

UNIVERZITA PARDUBICE

Fakulta elektrotechniky a informatiky

BAKALÁŘSKÁ PRÁCE

2024

Jakub Graňák

Univerzita Pardubice  
Fakulta elektrotechniky a informatiky

Zpracování obrazu pro kontrolu kvality dveřního panelu  
Bakalářská práce

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

# ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Jakub Graňák**  
Osobní číslo: **I21042**  
Studijní program: **B0714A150008 Automatizace**  
Téma práce: **Zpracování obrazu pro kontrolu kvality dveřního panelu**  
Zadávací katedra: **Katedra řízení procesů**

## Zásady pro vypracování

Cílem práce je vytvořit a implementovat algoritmus pro kontrolu kvality dveřního panelu z obrazových dat. Algoritmus bude založen na detekci přítomnosti definovaných relevantních součástí na staticky uchyceném dílu dveřního panelu. V rámci teoretické části bakalářské práce bude kladen důraz na prostudování oblasti kontroly kvality ve výrobním průmyslu, s výrazným zaměřením na obrazovou analýzu a detekci složek výrobků prostřednictvím standardních technik zpracování obrazu a konvolučních neuronových sítí (CNN). V praktické části bude student navrhovat, vyvíjet a optimalizovat algoritmy pro obrazovou detekci a klasifikaci klíčových komponent dveřních panelů, a to s využitím jak standardních metod zpracování obrazu, tak CNN. Aplikovatelnost algoritmů bude demonstrována prostřednictvím implementace a otestování v kontextu konkrétní výrobní linky dveřních panelů s analýzou výsledků a jejich diskusí.

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

Seznam doporučené literatury:

AGGARWAL, Charu C. Neural networks and deep learning: a textbook. Cham, Switzerland: Springer, 2018. ISBN 978-3-319-94462-3.  
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 Zpracování obrazu pro kontrolu kvality dveřního panelu 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 10. 05. 2024

Jakub Graňák v.r.

## **PODĚKOVÁNÍ**

Tímto chci poděkovat Ing. Dominiku Štursovi za vedení práce a jeho cenné rady, panu Ing. Lukáši Potočnému za technickou podporu ve společnosti Forvia a Pavlu Strakošovi za pomoc s obrazovými snímky z výrobní linky. Rovněž děkuji rodině za trpělivost a podporu během tvorby práce a studia.

## **ANOTACE**

V této bakalářské práci je cílem vyvinout algoritmy pro zpracování obrazu za účelem kontroly kvality dílu dveřního panelu. V teoretické části bude popsána problematika kvality a důvody její kontroly se zaměřením na moderní technologie, jako je například kontrola kvality s využitím kamerových systémů. Bude uvedena problematika kontroly dveřního panelu, dále budou vytvořeny algoritmy pro kontrolu kvality i za využití konvolučních neuronových sítí. Na konci budou diskutovány výsledky těchto algoritmů.

## **KLÍČOVÁ SLOVA**

kvalita, neuronová síť, detekce, zpracování obrazu, kvalita v automobilovém průmyslu

## **TITLE**

Image processing for door panel quality control

## **ANNOTATION**

In this bachelor's thesis, the goal is to develop algorithms for image processing in order to check the quality of a door panel part. In the theoretical part, the issue of quality and the reasons for its control will be described. I will focus on modern technologies, such as quality control using camera systems. The issue of door panel control will be presented, and algorithms for quality control will also be created using convolutional neural networks. At the end, the results of these algorithms will be discussed.

## **KEYWORDS**

quality, neural network, detection, image processing, quality in the automotive industry

# OBSAH

SEZNAM ILUSTRACÍ A TABULEK.....	11
SEZNAM ZKRATEK A ZNAČEK .....	12
ÚVOD.....	13
1 KVALITA V AUTOMOBILOVÉM PRŮMYSLU .....	14
1.1 KONTROLA KVALITY .....	14
1.2 AUTOMOBILOVÝ PRŮMYSL.....	14
1.3 CÍL A VÝZNAM PRÁCE.....	15
2 KVALITÁŘSTVÍ.....	16
2.1 HISTORIE KONTROLY KVALITY .....	17
2.2 VÝZNAM KONTROLY KVALITY .....	18
2.3 TECHNOLOGICKÉ INOVACE.....	19
2.4 KAMEROVÁ KONTROLA .....	20
3 STROJOVÉ VIDĚNÍ.....	21
3.1 PŮVOD ZPRACOVÁNÍ OBRAZU .....	21
3.2 PRINCIPY STROJOVÉHO VIDĚNÍ.....	22
3.3 KAMEROVÉ SYSTÉMY .....	23
3.4 KLASICKÉ ZPŮSOBY ZPRACOVÁNÍ OBRAZU .....	25
3.4.1 PRAHOVÁNÍ.....	27
3.4.2 SEGMENTACE OBRAZU .....	27
3.4.3 DETEKCE HRAN .....	28
3.5 UŽITÍ TRADIČNÍCH METOD V PRŮMYSLU .....	28
4 NEURONOVÉ SÍTĚ .....	29
4.1 SKLADBA NEURONOVÝCH SÍTÍ .....	30
4.1.1 TRÉNOVÁNÍ NEURONOVÝCH SÍTÍ.....	32
4.2 KONVOLUČNÍ NEURONOVÉ SÍTĚ .....	33
4.3 VYUŽITÍ KONVOLUČNÍCH NEURONOVÝCH SÍTÍ.....	34
5 KONTROLA VE FIRMĚ FORVIA .....	35
5.1 KONTROLA KVALITY DVEŘNÍHO PANELU .....	35

5.2	STANICE FINÁLNÍ KONTROLY .....	37
5.3	STÁVAJÍCÍ PRŮBĚH KONTROLY .....	39
5.3.1	POPIS OK DÍLU .....	40
5.3.2	POPIS NOK DÍLU .....	42
5.4	CV-X SERIES .....	43
6	NÁVRH NOVÉHO ALGORITMU KONTROLY .....	45
6.1	POŽADAVKY NA ALGORITMUS.....	45
6.2	VYUŽITÍ KLASICKÝCH METOD .....	46
6.3	MOŽNOST VYUŽITÍ CNN .....	46
6.4	OČEKÁVANÉ VÝHODY CNN.....	48
7	METODY KONVENČNÍCH ALGORITMŮ .....	49
7.1	VÝBĚR REFERENČNÍHO KUSU A POZIC VÝSTŘÍŽKŮ .....	49
7.2	ALGORITMUS POČÍTÁNÍ BÍLÝCH PIXELŮ .....	50
7.3	ZKOUŠKA ALGORITMU POČÍTÁNÍ PIXELŮ .....	52
7.4	DETEKCE POMOCÍ NEJSVĚTLEJŠÍHO BODU.....	52
7.5	FUNKCE VZDÁLENOSTNÍHO ALGORITMU .....	53
7.6	TESTOVÁNÍ VZDÁLENOSTNÍHO ALGORITMU.....	54
7.7	VYHODNOCENÍ APLIKACE JEDNODUCHÝCH ALGORITMŮ.....	55
7.8	DETEKCE HRAN .....	56
7.9	ALGORITMUS DETEKCE HRAN.....	56
7.10	TESTOVÁNÍ ALGORITMU DETEKCE HRAN .....	58
7.11	VYHODNOCENÍ ALGORITMU DETEKCE HRAN .....	58
8	KONVOLUČNÍ NEURONOVÉ SÍTĚ .....	59
8.1	TRÉNOVÁNÍ NEURONOVÝCH SÍTÍ.....	60
8.2	TOPOLOGIE S TŘEMI PÁRY.....	62
8.3	VÝSLEDKY TOPOLOGIE TŘECH PÁRŮ.....	64
8.4	TOPOLOGIE S DVĚMA PÁRY .....	65
8.5	VÝSLEDKY TOPOLOGIE DVOU PÁRŮ .....	67

8.6	ZHODNOCENÍ APLIKACE NEURONOVÝCH SÍTÍ .....	69
	ZÁVĚR .....	70
9	SEZNAM PŘÍLOH.....	73

## SEZNAM ILUSTRACÍ A TABULEK

Obrázek 2.1 Vývoj jakosti v čase (Veber, 2011).....	17
Obrázek 2.2 Požadavky na výrobek (Veber, 2011).....	18
Obrázek 3.1 Obraz posílaný mezi USA a UK (Gonzalez, 2018). ....	21
Obrázek 3.2 Uspořádání systému strojového vidění (Havle, 2008). ....	22
Obrázek 3.3 Kamera KEYENCE (Vysokorychlostní kamera 16×, 0,47 megapixelu (černobílá), c2024).....	23
Obrázek 3.4 Blokové schéma kamerového senzoru (Havle, 2008).....	24
Obrázek 3.5 Klasické postupy při zpracování obrazu (Vlach, c2024b). ....	26
Obrázek 3.6. Konvenční přístup (Vlach, c2024a). ....	28
Obrázek 4.1 Schéma neuronu (Řeháček, c2024).....	31
Obrázek 4.2 Vícevrstvý perceptron (Řeháček, c2024).....	31
Obrázek 4.3 Princíp CNN (Reynolds, c2022). ....	33
Obrázek 4.4 Vyhodnocení pomocí CNN (Vlach, c2024a). ....	34
Obrázek 5.1 OK díl připravený na kontrolu .....	36
Obrázek 5.2 Detail místa pro zacvaknutí komponentu.....	37
Obrázek 5.3 Správně umístěných devět komponent.....	38
Obrázek 5.4 OK díl připravený ke kontrole - foceno kamerou na stanici.....	40
Obrázek 5.5 OK díl dveřního panelu. ....	41
Obrázek 5.6 NOK díl s chybějícími součástmi.....	42
Obrázek 5.7 Menu CV-X.....	43
Obrázek 5.8. Vyznačení místa komponentu .....	44
Obrázek 6.1 Světlý a tmavý obraz .....	47
Obrázek 7.1 Referenční kus OK1. ....	50
Obrázek 7.2 Vývojový diagram algoritmu počítání pixelů. ....	51
Obrázek 7.3 Vývojový diagram algoritmu porovnávání vzdáleností nejsv. bodů.....	54
Obrázek 7.4 Vývojový diagram algoritmu detekce hran.....	57
Obrázek 8.1 Topologie sítě s třemi páry.....	59
Obrázek 8.2 Topologie sítě s dvěma páry.....	60
Obrázek 8.3 Síť pro tři páry vrstev, kde $k=6$ , 12. trénování. ....	62
Obrázek 8.4 Síť pro tři páry vrstev, kde $k=10$ , 11. trénování. ....	63
Obrázek 8.5 3 páry - BOX graf minimální chyby pro každé $k$ .....	64
Obrázek 8.6 Confusion matrix pro 3 páry $k=14$ . ....	65
Obrázek 8.7 Síť pro dva páry vrstev, kde $k=4$ , 14. trénování.....	66
Obrázek 8.8 Síť pro dva páry vrstev, kde $k=16$ , 6. trénování.....	66
Obrázek 8.9 2 páry - BOX graf minimální chyby pro každé $k$ .....	67
Obrázek 8.10 Confusion matrix pro 2 páry $k=4$ . ....	68

## **SEZNAM ZKRATEK A ZNAČEK**

3D	třídimenzionální
2D	dvoudimenzionální
CNN	konvoluční neuronová síť
ME	manufacturing engineering – oddělení údržby strojů a správy budov
HMI	human machine interface – rozhraní člověk/stroj
TP	true positive – pravdivě pozitivní
FN	false negative – falešně negativní
FP	false positive – falešně pozitivní
TN	true negative – pravdivě negativní

## ÚVOD

V dnešní době, kdy se průmysl dynamicky rozvíjí, je kladen obzvláště velký důraz na kvalitu výrobků. Nicméně s rostoucími objemy výroby se kontrola kvality stále více přesouvá do oblasti strojové kontroly. Tím je možno vyřadit lidský faktor z procesu. Avšak někdy kvůli nedokonalým algoritmům pro kontrolu, nebo kvůli špatné aplikaci těchto algoritmů, může docházet, a také v praxi dochází, k chybné identifikaci výrobků a považovat tak vadný kus za dobrý a naopak.

