: methodologies and challenges [Invited]. *Journal of Communications and Networking*. October 2021, sv. 13, č. 10. DOI: 10.1364/JOCN.426826.
- [32] LOH, W.-Y. Classification and regression trees. *WIREs Data Mining and Knowledge Discovery*. 2011. DOI: 10.1002/widm.8.
- [33] IBM. *What is a Decision Tree?* [<https://www.ibm.com/topics/decision-trees>]. 2024. Accessed: 2024-05-21.
- [34] PRAKASH, J. S. et al. Multi class Support Vector Machines classifier for machine vision application. In: IEEE. *2012 International Conference on Machine Vision and Image Processing (MVIP)*. 2012.
- [35] CHRISTMANN, A. a STEINWART, I. *Support Vector Machines*. 1st. New York, NY: Springer, 2008. Information Science and Statistics. ISBN 978-0-387-77242-4.
- [36] WONG, S., GATT, A., STAMATESCU, V. a MCDONNELL, M. Understanding data augmentation for classification: when to warp? In: IEEE. *2016 International Conference on Digital Image Computing: Techniques and Applications (DICTA)*. 2016. DOI: 10.1109/DICTA.2016.7797091.
- [37] XU, M., YOON, S., FUENTES, A. a PARK, D. S. A Comprehensive Survey of Image Augmentation Techniques for Deep Learning. *Pattern Recognition*. May 2023, sv. 137, č. 1. DOI: 10.1016/j.patcog.2023.109347.
- [38] TANIMURA, T. a HOSHIDA, T. Deep Learning Techniques for Optical Monitoring. In: LAU, A. P. T. a KHAN, F. N., ed. *Machine Learning for Future Fiber-Optic Communication Systems*. Academic Press, 2022. ISBN 9780323852272.

- [39] PAPERNOT, N., MCDANIEL, P., WU, X., JHA, S. a SWAMI, A. Distillation as a Defense to Adversarial Perturbations Against Deep Neural Networks. In: IEEE. *2016 IEEE Symposium on Security and Privacy (SP)*. 2016. DOI: 10.1109/SP.2016.41.
- [40] GOODFELLOW, I., BENGIO, Y. a COURVILLE, A. *Deep Learning*. MIT Press, 2016. ISBN 9780262035613.
- [41] BENGIO, Y. Learning deep architectures for AI. *Foundations and Trends R in Machine Learning*. 2009. DOI: 10.1561/2200000006.
- [42] KRIZHEVSKY, A., SUTSKEVER, I. a HINTON, G. Imagenet classification with deep convolutional neural networks. In: *Advances in Neural Information Processing Systems 25*. 2012. DOI: 10.1145/3065386.
- [43] TRUONG, D. *Data Science and Machine Learning for Non-Programmers: Using SAS Enterprise Miner*. USA: CRC Press, 2024. ISBN 9781003835615, 1003835619.
- [44] HOSSIN, M. a SULAIMAN, M. N. A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process (IJDKP)*. March 2015, sv. 5, č. 2. DOI: 10.5121/ijdkp.2015.5201.



## SEZNAM ZKRATEK A SYMBOLŮ

- AOI** Automatizovaná optická kontrola – Automated Optical Inspection
- CPU** Centrální procesorová jednotka – Central Processing Unit
- GPU** Grafický procesor – Graphics Processing Unit
- CCD** Elektronická součástka používaná pro snímání obrazové informace – Charge-Coupled Device
- ADC** Analogově-digitální převodník – Analog to Digital Converter
- CMOS** Technologie výroby integrovaných obvodů – Complementary Metal-Oxide-Semiconductor
- FOV** Zorné pole – Field Of View
- IR** Infrčervené světlo – Infrared
- UV** Ultrafialové světlo – Ultraviolet
- HOG** Histogram orientovaných gradientů – Histogram of Oriented Gradients
- SIFT** Škálově invariantní vlastnostní transformace – Scale Invariant Feature Transform
- SVM** Metoda podpůrných vektorů – Support Vector Machine
- DNN** Hluboké neuronové sítě – Deep Neural Networks
- MSE** Střední kvadratická chyba – Mean Squared Error
- ROC** Křivka kvality binárního klasifikátoru – Receiver Operating Characteristic
- AUC** Plocha pod křivkou – Area under the ROC Curve
- $R_s$  Prostorové rozlišení
- $N_f$  Počet pixelů přiřazené nejmenšímu prvku
- $S_f$  Velikost nejmenšího prvku
- $f'$  Ohnisková vzdálenost
- $a$  Vzdálenost objektu od objektivu
- $a'$  Vzdálenost obrazu od objektivu