Pozornost této práce bude v teoretické části věnována oblasti kvality ve výrobním průmyslu, kde se zaměří na obrazovou detekci a zpracování obrazu na poli kvality. Toto pole působnosti je moderní a je zaváděno do mnohých výrobních firem po celém světě, čímž se snižují náklady na pracovníky. Dále bude věnována konvolučním neuronovým sítím a jejich aplikaci při zpracování obrazu.

V praktické části bude proveden návrh standardního algoritmu pro zpracování obrazu a jeho využití při kontrole kvality dveřního panelu. Dále se vytvoří a aplikuje postup pro zpracování obrazu pomocí neuronové sítě. Poté se vyhodnotí účinnost algoritmů při kontrole kvality dveřního panelu.

Toto téma bakalářské práce bylo zvoleno, jelikož se pohybuji v prostředí automobilového průmyslu a zároveň studuji automatizaci. Dlouho jsem přemýšlel nad volbou tématu, které by pokrývalo současné trendy v obou oborech. Nakonec se tím tématem ukázalo být zpracování obrazu, jak klasicky, tak pomocí neuronových sítí a jeho využití při kontrole kvality.

# **1 KVALITA V AUTOMOBILOVÉM PRŮMYSLU**

V České republice, ale i v Evropské unii, je automobilový průmysl hybnou silou hospodářství. Kvůli tradici a schopnosti konkurence se v České republice nachází velká koncentrace výroby automobilů, a s tím spojeného výzkumu a designérství. Součástí každé prosperující firmy by měla být schopnost dodržovat co nejvyšší kvalitu, schopnost plnit požadavky zákazníka a dodržovat všechny legislativní předpisy a normy. Automobilový průmysl se nachází mezi obory, kde je nutné systematické zajištění kvality vyráběných součástí. K tomu je možno využít i moderní technologie jako jsou neuronové sítě (MM Průmyslové spektrum, 2020).

## **1.1 KONTROLA KVALITY**

V současnosti vzbuzuje pojem kvalita zájem každého podniku. Ovšem kvalitu jako takovou není možno správně definovat pouze jedinou definicí. Třeba taková japonská filozofie kvality definuje kvalitu jako nulovou chybovost. Kvalita je také něco, co pomáhá podnikům přitáhnout zákazníky. Na světě existuje několik norem zabývajících se problematikou kvality, např. ISO 9000. V širokém slova smyslu je kvalita výrobku nástroj, jak výrobek odlišit od konkurence a chránit ho tak před negativními důsledky konkurence (Sedláček, 2011).

## **1.2 AUTOMOBILOVÝ PRŮMYSL**

Automobilový průmysl je odvětví průmyslu, které se orientuje na vývoj, výrobu, marketing a prodej motorových vozidel. Toto odvětví zahrnuje širokou škálu subjektů. Od samotných výrobců motorových vozidel, až po jejich subdodavatele představuje automobilový průmysl rozsáhlý ekosystém. Automobilový průmysl se vyznačuje vysokou úrovní technického pokroku a inovací, což je dáno vysokými nároky na bezpečnost a kvalitu výrobků. Klíčovým prvkem v tomto poli jsou moderní metody řízení, neboť efektivní výrobní procesy a správné řízení kvality jsou nezbytné pro splnění komplexních standardů a norem, kterými je automobilový průmysl vázán.

Také konkurenční tlak hraje v automobilovém průmyslu významnou roli, a to zejména vzhledem k rostoucí poptávce po vozidlech, která splňují nejvyšší standardy v oblasti bezpečnosti, kvality a inovací. Automobilový průmysl se tak řadí mezi průkopníky v implementaci moderních obchodních a výrobních strategií (Automobilový průmysl (Automotive Industry), c2011-2016).

### **1.3 CÍL A VÝZNAM PRÁCE**

V této práci je cílem prozkoumat problematiku kvality ve výrobním průmyslu, nastínit důvody, proč se kontrola kvality využívá a jaké jsou její moderní prostředky, jakým je například využití strojového vidění. V praktické části je proveden návrh algoritmů pro zpracování obrazu, za účelem kontroly kvality dílu dveřního panelu, jež poskytla firma Forvia. Na tomto panelu bude detekována přítomnost a správnost umístění devíti komponentů. Na závěr práce je uvedeno vyhodnocení schopnosti algoritmů pro určení dobrého (OK), či vadného (NOK) kusu.

## 2 KVALITÁŘSTVÍ

Tato kapitola se zabývá komplexní problematikou spojenou s kvalitou výrobků, aby bylo lépe porozuměno historii kontroly kvality a nezbytnosti tohoto procesu ve výrobním prostředí. Budou zde nastíněny moderní metody a trendy na poli kvality, které slouží k zajištění a optimalizaci kvality v průmyslovém prostředí. Kvalita výrobků se stává v kontextu průmyslu klíčovým faktorem, který má zásadní vliv na celkovou spokojenost zákazníků a úspěch podniku jako celku na dnešním trhu. Tato kapitola nám umožní prozkoumat evoluci pohledu na kvalitu, od historických souvislostí po současné trendy, a vyzdvihnout významné faktory, které formují a ovlivňují oblast kontroly kvality ve světě průmyslu.

Existuje mnoho důvodů pro implementaci a zdůrazňování kvality ve výrobním prostředí, přičemž některé z nich jsou klíčové pro udržení konkurenceschopnosti a dosažení dlouhodobé úspěšnosti podniku. V dnešní dynamické obchodní krajině je schopnost nabídnout výrobky nejvyšší kvality zásadní pro zaujetí pozice na trhu a udržení kroku s konkurencí.

Dalším podstatným důvodem je snaha o zajištění bezpečnosti výrobku. Kromě toho hraje kvalita významnou roli v budování pověsti společnosti. Organizace, které se mohou pyšnit vysokou kvalitou svých výrobků, budují pozitivní vnímání a důvěru u svých zákazníků (Sedláček, 2011).

## 2.1 HISTORIE KONTROLY KVALITY

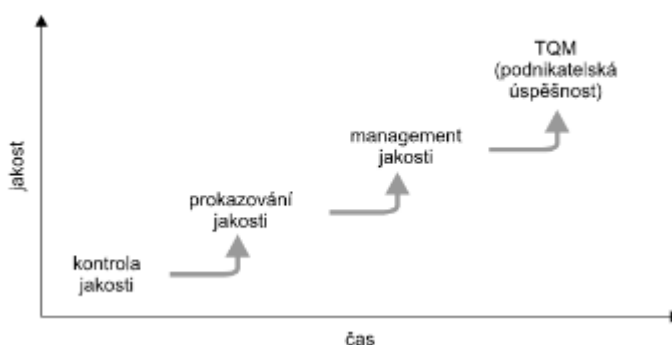
Od dob, kdy lidstvo začalo vytvářet ať už nástroje pro lov, obydlí nebo oděvy pro každodenní nošení, se lidé pak zajímali, zda jim tento výrobek přinesl takový užitek, jaký od něj očekávali. Již od dob Mezopotámie nalezneme texty, které se věnují kvalitě a postihům za její nedodržení.

Ve středověku přebíralo tuto roli cechovní uspořádání řemeslníků. Po staletí byl výrobce v kontaktu s výrobkem od počátku až do konce, takže mohl sám posuzovat správnost výrobku podle přání zákazníka. Avšak při nástupu manufaktur, za průmyslové revoluce, se tento princip změnil díky dělbě práce. Tak se vytratil i pocit odpovědnosti za výrobek a bylo třeba zavést průběžné zkoumání a vyhodnocování kvality.

Významný růst požadavku na kvalitu nastal během druhé světové války. Ta přinesla poptávku po kvalitním vojenském materiálu, a to ve velkém množství. Začala se provádět statistická vyhodnocení na naměřených vlastnostech dílů z výroby.

Po druhé světové válce se do úspěšnosti produktů začala podepisovat i touha po dobrém vzhledu výrobku, dobré výdrži i úspornosti výrobku.

Výsledkem tohoto vývoje byla v roce 1987 přijata řada norem ISO 9000 pro řízení jakosti (Veber, 2011).



Obrázek 2.1 Vývoj jakosti v čase (Veber, 2011).

## 2.2 VÝZNAM KONTROLY KVALITY

Jak uvádí (Veber, 2011), význam kontroly kvality je relativně prostý a pojí se s historií kontroly kvality. V knize je psáno, že s tím, jak postupně převyšovala nabídka nad poptávkou, se začala objevovat snaha výrobců o propagaci svých výrobků právě pomocí jejich kvality. Jako příklad je uveden přelom šedesátých a sedmdesátých let dvacátého století, kdy japonští výrobci televizorů začali kvůli vysoké jakosti jejich produktů vážně ohrožovat svoji světovou konkurenci.

Dále díky přílivu nových technologií a procesů výroby je zákazník staven do pozice, kdy může volit z více produktů a jakost se pro něj stává faktorem ovlivňujícím jeho volbu. Tedy oproti letům minulým není kvalita chápána jako výsada, ale jako standard, který musí dodržovat každá firma, chce-li mít naději na úspěch.

Dalším důvodem je, že nízká kvalita s sebou nese další náklady v podobě ceny přepracování nebo nákladů na likvidaci vadných či poškozených dílů.

Všechny tyto aspekty mají svůj významný vliv na kontrolu kvality ve výrobě a také přispívají k inovacím, jež zefektivňují prováděnou kontrolu.



Obrázek 2.2 Požadavky na výrobek (Veber, 2011).

## 2.3 TECHNOLOGICKÉ INOVACE

S rostoucími požadavky na efektivnější a přesnější výrobní procesy, rostou zároveň i požadavky na kvalitu nových výrobků.

Při kontrole kvality je funkce lidského oka a našeho okamžitého úsudku nenahraditelná. Ovšem v dnešním světě existuje mnoho výrobních procesů, které vybízejí k automatizaci kontrolních postupů. Může se jednat o automatizovanou kontrolu kvality pomocí kamerových systémů, 3D robotických skenerů a podobně. Takovýchto postupů bychom našli mnoho.

Integrace těchto postupů přímo do výrobního procesu je možná díky těmto moderním technologiím, které nám nezaručují pouze kvalitu, ale i schopnost sledovat celý průběh výroby a měření (Automatizace výroby a kontrola kvality, c2001-2024).

## 2.4 KAMEROVÁ KONTROLA

Kamerová kontrola nachází své uplatnění zejména tam, kde klasická měřidla čelí omezením, například v situacích, kde vysoká rychlost procesu nebo velký objem výroby komplikují jejich efektivní využití. V takových případech přichází na scénu kamerové systémy, které umožňují bezkontaktní měření a kontrolu kvality.

Jedním z klíčových faktorů, které podporují implementaci kamerových kontrol, je právě rychlost výrobního procesu. V dnešní době jsou kamerové systémy schopny se přizpůsobit tempu výrobní linky, což je zásadní vlastnost při sledování a kontrole kvality v dynamickém prostředí. Moderní technologie těmto systémům umožňují snímat a zpracovávat až stovky obrázků za sekundu. Právě toto je faktor ovlivňující efektivní monitorování.

Dalším důvodem pro zavedení kamerových kontrol je jejich bezkontaktní povaha. Tím se eliminuje potenciální ztráta času spojená s nutností manipulace s tradičními měřidly, a navíc kamerové systémy jsou schopny měřit i složitě tvarované díly pomocí softwaru na zpracování obrazu. Tato bezkontaktnost se osvědčuje zejména v odvětví potravinářství nebo v prostředí s vysokými teplotami, kde by byl kontakt s měřidly problematický nebo nebezpečný.

Strojové vidění, které je jádrem kamerových systémů, nabízí výjimečnou přesnost a nevyčerpává se, na rozdíl od člověka. Systém je schopen neustále vyhodnocovat kvalitu výrobků a zaznamenávat obrázky z průběhu kontroly. Tato schopnost umožňuje detailní analýzu a odhalování potenciálních nedostatků v procesu výroby, jako je opotřebení nástrojů (Kontrola kvality výroby: 5 předností kamerových systémů pro bezkontaktní měření, c2022).

### 3 STROJOVÉ VIDĚNÍ

Od sedmdesátých let minulého století, kdy počítače získaly potřebnou výpočetní kapacitu pro zpracování velkého objemu dat, jež představují data, která nesou informaci o obrazu, postupně vznikl obor počítačového vidění. Je to obor, který se zabývá zpracováním a vyhodnocováním obrazových dat, která nám poskytne kamera. Cílem počítačového vidění může být správa jakýchkoliv obrazových dat, ať už se jedná o dopravní situaci, či nějaký výrobní proces.

V dnešní době je strojové vidění považováno za prvek automatizace průmyslu. Je svázáno s klasickými úlohami spojenými s kontrolou procesů. Může se jednat o detekci vadných kusů, počítání výrobků v reálném čase či hledání defektů (Havle, 2008).

#### 3.1 PŮVOD ZPRACOVÁNÍ OBRAZU

Jednou z prvních aplikací zpracování obrazu se stalo z počátku 20. let 20. století odeslání snímků pro novinové listy podmořským kabelem mezi New Yorkem a Londýnem. Bylo využito speciální tiskové zařízení, které kódovalo obrázky pro kabelový přenos a následně je přijímač na druhé straně Atlantského oceánu rekonstruoval do původní podoby.

Takovéto zpracování obrázku se sice nedá nazývat digitálním, jelikož pro úpravu těchto obrázků nebylo užito počítače. Nicméně jde o první pokusy a případy zpracování obrazu (Gonzalez, 2018).



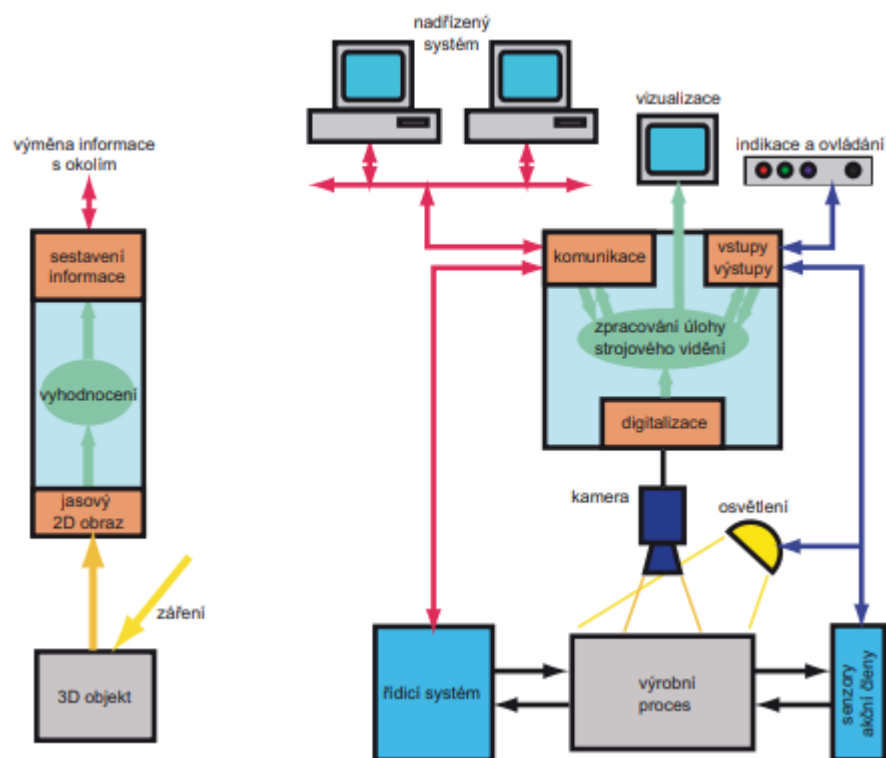
*Obrázek 3.1 Obraz posílaný mezi USA a UK (Gonzalez, 2018).*

### 3.2 PRINCIPY STROJOVÉHO VIDĚNÍ

Strojové vidění systematicky napodobuje funkci lidského oka, které zachycuje vizuální informace ze světa okolo nás. Podobně jako naše oči zachytí obraz objektu a předávají informace do mozku, tak i kamerový systém snímá obraz a předává tuto obrazovou informaci ke zpracování systému. V technickém kontextu je tento systém strojového vidění často chápán jako senzor, schopný vnímat a analyzovat vizuální data.

Pro získání obrazu ze snímaného objektu se používá většinou cizí zdroj záření, a objekt musí toto záření odrazit tak, aby vytvořil dvojrozměrný obraz na snímacím prvku senzoru. K tomu je nezbytné, aby odražené záření obsahovalo informace, které jsou potřebné pro daný proces. Tento postup vyžaduje správné ozáření objektu a jeho následné zachycení, což je klíčový krok pro získání správných a užitečných obrazových dat.

Získaný obraz je následně transformován do vhodné veličiny, která nese obsažené informace. Takovéto informace jsou přes vhodné rozhraní předávány do okolí, což může zahrnovat další fáze zpracování a interpretace v rámci celkového systému. Touto sérií kroků strojové vidění efektivně nahrazuje lidskou schopnost vnímání a analyzování vizuálních podnětů, což má značný význam zejména v oblasti průmyslové kontroly a automatizace (Havle, 2008).



Obrázek 3.2 Uspořádání systému strojového vidění (Havle, 2008).


### 3.3 KAMEROVÉ SYSTÉMY

Sledovaný objekt je ozářen z povětšinou externích ozařovacích prvků. Díky tomu lze zachytit 2D obraz vytvořený na snímacím prvku kamery. Měronosnými veličinami jsou, v kamerových systémech s polovodičovými snímacími prvky, proudy či náboje, které se vytvářejí v součástech kamer, které snímají obraz. Takovéto veličiny mohou nést informace třeba jen redukované na údaj o jasů dopadajícího světla, jak je tomu v případě černobílých kamer. Nebo jsou schopny nést informace i o barevném spektru, když se jedná o kamery schopné zachytit barevný obraz.

Ke zpracování takovýchto dat v reálném čase nejsou jiné možnosti než použití počítačů, které mají dostatečnou výpočetní kapacitu k analýze a zpracování obrazových dat. Proto je nutné měronosné veličiny převést do digitální formy, se kterou počítače pracují, aby s nimi mohl počítač manipulovat (Havle, 2008).



Obrázek 3.3 Kamera KEYENCE (Vysokorychlostní kamera 16×, 0,47 megapixelu (černobílá), c2024).



Obrázek 3.4 Blokové schéma kamerového senzoru (Havle, 2008).

### 3.4 KLASICKÉ ZPŮSOBY ZPRACOVÁNÍ OBRAZU

Obraz jako takový může být zadefinován jako funkce  $f(x, y)$ , kde  $x$  a  $y$  jsou prostorové souřadnice a amplituda  $f$ , v jakémkoliv páru souřadnic  $(x, y)$ , se nazývá intenzitou. Když všechny veličiny  $x$ ,  $y$  a hodnoty intenzity  $f$  jsou konečné a diskrétní veličiny, nazýváme takovýto obraz digitálním. Digitální obraz se tedy skládá z konečného počtu prvků, které mají svoji souřadnici a zároveň hodnotu (intenzitu). Pro takovéto prvky se v současné době nejčastěji používá označení pixel (Gonzalez, 2018).

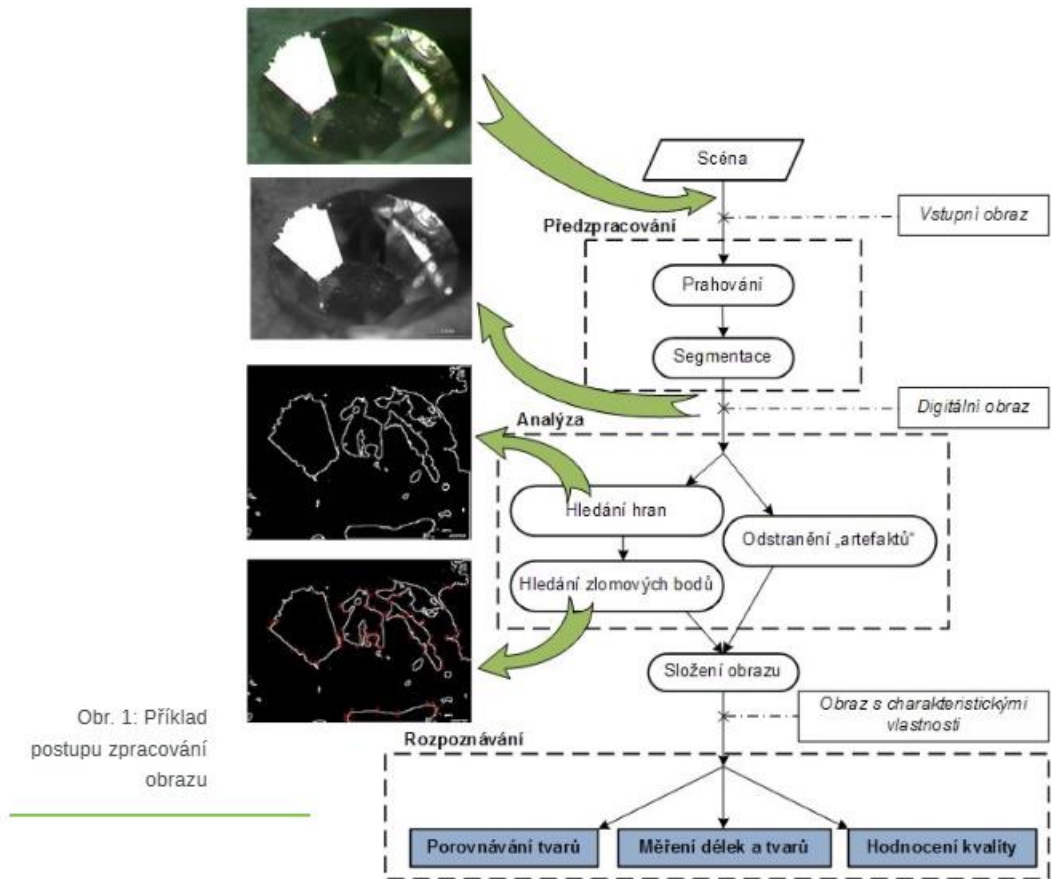
Zpracování obrazu při řešení úloh může být rozděleno do tří zásadních kroků, přičemž vstupní obraz prochází následujícími procesy a zpracováním.

První fází je předzpracování obrazu, kde se vstupní obraz vystavuje různým operacím s cílem zlepšit jeho vhodnost pro následující analýzu. Mezi klasické techniky předzpracování obrazu patří diskretizace, prahování a detekce hran. Diskretizace se zaměřuje na transformaci obrazu do diskrétní formy. Prahování na rozdělění pixelů do různých úrovní intenzity a detekce hran identifikuje přechody mezi různými oblastmi obrazu (Španěl, 2005).

Dalším krokem je segmentace, která se zabývá identifikací a oddělením různých oblastí a objektů ve zkoumaném obraze. Segmentace může být provedena na základě intenzity pixelů, barevnosti, nebo dalších různých charakteristik. Cílem je vytvořit strukturovanou reprezentaci vizuálních prvků v obraze, což usnadňuje následné zpracování (Španěl, 2005).

Posledním krokem je rozpoznávání a porozumění obrazu, kde jsou identifikovány a interpretovány objekty nebo tvary či vzory v obraze. Tato fáze může zahrnovat použití pokročilých algoritmů strojového učení a neuronových sítí. Cílem je převést vizuální informace na údaje, které lze reprezentovat, což umožňuje automatizovaným systémům porozumět obsahu obrazu (Vlach, c2024b).