$y$	Velikost objektu
$y'$	Velikost obrazu
$V_s$	Velikost senzoru
$V_p$	Velikost pixelu kamery

## SEZNAM OBRÁZKŮ

1	Ukázka robotické buňky . . . . .	19
2	Srovnání principů práce liniového a plošného skenování . . . . .	21
3	Princip činnosti plošného CCD snímače . . . . .	23
4	Zorné pole (FOV) . . . . .	25
5	Běžné formáty snímačů pro kamery strojového vidění . . . . .	25
6	Rozlišení obrazu, faktor měřítka a hustota pixelů . . . . .	26
7	Rozdíl ve snímání pomocí standardního, telecentrického a hypercentric- kého objektivu . . . . .	27
8	Znázornění montážního závitu, polohy snímače, mechanické zadní strany a zadní strany příruby . . . . .	31
9	Základní osvětlovací techniky používaná při návrhu řešení strojového vidění	33
10	Princip fungování předního osvětlení s plně jasným obrazovým polem . .	34
11	Komplementární barvy . . . . .	35
12	Schema kruhového osvětlovače a ukázka světla firmy SmartView . . . . .	36
13	Schema plošného osvětlovače a ukázka světla firmy SmartView . . . . .	37
14	Schema zadního osvětlovače a ukázka světla firmy SmartView . . . . .	37
15	Schema kopulovitého osvětlovače a ukázka světla firmy SmartView . . . .	38
16	Schema DOAL osvětlovače a ukázka světla firmy SmartView . . . . .	38
17	Speciální typy osvětlení: Čtvercový spojitý difúzní iluminátor (SCDI) a Multi-axiální osvětlení . . . . .	39
18	Schéma zpracování obrazu . . . . .	41
19	Binární obraz . . . . .	42
20	Histogram separace mezi dvěma třídami pixelů . . . . .	43
21	A: Strukturní prvek se vejde do obrazu, B: Strukturní prvek zasahuje (intersectuje) obraz, C: Strukturní prvek se ani nevejde, ani nezasáhne obraz . . . . .	44
22	Rozhodovací strom . . . . .	46
23	Strojové učení, neuronové sítě a hluboké neuronové sítě . . . . .	48
24	Přehled architektury DNN . . . . .	48
25	Matice záměn . . . . .	50
26	ROC (Receiver Operating Characteristic) křivka a AUC plocha . . . . .	51
27	Rozdělení na 2 částí (Metoda 1), rozměry jsou uvedeny v mm . . . . .	54
28	Rozdělení na 4 částí (Metoda 2), rozměry jsou uvedeny v mm . . . . .	54
29	Rozdělení na 6 částí (Metoda 3), rozměry jsou uvedeny v mm . . . . .	54

30	Rozdělení na 9 částí (Metoda 4), rozměry jsou uvedeny v mm . . . . .	54
31	Schéma a obrázek provedení experimentu s použitím plochého osvětlení, uvedené rozměry jsou v mm . . . . .	57
32	Schéma a obrázek provedení experimentu s použitím kupolového osvětlení, uvedené rozměry jsou v mm . . . . .	58
33	Výška všech komponent . . . . .	59
34	Výsledek osvětlení bílým plochým světlem . . . . .	61
35	Výsledek osvětlení červeným plochým světlem . . . . .	62
36	Výsledek osvětlení modrým kupolovým světlem . . . . .	62
37	Princip činnosti Cognex ViDi Suite . . . . .	65
38	Proces sběru dat . . . . .	66
39	Rozhraní softwaru Cognex ViDi Suite. . . . .	67
40	Speciální nástroj na označení vad . . . . .	67
41	Označování vady pomocí speciálních nástrojů . . . . .	68
42	Správný a vadný kus . . . . .	68
43	Nastavení klasifikace . . . . .	69
44	Výsledky klasifikace . . . . .	71
45	Přesnost klasifikačního modelu pomocí ROC křivky a AUC plochy . . . .	72

## SEZNAM TABULEK

1	Parametry kamery . . . . .	53
2	Parametry objektivu . . . . .	53
3	Výsledné rozlišení pro každou metodu rozdělení . . . . .	55
4	Parametry snímání pro ploché osvětlení . . . . .	57
5	Parametry snímání pro kupolové osvětlení . . . . .	58
6	Výška všech komponent . . . . .	58
7	Výsledný počet pořízených snímků . . . . .	66
8	Konfigurace počítače . . . . .	69
9	Výsledky klasifikace . . . . .	72



## SEZNAM PŘÍLOH

A	Příloha Cognex ViDi Suite .....	89
---	---------------------------------	----





## A Příloha Cognex ViDi Suite

*BP\_Tsarykau\_Matsvei\_prilohy.zip*