V rámci každého z těchto kroků existuje široké spektrum metod, algoritmů a konkrétních postupů, které lze použít v různých programových prostředích. Je však klíčové si být vědom toho, že každá úloha v oblasti zpracování obrazu může vyžadovat individuální přístup a upravené postupy a algoritmy. Důležitým faktorem je také optimální nasvícení scény, což má velmi výrazný vliv na kvalitu a úspěšnost celého procesu (Vlach, c2024c).



Obr. 1: Příklad postupu zpracování obrazu

Obrázek 3.5 Klasické postupy při zpracování obrazu (Vlach, c2024b).

### 3.4.1 PRAHOVÁNÍ

Podle distribuce úrovní šedi ve zpracovávaném obraze lze určit práh pro převod obrazu do binární reprezentace, na objekt a na pozadí. Informaci o počtu pixelů, které mají určitou hodnotu, nese histogram. Jeho analýzou jsme schopni získat práh, respektive množinu prahů. Díky těmto prahům jsme pak schopni rozdělit obraz na oblasti.

Při základním prahování získáváme výše zmíněný binární obraz, obsahující jen 1 a 0. 1 symbolizuje objekt a 0 pozadí. Další zpracování zahrnuje snahu najít takové pixely, které reprezentují objekt a jsou ve shlucích.

Nevýhodou této techniky je, že histogramy neobsahují informaci o tom, kde se pixel nachází. Například obraz, jenž by byl tvořen náhodnými shluky černé a bílé, by měl stejný histogram jako obraz, který je utvořen dvěma obdélníky. Jedním barvy černé a druhým barvy bílé.

Modifikace tohoto algoritmu se nazývá polo-prahování. Při této metodě zůstávají hodnoty větší než práh a ostatní jsou nahrazeny 0 (Španěl, 2005).

### 3.4.2 SEGMENTACE OBRAZU

Segmentace obrazu představuje hlavní krok ve většině systémů pro zpracování obrazu, přičemž jejím primárním úkolem je oddělit jednotlivé objekty v obraze. Tato fáze je kritická pro úspěšné provádění následných operací, jako je rozpoznávání a klasifikace objektů. Výsledky segmentace poskytují důležité informace, které nacházejí uplatnění v různých oblastech, od počítačového vidění po průmyslovou automatizaci.

V průběhu let bylo vyvinuto a publikováno široké spektrum segmentačních metod, zahrnující jak jednoduché algoritmy, tak i ty velmi složité. Tyto metody mohou být obecné, schopné zpracovávat různorodé typy obrazů, nebo specializované, optimalizované pro specifické úlohy a podmínky, pro něž jsou určeny a na míru vytvořeny (Španěl, 2005).

### 3.4.3 DETEKCE HRAN

Jednou z nejvíce důležitých oblastí nižší úrovně zpracování obrazu je detekce hran, i když to je v současnosti v reálných podmínkách složitý problém. Hranám v obrazu rozumíme jako bodům, ve kterých se hodnota jasu mění. Když se uvažuje jako matematická funkce, má takováto hrana svoji velikost a směr. Takovéto změny a přerušení v jasnosti obrazu jsou jednou z těch nejzákladnějších charakteristik, jaké obraz může mít. Také naznačují prostorové umístění objektů v obraze. Ideální hrana by byla tvořena skokovou funkcí, nicméně ve skutečném prostředí je takováto změna v obraze postupná. Užívá se tedy šikmé funkce (Španěl, 2005).

## 3.5 UŽITÍ TRADIČNÍCH METOD V PRŮMYSLU

Za užití stávajících metod jsou vstupní obrazová data krokově zpracovávána. Tyto kroky vyhodnocují obraz, který jim byl poskytnut. Postupně musí nalézt všechny zkoumané vlastnosti, jež jsou vyžadovány. Takovéto vlastnosti se dále klasifikují. Po klasifikaci přichází rozdělení na dobrý OK, či špatný NOK kus. Nezřídka se stává, že při změně vyráběného dílu, či procesu, jímž je tento díl vyráběn, vyplývá na povrch nutnost provést nové nastavení celého řetězce programového řešení.

Z takových závěrů lze usoudit, že konvenční metody přístupu k inspekci za užití strojového vidění nejsou schopny stabilně analyzovat nepravidelné snímky, kde nejsou či nemohou být vady pevně definovány. Na rozdíl od stávajících algoritmů lze využít metod tzv. hlubokého učení, anglicky označovaného jako „Deep Learning“. Tento postup pomocí umělých neuronových sítí umožňuje obecnější přístup. Takovouto síť je ale nutno nejdříve správně natrénovat tak, aby byla schopná správně rozpoznat vadné či správné kusy. Trénování zabere čas a je tu větší množství přípravné práce, než za užití stávajících algoritmů (Vlach, c2024a).



Obrázek 3.6. Konvenční přístup (Vlach, c2024a).

## 4 NEURONOVÉ SÍTĚ

Neuronová síť představuje inovativní algoritmus, který čerpá inspiraci z fungování lidského mozku. Struktura mozku je složena ze vzájemně propojených buněk, známých jako neurony. A právě tato organická architektura poskytuje jakousi předlohu pro vytvoření umělých neuronových sítí. Hlavním prvkem této technologie je schopnost adaptace a učení, což ji činí výjimečně schopným nástrojem pro analýzu a interpretaci dat z široké škály oblastí.

Inspirována lidským myšlením, dokáže neuronová síť extrahovat pravidla a vzorce z rozsáhlých souborů dat, které jí poskytneme. Tato schopnost učení a analýzy umožňuje síti dále zdokonalovat svoje schopnosti.

V oblasti kontroly kvality má neuronová síť obzvláště výrazný dopad. Je schopná identifikovat a klasifikovat složité vzory v obrazech a datech, čímž umožňuje automatizaci procesů kontroly kvality s vysokou přesností. Kromě průmyslu nachází využití i v medicíně, bankovníctví, předpovědi různých jevů a v odhadu stability dynamických energetických systémů.

V medicíně může neuronová síť pomoci při diagnostice a prognóze onemocnění, v bankovníctví při detekci podvodných transakcí, a ve sledování dynamiky energetických systémů při zajištění stabilní dodávky elektřiny. Její univerzálnost a schopnost adaptace činí neuronovou síť neocenitelným nástrojem pro využití v mnohých odvětvích (IT Systems, 2014).

## 4.1 SKLADBA NEURONOVÝCH SÍTÍ

Náš lidský neuron je základním stavebním kamenem mozku, umělý neuron je také základem umělé neuronové sítě. Umělým neuronem se dá vyrozumět algoritmický procesor. Takovýto algoritmický procesor načítá vstupní signály a vzhledem k nim generuje výstupní signál. Neuronové sítě mají snahu najít vztah mezi vstupními veličinami a veličinami výstupními, které mají svoji identifikační nálepku.

Aby bylo dosaženo učení, software načítá tréninková data a podle nich se snaží najít vztah mezi vstupními a výstupními veličinami. Takovýto vztah pomůže síti dále určovat a rozlišovat data bez vnějšího zásahu.

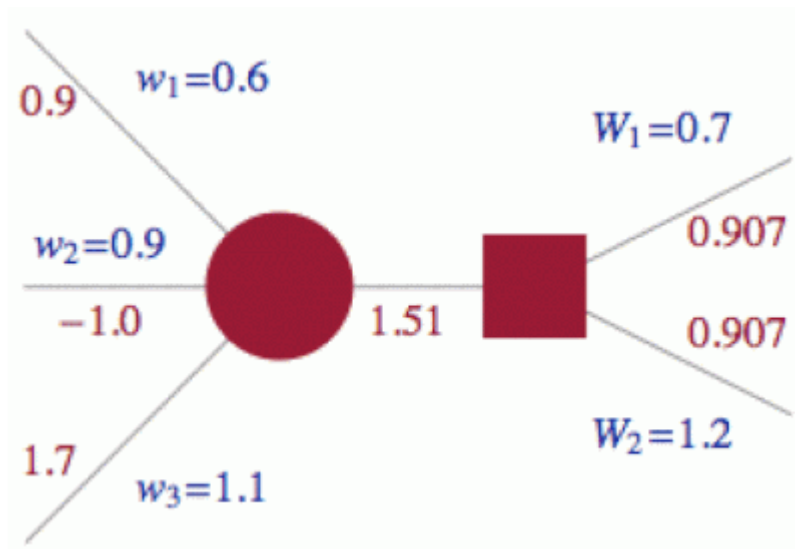
Obvykle jsou sítě složeny ze vstupních neuronů, z vrstev skrytých neuronů a poté z výstupní vrstvy. Časté rozdělení je takové, že každý neuron předchozí vrstvy je spojen s každým neuronem další vrstvy.

Princip fungování takovéto sítě je pak relativně snadno pochopitelný. Vstupní neurony obdrží vstupní data a poté vyšlou numerické signály dále do sítě, které se v síti podobným způsobem upravují a poté, co se dostanou k výstupním neuronům, je odečtena hodnota výstupního signálu.

Neurony tedy přijmou signály, jež přichází z jejich předchůdců a dají jim nějakou váhu, sečtou je a aplikují na nich nelineární, tzv. aktivační funkci.

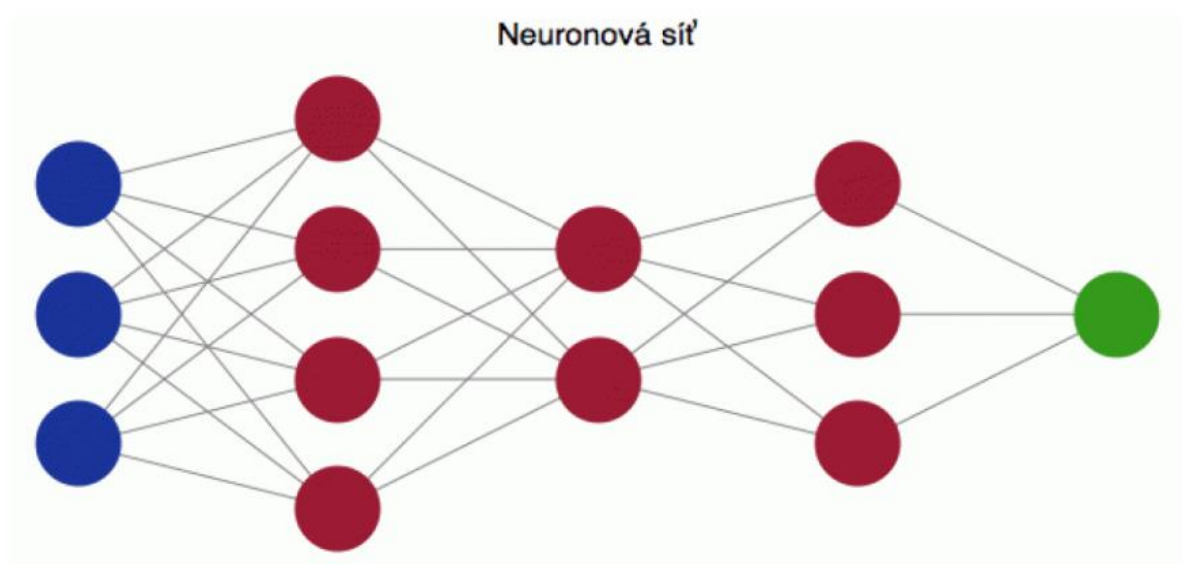
Na níže uvedeném obrázku 4.1 je znázorněna funkce neuronu. Neuron je zde rozdělen na kolečko, jež představuje součet, a čtvereček, který reprezentuje násobení sečtených vážených hodnot.

Na obrázku 4.1 jsou malými písmeny  $w_1$ ,  $w_2$  a  $w_3$  a velkými  $W_1$  a  $W_2$  naznačeny váhy, které jsou ovšem pohyblivé. Jako aktivační funkce byl vybrán  $\tanh$  (hyperbolický tangens). Je nutno poznamenat, že tato funkce se v průběhu výpočtu nemění (Řeháček, c2024).



Obrázek 4.1 Schéma neuronu (Řeháček, c2024).

Jak je známo, hlavním stavebním kamenem neuronové sítě je jeden neuron. Perceptronem pak lze nazvat algoritmus využívající právě jeden takový neuron. Když spojíme více perceptronů, získáváme tzv. vícevrstvý perceptron. Vícevrstvý perceptron lze jinými slovy nazvat jako dopřednou neuronovou síť, jež má vstupní, skryté a výstupní vrstvy (Pilát, b. r. b).



Obrázek 4.2 Vícevrstvý perceptron (Řeháček, c2024).

### 4.1.1 TRÉNOVÁNÍ NEURONOVÝCH SÍTÍ

Asi nejdůležitější částí fungování neuronových sítí je schopnost měnit váhy použité v síti během procesu učení. Označme očekávané výstupy jako  $y$  a výstupy ze sítě jako  $y'(w)$ , jelikož výstupy jsou funkcí vah  $w$ . Pro natrénování neuronové sítě je zapotřebí několik desítek až stovek opakování cyklu, než se podaří synchronizovat očekávaný výstup s tím skutečným. Chybovou funkci pro váhy  $w$  si definujeme jako rovnicí 4.1.

$$\text{error}(w) = \sum |y - y'(w)| \quad (4.1)$$

Další postup se řeší jako optimalizační úloha. Snažíme se najít hodnoty  $w$  tak, aby chybová funkce byla co nejmenší. Je tedy zapotřebí znát gradient této funkce, musíme vědět, jestli chyba roste nebo klesá v závislosti na užitých váze. Formulováno matematicky, je nutno znát parciální derivaci  $\text{error}(w)$ , která reprezentuje chybovou funkci, vzhledem k nastaveným vahám  $w$ . Toto jde relativně správně odhadnout pro váhy v poslední vrstvě sítě, kde nejsou jiné neurony umístěné za ní. V tuto chvíli je možno matematicky určit, jak se chyba zachová při změně vah. V okamžiku, kdy jsou určeny váhy poslední vrstvy, se přechází k vrstvě předposlední. Nyní se derivuje složená funkce, jelikož chyba z předposlední vrstvy vzniká i za přispění chyby vrstvy poslední. Takto se postupuje od poslední vrstvy k té první. Tento proces se nazývá zpětná propagace (back propagation). Dnes však tuto činnost vykonávají specializované knihovny, takže uživatel se může orientovat pouze na praktickou aplikaci (Řeháček, c2024).

## 4.2 KONVOLUČNÍ NEURONOVÉ SÍŤ

Jedním s častých úkolů, které jsou neuronovým sítím zadávány, je zpracování obrazu. Poslední dobou v tomto směru došlo k velkým pokrokům.

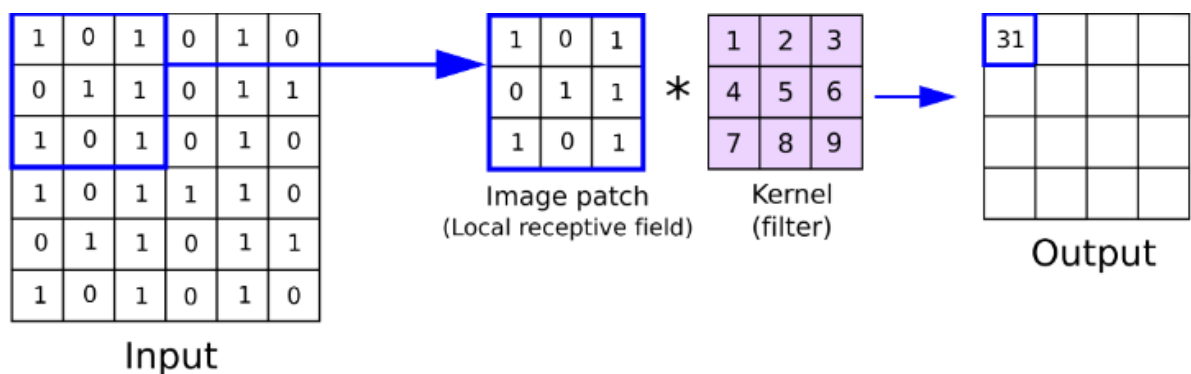
Největší překážkou spojenou se zpracováváním obrazu pomocí neuronových sítí je velikost obrázku. Takové obrázky mohou mít rozměry větší než 100 x 100 pixelů. Když se jedná o barevný obraz, každý pixel je sestaven z 3 barevných kanálů. Pro plně propojenou síť je to enormní počet hodnot ke zpracování.

Proto se při zpracovávání obrazu užívá CNN (konvoluční neuronové síť). CNN fungují tak, že zkoumají postupně malé části obrazu, například o velikosti 3x3 pixely a na tuto oblast aplikují stále stejné operace. Operace je aplikována postupně na všechna místa na obrázku. Délka kroku, se kterým se tato operace pohybuje, se nazývá stride.

Takových konvolučních vrstev obsahuje síť několik, to dovoluje zpracovávat obraz pomocí několika konvolucí záraz. Výsledkem je obrázek s podobnou velikostí jako originál na vstupu, nicméně má větší počet kanálů. Kdybychom tedy užívali jen konvolučních vrstev, dostávali bychom obrázky se stejnou velikostí.

V CNN se využívá střídajících se konvolučních a tzv. pooling vrstev. Pooling vrstva se použije podobně jako konvoluční vrstva na oblast obrazu, ale vrátí z ní maximum.


Konvoluční síť by se při zobrazení aktivace neuronů chovaly jako detektory hran v případě prvních vrstev, v pokročilejších vrstvách jsou pak jednotlivé neurony schopny pracovat jako detektory objektů (Pilát, b. r. a).



Obrázek 4.3 Prinicíp CNN (Reynolds, c2022).

### 4.3 VYUŽITÍ KONVOLUČNÍCH NEURONOVÝCH SÍTÍ

Poté, co neuronová síť projde učením, lze s její pomocí začít rozpoznávat vadné a správné kusy. A to i tam, kde by použití tradičních způsobů vyhodnocování kvality bylo extrémně obtížné aplikovat. Řešení takového problému lze rozdělit do několika fází. První fází je získání sady obrázků, následně je označíme na OK a NOK. Rozdělíme je na trénovací a testovací sadu, s trénovací sadou poté učíme neuronovou síť. Následně na testovací sadě zkusíme funkčnost CNN (Vlach, c2024a).



Obrázek 4.4 Vyhodnocení pomocí CNN (Vlach, c2024a).

## **5 KONTROLA VE FIRMĚ FORVIA**

Ve společnosti Forvia, i v pro tuto práci zvoleném závodě Forvia Faurecia Interiors Pardubice, je řízení kontroly kvality založeno na interních směrnících s důrazem na ochranu zájmů zákazníka. Tyto směrnice poskytují podrobný návod a postupy pro provádění efektivních úkonů v oblasti kontroly kvality s cílem zajištění vysoké úrovně jakosti. Některé z těchto kontrol jsou prováděny pověřenými pracovníky.

V zájmu dále optimalizovat a urychlit kontrolní procesy a zajistit co nejvyšší přesnost a nulovou chybovost jsou rovněž nasazovány moderní technologické prostředky. Mezi ně se řadí i kamerové systémy, které přinášejí další úroveň preciznosti do kontroly kvality. Kamerové systémy umožňují detailní monitorování výrobních procesů a identifikaci potenciálních nesrovnalostí či vad, což přispívá k dosažení požadované úrovně jakosti a zvyšuje celkovou spolehlivost vyráběných komponentů.

Celý proces kontroly kvality probíhá od úplného zrodu výrobku. Od úvodní kontroly ihned po vylisování, přes dílčí kontroly při ořezávání či skládání výrobku, až po finální inspekci se sleduje správnost provedení úprav a zhotovení výrobku.

### **5.1 KONTROLA KVALITY DVEŘNÍHO PANELU**

Po vylisování prochází díl vizuální kontrolou, kde jsou hledány jakékoliv případné nedostatky, které by mohly ovlivnit pevnost, použitelnost nebo estetiku tohoto panelu. Poté díl podstupuje úkony zmíněné výše, tedy prochází pečlivou kontrolou podle vnitřních směrníc, až se dostane na stanici finální inspekce, nebo jinými slovy finální kontroly.

Ve stanici finální kontroly je díl uchycen do držáku, je na něj umístěno 9 komponentů a následně určený pracovník spustí proces kamerové kontroly.

Na ní se zkontroluje, zda je všech 9 komponentů správně umístěno a ani mezi nimi nebyl žádný vadný kus, jenž by byl instalován na dveřní panel.



Obrázek 5.1 OK díl připravený na kontrolu


## 5.2 STANICE FINÁLNÍ KONTROLY

Stanice finální kontroly představuje poslední fázi výrobního procesu, umístěnou na konci výrobní linky. Po průchodu touto stanicí je výrobek deklarován jako bezvadný a vhodný pro použití dle přání zákazníka. Úkolem této stanice je důkladně, a hlavně správně ověřit, zda je výrobek v naprostém pořádku a zda v průběhu výrobních operací nedošlo k žádnému poškození, jež by mohlo vést k problémům, nebo až k případným reklamám ze strany zákazníka. Vzhledem k tomu, že i drobné odřeninby by mohly představovat významný estetický problém, je nezbytné, aby pracovník provedl pečlivou vizuální kontrolu celého dílu před umístěním dílu do stroje.

Po vizuální prohlídce je výrobek pevně uchycen do „holderu“ tedy do držáku, a to takovým způsobem, který brání jakémukoliv pohybu v držáku. Takovýto pohyb by znamenal vážné riziko špatného vyhodnocení pomocí kamery. Následuje umístění devíti komponentů na dveřní panel do předem vymezených pozic. Jakmile jsou komponenty zacvaknuty na svá místa, není možné s nimi dále manipulovat, aniž by hrozilo poškození dílu dveřního panelu. Tímto způsobem je zajištěno, že výsledný výrobek splňuje nejen estetické standardy, ale i požadavky na celistvost. Provedením všech těchto úkonů je zajištěna potřebná kvalita dílu. Na obrázku 5.3 je možno vidět správně umístěných devět komponentů do dveřního panelu. Pro lepší přehlednost jsou pozice těchto komponentů zvýrazněny červeným ohraničením.



Obrázek 5.2 Detail místa pro zacvaknutí komponentu



Obrázek 5.3 Správně umístěných devět komponent.

### 5.3 STÁVAJÍCÍ PRŮBĚH KONTROLY

Jak je naznačeno v textu dříve, konkrétně v podkapitolách 5.1 a 5.2, nejdříve se provádí vizuální kontrola za pomoci zraku pracovníka. Poté jsou umístěny komponenty a je spuštěn program na detekci komponentů.

Nevýhodou tohoto procesu je fakt, že kamerový systém sice snímá celý díl, ale vyhodnocováno je pouze správné umístění komponentů. Tudiž je stále potřeba spoléhat na úsudek pracovníka. Ve stávajícím průběhu kontroly se někdy objevují problémy s nasvícením scény. Díl je sice nasvícen zářivkou, ale kvůli vnějším světelným podmínkám, zejména díky pronikajícímu slunečnímu svitu, se může stát, že kamerový systém špatně vyhodnotí OK kus za NOK kus právě kvůli nevhodným světelným podmínkám. Tato záměna probíhá zejména v letních měsících, kdy se může poměrně rychle měnit počasí a prudký sluneční svit střídá zatažená obloha. Při změnách osvětlení je velmi často nutno zkalibrovat průběh vyhodnocení, jelikož v tu chvíli je výrobní linka mimo provoz.

Je možno dedukovat, že při rychle střídajících se světelných podmínkách je nutno provádět kalibrace velmi často, což zabírá hodně času specialistům ME (Manufacturing Engineering) pověřeným k těmto úkonům.

Obrázek 5.4 ukazuje správně umístěný díl pohledem kamery. Je možno vidět velký kontrast mezi umístěnými komponenty a černým dílem. Problém nastává v případě odlesků od stolu, nebo zvýšenou či sníženou světlostí bílých komponentů, při velké či naopak nízké intenzitě dopadajícího světla zvenčí.




*Obrázek 5.4 OK díl připravený ke kontrole - foceno kamerou na stanici.*

### **5.3.1 POPIS OK DÍLU**

OK dílem je myšlen díl, který bez problémů prošel veškerými fázemi kontroly a splňuje požadavky zadané zákazníkem. Na takovémto dílu již není třeba provádět opravné práce, tzv. rework, či ho vyřazovat jako úplně vadný díl neschopný dalšího použití.

Z pohledu této práce to je takový díl, který obsahuje všech devět komponentů, které jsou správně umístěny.

Není bráno v potaz případné špatné umístění dílu do držáku pracovníkem, jelikož tato práce se nevěnuje metodice práce na stanovišti finální kontroly. Bude se tedy uvažovat vždy správné umístění do držáku.



*Obrázek 5.5 OK díl dveřního panelu.*

### 5.3.2 POPIS NOK DÍLU

NOK dílem je myšlen takový díl, který neprošel veškerými fázemi kontroly a nesplňuje požadavky zadané zákazníkem. Řešením výskytu takového dílu je možný „rework“, například doplnění chybějící součásti. Nicméně, vada může být někdy fatálního charakteru a díl se pak vyřazuje jako vadný.

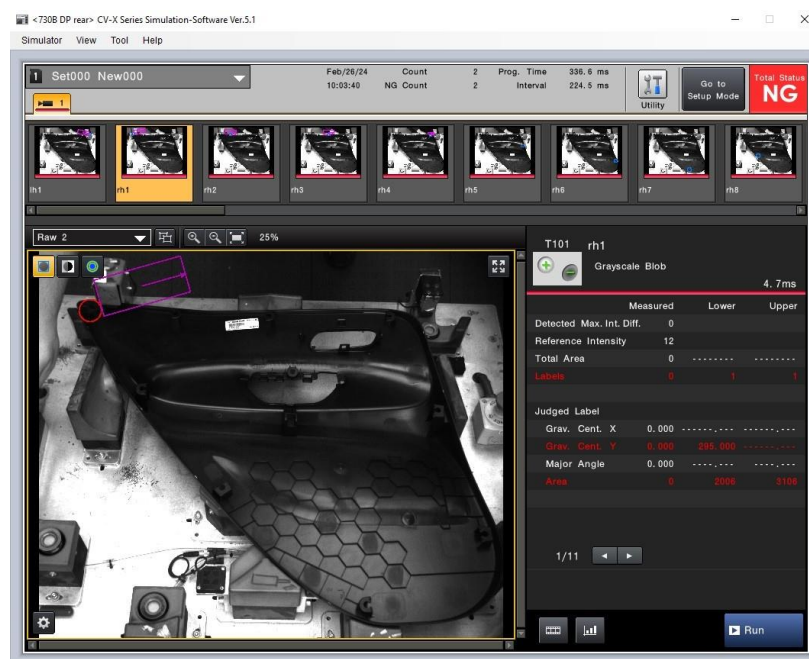
V této práci bude za NOK díl považován díl takový, kterému bude chybět jedna či více komponentů, nebo tyto komponenty budou špatně připevněny.



*Obrázek 5.6 NOK díl s chybějícími součástmi.*

## 5.4 CV-X SERIES

V současné době se pro úpravu vyhodnocování fotografií z finální kontroly využívá systému CV-X Series od firmy Keyence. V tomto prostředí je algoritmus nakonfigurován tak, aby porovnával nový díl s referenčním. Program porovnává jednotlivé výstřižky z míst umístění komponentu s referenčním OK kusem. Od určité hranice podobnosti je daný výstřižek prohlášený za OK. Celkové potvrzení kvality dílu nastává, pokud všech devět výstřižků dosáhne hranice podobnosti a odpovídá referenčnímu modelu. V takovém případě se na obrazovce Human Machine Interface (HMI) zobrazí potvrzení pro pracovníka, indikující, že díl splňuje stanovené normy a může být bezpečně odebrán z výrobní linky.



Obrázek 5.7 Menu CV-X



Obrázek 5.8. Vyznačení místa komponentu

## **6 NÁVRH NOVÉHO ALGORITMU KONTROLY**

Tato část bakalářské práce se zabývá problematikou návrhu nových algoritmů pro stanici finální kontroly. Samotný návrh a vývoj těchto algoritmů je spojen s problémy, které mohou nastat při kontrole dílu. Tyto jevy jsou popsány v podkapitole 6.1. Návrh také musí reflektovat potřeby a požadavky firmy, jako je například rychlost vyhodnocení, jelikož algoritmus, který by třeba danou fotografii dílu vyhodnocoval déle jak 10 sekund, by byl z hlediska efektivity práce zcela nepotřebný.

### **6.1 POŽADAVKY NA ALGORITMUS**

Návrh algoritmu pro vyhodnocení by měl ve své podstatě odrážet podstatu pracoviště, to je tedy vyhodnotit správně OK nebo NOK díl s maximální spolehlivostí.

V průběhu kontroly algoritmus pracuje s obrazovými daty, které byly nasnímány kamerou. Tato data jsou pro účely této práce nashromážděna v osobním počítači z důvodu pokračující výroby na stanici finální kontroly a na celé lince.

Hlavním požadavkem na vyvíjený algoritmus je schopnost správně vyhodnotit OK nebo NOK díl. V rámci tohoto bodu je klíčová schopnost rozpoznat i jen velmi málo posunutý komponent, jenž se umísťuje na dveřní panel. Toto by se mohlo dále jevit jako hlavní problém vyvíjeného programu. Ten by sice detekoval součást, která by byla umístěna v okolí místa určení, jenže už by dále nereflektoval skutečnost, že tato součást není na svém místě. NOK díl by byl prohlášen za OK, a to je v kontextu výrobního průmyslu, a i obecně zcela nepřijatelné.

Další vlastností, která by byla velmi užitečná pro toto pracoviště, je adaptabilita na různé světelné podmínky. Tedy schopnost nového programu správně vyhodnotit díl, i když se mění okolní osvětlení. Jak je zmíněno v popisu stanice finální kontroly, současný program má občasné problémy se světelnými podmínkami. Je vhodné zohlednit i tento požadavek.

## 6.2 VYUŽITÍ KLASICKÝCH METOD

Při vytváření algoritmu pro detekci objektů na základě porovnávání dvou obrázků, je možné uplatnit klasické metody bez nutnosti použití konvolučních neuronových sítí (CNN). Tento algoritmus bude systematicky prohledávat oblasti na snímku dílu dveřního panelu, kde by se měly nacházet správně umístěné součásti. V souladu s požadavky v kapitole 6.1 je kladen důraz na schopnost algoritmu identifikovat i malé odchylky od očekávané polohy komponentů.

Program využije výstřižky z původního snímku, které budou získány z předem určených pozic, jež jsou vyhrazeny pro umístění komponentů na dveřní panel. Tyto výstřižky budou dále porovnávány s odpovídajícími výstřižky z referenčních „OK“ kusů, které jsou využity jako vzor pro správné umístění komponent.

Proces porovnání výstřižků zahrnuje analýzu jejich podobnosti a identifikaci případných odchylek. Klíčovou vlastností je pak míra podobnosti, která bude určovat, zda je díl správně osazen, a jestli je vhodný pro další zpracování. Čím vyšší podobnost výstřižků, tím pravděpodobnější je, že se jedná o správně osazený díl.

Využití klasických metod v tomto směru umožní efektivní a účinnou implementaci algoritmu, který je schopen robustně detekovat a identifikovat komponenty na dveřním panelu. Důkladné vyhodnocení podobnosti výstřižků a adaptabilita algoritmu na různé podmínky osvětlení jsou klíčovými aspekty, které povedou k spolehlivým výsledkům v průběhu finální kontroly.

## 6.3 MOŽNOST VYUŽITÍ CNN


Pro detekci objektů na dveřním panelu lze využít konvoluční neuronové sítě. Jedná se o velmi moderní a efektivní přístup, v současné době často využívaný při zpracování obrazových dat. Tato síť bude sloužit k systematickému prohledávání celého obrazu dveřního panelu s cílem identifikovat správně umístěné komponenty. Stejně jako u stávajícího algoritmu budou důležité požadavky na schopnost detekovat i malé odchylky od předepsané polohy komponenty na dveřním panelu.

CNN bude trénována na vzorových fotografiích „OK“ kusů. Tyto fotografie budou upravovány prostřednictvím programů tak, aby simulovaly měnící se světelné podmínky. Tím

bude zajištěno, že síť bude odolná vůči různým úrovním osvětlení a schopna detekovat objekty i za proměnlivých světelných podmínek.

Po tréninku se využije validačního datasetu fotografií, jenž umožní zkoumat schopnost sítě rozpoznat vadné a správné kusy. Během tohoto kroku se analyzují výsledky a síť se nastaví tak, aby dosáhla co nejlepších výsledků. Tato validace bude hrát významnou roli v ověřování, zda je neuronová síť schopna spolehlivě rozpoznávat a vyhodnocovat stav dveřního panelu.

Jak se píše v teoretické části práce, výhodou použití CNN je schopnost automatického extrahování vlastností z obrazových dat, což umožňuje efektivní detekci a identifikaci objektů. Trénink na různých podmínkách osvětlení zvyšuje robustnost sítě a zajišťuje, že bude schopna pracovat v reálných podmínkách výrobní linky. Celkově lze očekávat, že CNN přinese významné vylepšení v přesnosti a spolehlivosti detekce komponentů na dveřním panelu ve srovnání se stávajícím algoritmem, a to zejména v oblasti měnících se světelných podmínek.



*Obrázek 6.1 Světlý a tmavý obraz*

Obrázek 6.1 nám poskytuje přímé porovnání dvou dveřních panelů, z nichž ten vlevo je výrazně lépe osvětlený než jeho protějšek napravo. Tato odlišnost v osvětlení má dobře zřetelný vliv na viditelnost bílých komponent, které jsou na panelu umístěny. Při povrchovém prozkoumání dílu nalevo lze rozeznat jeho povrchové detaily s větší jasností a ostrostí ve srovnání s dílem napravo.

Výhody lepšího osvětlení na levém panelu jsou patrné ve zvýšené viditelnosti komponentů. Povrchové detaily jsou lépe viditelné, což přispívá k celkové kvalitě vizuálního hodnocení. Prostředí stanice však vždy nezaručuje dobré světelné podmínky, proto bude síť trénována i pro neoptimální podmínky.

Nicméně, je důležité dodržovat a externě zajistit optimální úroveň osvětlení, aby nedošlo k nežádoucím odleskům od povrchu stolu, což by ovlivnilo obraz natolik, že by byl zcela nepoužitelný pro následné vyhodnocení. Touto situací se ale práce nezabývá a je předpokládáno, že nebude docházet k odleskům od stolu znemožňujícím práci s obrazem.

## **6.4 OČEKÁVANÉ VÝHODY CNN**

Od konvoluční neuronové sítě se očekávají výrazné výhody oproti klasickým algoritmům při detekci objektů ve změněných světelných podmínkách a identifikaci větších oděrků na díle. Jejich schopnost automatické extrakce důležitých vlastností z obrazových dat umožňuje efektivní detekci objektů a adaptaci k různým úrovním abstrakce v obrazech. Tato adaptabilita se projevuje zejména v odolnosti vůči proměnlivým světelným podmínkám, což je klíčové pro průmyslové prostředí s různými osvětlovacími podmínkami v průběhu dne.

Od sítě je předpokládána schopnost učit se ze změn osvětlení během tréninku, což zajišťuje robustnost v reálném provozu. Jejich schopnost identifikovat malé odchylky od očekávané polohy komponentů a pracovat s původními obrazovými daty zvyšuje přesnost detekce i při neideálních podmínkách. To je zásadní zejména v procesu finální kontroly, kde se musí detekovat i nejmenší odchylky od standardů.

Zároveň se očekává, že síť bude schopna detekovat i případné oděrky či jiné, vizuálně detekovatelné změny na povrchu dveřního panelu. Tato skutečnost by do budoucna mohla přinést úsporu času pracovníka, který by nemusel provádět vizuální kontrolu a mohl by se věnovat pouze ukládání dílu do držáku a následnému spuštění procesu kontroly.

## 7 METODY KONVENČNÍCH ALGORITMŮ

V této kapitole je věnována pozornost návrhu, zkoušení a vyhodnocení výsledků, kterých bylo dosaženo při aplikaci algoritmů, které zpracovávají obraz klasickým způsobem. U každého algoritmu je uveden stručný popis jeho činnosti a je popsána jeho schopnost vyhodnotit, zda je předložený kus OK či NOK.


### 7.1 VÝBĚR REFERENČNÍHO KUSU A POZIC VÝSTŘÍŽKŮ

Referenční kus, označený jako OK1, je vybrán s ohledem na optimální podmínky pro detekci všech devíti potřebných komponent. Zároveň je zajištěno, aby na něm a na desce za ním nebyly viditelné žádné nežádoucí odlesky, které by mohly narušit vyhodnocování OK nebo NOK kusů. Důležité je také, že na referenčním kusu nejsou viditelné žádné vnější interference, jako je například ruka operátora, která by mohla ovlivnit počet světlých pixelů. Tím je zajištěna spolehlivost obrazu pro prahování a další úkony spojené se zpracováním obrazu. Tento kus je označen jako OK1 a poskytuje referenci pro vyhodnocování všech následujících kusů pomocí standardních algoritmů.

Dalším důležitým krokem po vybrání základního referenčního kusu je získání pozic všech komponentů na tomto obraze. Formát obrázku poskytovaný kamerovým systémem je ve formě bmp, což přináší výhodu v eliminaci potřeby další manipulace či převodu na jiné formáty. Tím je zajištěno, že nedochází k nežádoucím chybám při převádění a jiné manipulaci s obrazovými daty.

Při volbě pozic jednotlivých výstřížků je klíčová snaha zajistit, aby komponenty vynikaly na pozadí a aby byl mezi nimi vysoký kontrast. To znamená, že na výstřížku musí být dobře patrný rozdíl mezi bílými komponenty a okolním pozadím, aniž by bylo nutné předem nastavovat prahování. Ideálně by měl být komponent zobrazen celý, nicméně vzhledem k pohyblivosti dílu v držáku to není možné vždy zajistit. Pozice jednotlivých výstřížků se mohou drobně lišit pro potřeby různých algoritmů.

Pro výběr konkrétních výstřížků je využito programového prostředí Microsoft Visual Studio Code. Bohužel existuje skutečnost, že i přes deklarované pevné uchycení dílu v držáku, existuje určitá míra pohyblivosti dílu dveřního panelu, což má za následek rozšíření oblasti, která je třeba prozkoumat. Velikost této oblasti je stanovena na 120x120 pixelů, což umožňuje pokrýt oblast potenciální posunutí komponentu od referenční polohy.



*Obrázek 7.1 Referenční kus OKI.*

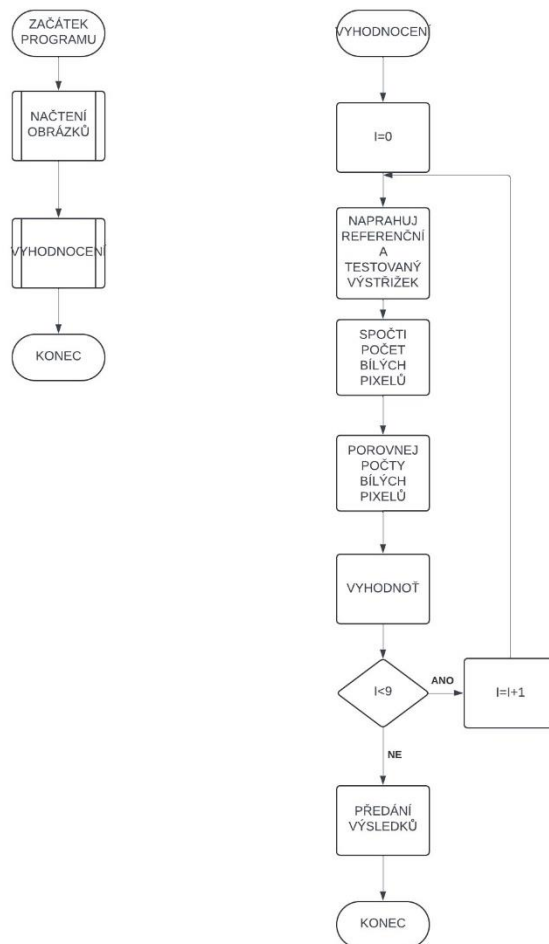
## **7.2 ALGORITMUS POČÍTÁNÍ BÍLÝCH PIXELŮ**

Jako první vyvíjený způsob detekce přítomnosti komponentu ve výstřižku je zvolen algoritmus pracující na principu počítání bílých pixelů na obrazu. Tento algoritmus ke své činnosti zprvu využívá metodu prahování. Jak je již popsáno v teoretické části práce, prahování převádí všechny pixely s intenzitou menší, než je daná hodnota, tedy onen práh, na pixely černé. Naopak pixely, které jsou světlejší než prahová hodnota jsou převedeny na bílou barvu.

Algoritmus nejdříve načítá černobílý obraz, poté provede prahování, čímž zajistí dobrou zpracovatelnost výsledného výstřižku.

Následně algoritmus prochází výstřižek postupně po jednotlivých pixelech. Funkce počítá bílé pixely a konečnou výslednou hodnotu navrátí. Tento proces je použit jak pro referenční kus, tak i pro kus testovaný. Vyhodnocení obrázku je poměrně snadné, využívá se procentuálního poměru bílých pixelů na výstřižku testovaném ku počtu bílých pixelů na výstřižku referenčním.

Hranice pro OK kus byla zvolna jako více než 55%. Tato hranice je zvolena z důvodu možné pohyblivosti dílu a také proměnných světelných podmínek.



Obrázek 7.2 Vývojový diagram algoritmu počítání pixelů.

### **7.3 ZKOUŠKA ALGORITMU POČÍTÁNÍ PIXELŮ**

Algoritmus prokázal schopnost detekovat přítomnost komponentů ve výstřižku. Správně vyhodnotil většinu OK a NOK fotografií s úrovní osvětlení, jež je podobná referenčnímu kusu, nicméně pro použití ve výrobní lince se choval nespolehlivě. Při dalším testování se ukázala možnost zaručit toto vyhodnocení pomocí vysokého odlesku od dílu, či od držáku dílu. Jelikož je fotografie prahována, světlé odlesky jsou po prahování převedeny na bílé. Program pak sčítá bílé pixely a může zaměnit OK kus s NOK kusem a naopak. Při aplikaci podobného algoritmu by byla nutnost odstínit nežádoucí světelné vlivy, zajistit konstantní osvětlení a mechanicky zabránit dílu v pohybu na držáku.

Tento relativně velmi jednoduchý algoritmus dokáže v omezené míře spolehlivě vyhodnotit OK a NOK díly. Nicméně by byla vhodná jeho další modifikace. V případě použití tohoto algoritmu bez programových úprav by se musely zajistit podmínky výše popsané. Algoritmus je tedy pro využití ve stávajícím prostředí konkrétní výrobní linky téměř nepoužitelný.

### **7.4 DETEKCE POMOCÍ NEJSVĚTLEJŠÍHO BODU**

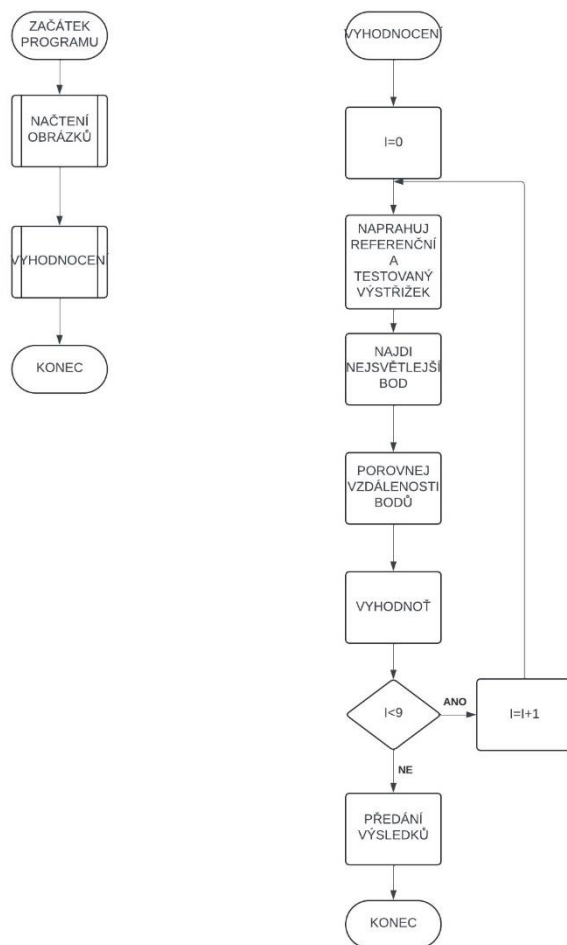
Při zvážení rozsahu barev vyskytujících se na zpracovávaných výstřižcích obrazu vynikají především dvě barvy: bílá a černá. Z tohoto důvodu je možné identifikovat komponent pomocí pozice nejsvětlejšího bodu na referenčním výstřižku, která by měla korespondovat s bílým komponentem a pomocí jednoduchých trigonometrických výpočtů získat vzdálenost mezi těmito body na referenčním a zkoumaném obraze.

Tento postup umožňuje rychlé a přesné stanovení rozdílu v pozicích mezi nejjasnějším bodem na referenčním obrázku a nejjasnějším bodem na testovaném obrázku. Získané informace o vzdálenosti vystupují jako klíčový parametr pro vyhodnocení správnosti umístění komponentu na dílu. Díky tomuto poměrně jednoduchému a rychlému přístupu lze dosáhnout spolehlivé detekce a vyhodnocení výsledků finální kontroly s minimálními chybami.

## 7.5 FUNKCE VZDÁLENOSTNÍHO ALGORITMU

Algoritmus začíná načtením černobílého obrázku a následně aplikuje metodu polo-prahování, která spočívá v nahrazení hodnot nižších než určený práh černou barvou, zatímco hodnoty nad tímto prahovým limitem zůstávají zachovány. Tento proces se opakuje pro každý výstřižek s individuálně nastavenými hodnotami pro polo-prahování, což zajišťuje relativně optimální adaptaci na rozdílné osvětlení v různých částech obrázku.

Následně algoritmus systematicky prohledává každý pixel v celém výstřižku a identifikuje souřadnice s nejvyšší hodnotou světlosti. Tato lokalizace se provádí za předpokladu, že nejvyšší světlost odpovídá bílému komponentu na dílu. Po lokalizaci nejsvětlejších bodů na výstřižku algoritmus vypočítá procentuální odchylku polohy těchto bodů od předem definované toleranční vzdálenosti. Tato tolerance zůstává konstantní pro všechny komponenty a umožňuje vyhodnocování dílů bez ohledu na to, o jaký výstřižek se jedná.



Obrázek 7.3 Vývojový diagram algoritmu porovnávání vzdáleností nejsv. bodů.

## 7.6 TESTOVÁNÍ VZDÁLENOSTNÍHO ALGORITMU

Pro testování algoritmu bylo využito několik OK a NOK fotografií. Na každé z těchto fotografií program správně vyhodnotil přítomnost či nepřítomnost komponentu Program velmi dobře detekuje komponenty i při zhoršených světelných podmínkách, oproti algoritmu počítání bílých pixelů. Tato skutečnost nastává díky tomu, že slabší odlesky sice projdou přes prahování obrázku, ale jelikož nejsou nastaveny na bílé, a zpracování vychází z nalezení nejsvětlejších bodů, algoritmus tyto oblasti bezpečně eliminuje. Riziko nastává až při velkém nasvícení, takovéto nasvícení může zmást algoritmus a ten může vyvodit nepravdivý závěr.

Pro aplikaci tohoto algoritmu na stanici finální kontroly by bylo vhodné provést, stejně jako v předchozím případě, naprosto nehybné uchycení dílu do držáku. Poté by bylo možné zmenšit prohledávanou oblast a zpřesnit tím možnosti vyhodnocení, které by nemuselo pokrývat tak velkou oblast.

Jak je zmíněno výše, algoritmus již nemá tolik problémů s případnými odlesky od desky držáku dílu. Ale při vyšších intenzitách odraženého světla může stále docházet k problémům. Tudíž by byl aplikovatelný při dodržení určitých světelných podmínek.

## **7.7 VYHODNOCENÍ APLIKACE JEDNODUCHÝCH ALGORITMŮ**

Ze zkoušek provedených na jednoduchých algoritmech založených na počítání světlých pixelů a vzdálenosti nejsvětlejšího bodu vyplývá, že pro aplikaci zmíněných algoritmů je nutno jejich vylepšení, či úprava prostoru stanice.

Vylepšení stávajících algoritmů by mělo zahrnovat způsob, jak odstranit nežádoucí vlastnosti algoritmů a s tím spojenou chybovost. Největší problém je spojen s nežádoucími odrazy světla, které znemožňují detekci správného umístění komponentu. Při užití algoritmu, který pracuje s počítáním světlých pixelů, lze velmi snadno algoritmus oklamat větším osvětlením nebo světlou plochou na výstřižku. Druhý algoritmus, pracující na principu hledání a porovnávání souřadnic nejsvětlejšího bodu, nelze již tak lehce oklamat, protože nejsvětlejší místo se při optimální, i zvýšené intenzitě světla, nachází na místě komponentu, tudíž je možno detekovat jeho přítomnost.

Jelikož oba algoritmy mají problémy s proměnnou intenzitou světla, bylo by možné uvažovat nad zavedením ochranné clony přímo na stanici finální kontroly. Tato clona by zamezovala okolnímu osvětlení prostupovat do prostoru dílu. Díky stejné intenzitě při každém vyhodnocení by bylo možno nastavit hodnoty prahování tak, aby odstínilo drobné odlesky a ponechaly viditelný pouze žádaný komponent.

## 7.8 DETEKCE HRAN

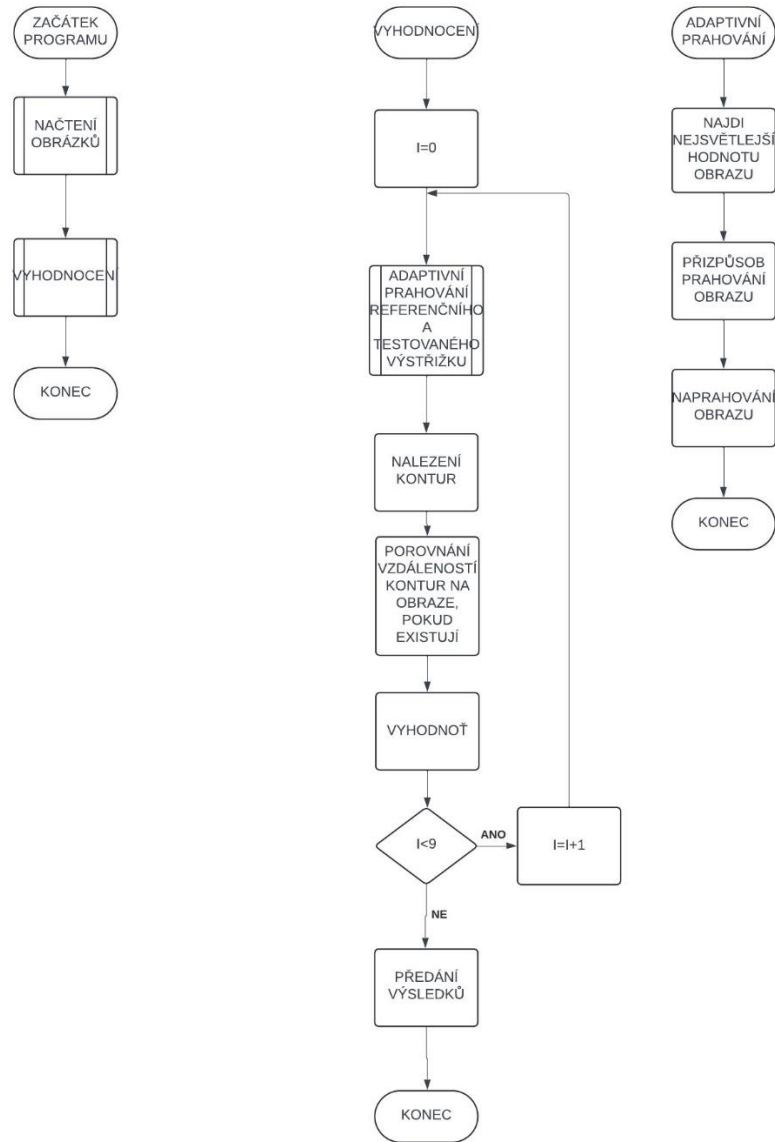
Při zpracování obrazu se hojně využívá detekce hran, což je metoda pro identifikaci míst, kde dochází k prudké změně jasu nebo barevného tónu. Tyto změny signalizují přechod mezi světlými a tmavými oblastmi v obraze. Detekce hran je klíčová při analýze obrazu, protože nám umožňuje identifikovat hrany a detaily objektů.

Po odstranění tmavých částí obrazu, které nejsou relevantní nebo mohou snižovat kontrast, se provádí vyhledávání kontur. Kontury jsou spojnice mezi body v obraze, kde dochází k prudké změně jasu nebo barevného tónu. Tyto kontury nám poskytují informace o přítomnosti komponentu na dílu dveřního panelu.

## 7.9 ALGORITMUS DETEKCE HRAN

Program nejprve načte černobílý obraz. V takovém černobílém obraze zjistí hodnotu nejvyšší světlosti, aby mohl prahovat obraz v závislosti na této hodnotě, takto upravené prahování dává lepší možnost zamezit vzniku nežádoucích tmavších kontur. Hodně světlé pixely jsou nastaveny na maximální možnou světlost. Tím by se měly případné hodně světlé bílé komponenty stát nejjasnější a největší konturou.

Po naprahování algoritmus zajistí vyhledání kontur a pokud nějaké najde, vybere z nich tu největší. Kolem této kontury vytvoří ohraničení pomocí pomyslného obdélníku, a uloží souřadnice jeho středu. Tato činnost se provede jak pro referenční, tak i pro testovaný kus. Následně se vypočítá vzájemná vzdálenost středů na obou výstřizcích a pokud je menší než hranice, je velice pravděpodobné, že se komponent nachází na správném místě a zároveň je na správné pozici.



Obrázek 7.4 Vývojový diagram algoritmu detekce hran

## 7.10 TESTOVÁNÍ ALGORITMU DETEKCE HRAN

Pro testování algoritmu bylo použito deset NOK a deset OK fotografií dveřního panelu. Každá fotografie obsahovala různé varianty osvětlení a pozadí, aby byla zajištěna robustnost algoritmu v různých podmínkách. Algoritmus úspěšně vyhodnotil přítomnost či nepřítomnost bílého komponentu na každé fotografii a prokázal tím svoji funkčnost.

Následné rozšířené testování odhalilo drobné možnosti zaručení schopnosti vyhodnocení v případě přítomnosti cizích předmětů v obraze.

Je důležité poznamenat, že takové události by neměly vznikat při běžném provozu, protože díl by měl být vždy kompletně a dobře viditelný. Algoritmus je navržen tak, aby byl odolný vůči světelným rušivým faktorům a mohl spolehlivě fungovat v reálných provozních podmínkách.

Díky schopnosti rozpoznávat komponenty, jak při snížené, tak i zvýšené hodnotě osvětlení, je algoritmus vhodný pro aplikaci na stanici finální kontroly.

## 7.11 VYHODNOCENÍ ALGORITMU DETEKCE HRAN

Existuje několik důvodů, proč je tento algoritmus vhodný pro aplikaci na stanici finální kontroly:

Dobrá adaptabilita na světelné podmínky: Algoritmus je navržen tak, aby byl schopen pracovat efektivně za různých světelných podmínek. Jeho schopnost rozpoznávat komponenty jak při snížené, tak i zvýšené intenzitě osvětlení znamená, že může spolehlivě fungovat.

Vynechání tmavých míst v obraze díky adaptabilnímu prahování: Algoritmus využívá adaptabilního prahování, které umožňuje efektivně odstranit tmavé oblasti v obraze a soustředit se pouze na relevantní světlé komponenty. Tím se minimalizuje riziko falešných pozitivních výsledků a zvyšuje se přesnost detekce.

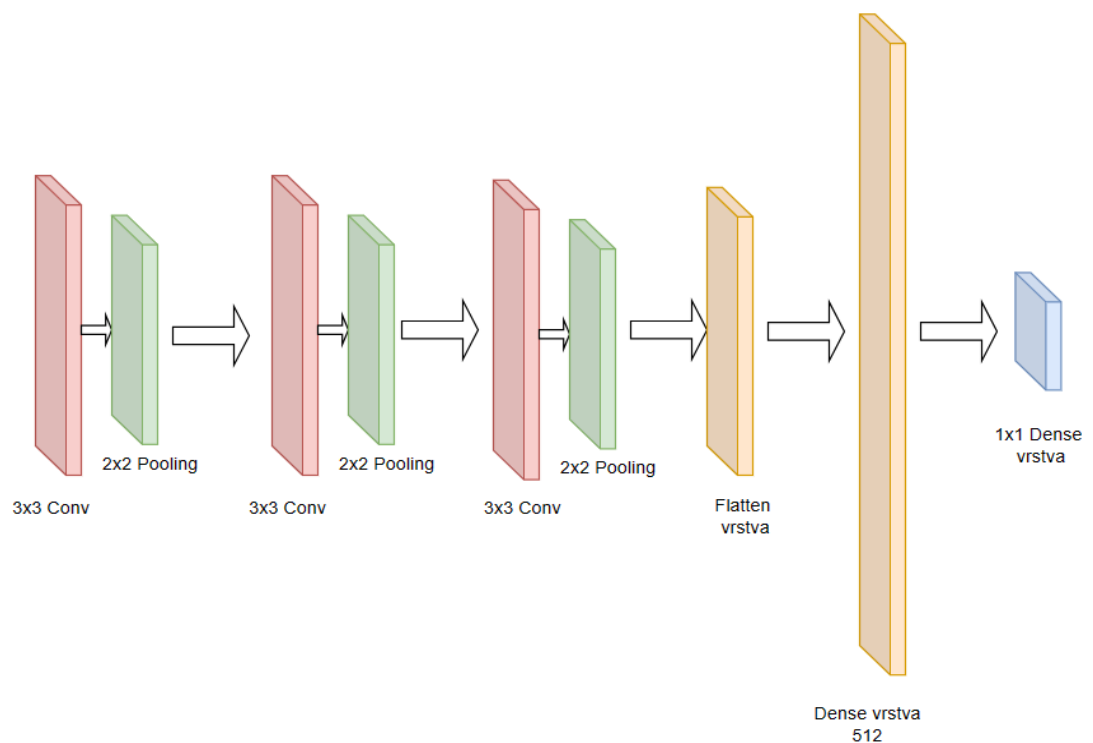
Velmi nízká chybovost při vyhodnocování: Algoritmus byl testován na širokém spektru fotografií dveřních panelů a prokázal velmi nízkou chybovost při vyhodnocování přítomnosti či nepřítomnosti bílých komponentů. Díky tomu by mohl být použit na stanici finální kontroly s důvěrou v jeho schopnost poskytovat spolehlivé a přesné informace o stavu výrobků.

Celkově lze tedy konstatovat, že algoritmus pro rozpoznávání komponent disponuje vlastnostmi, které ho činí ideálním kandidátem pro aplikaci na stanici finální kontroly.

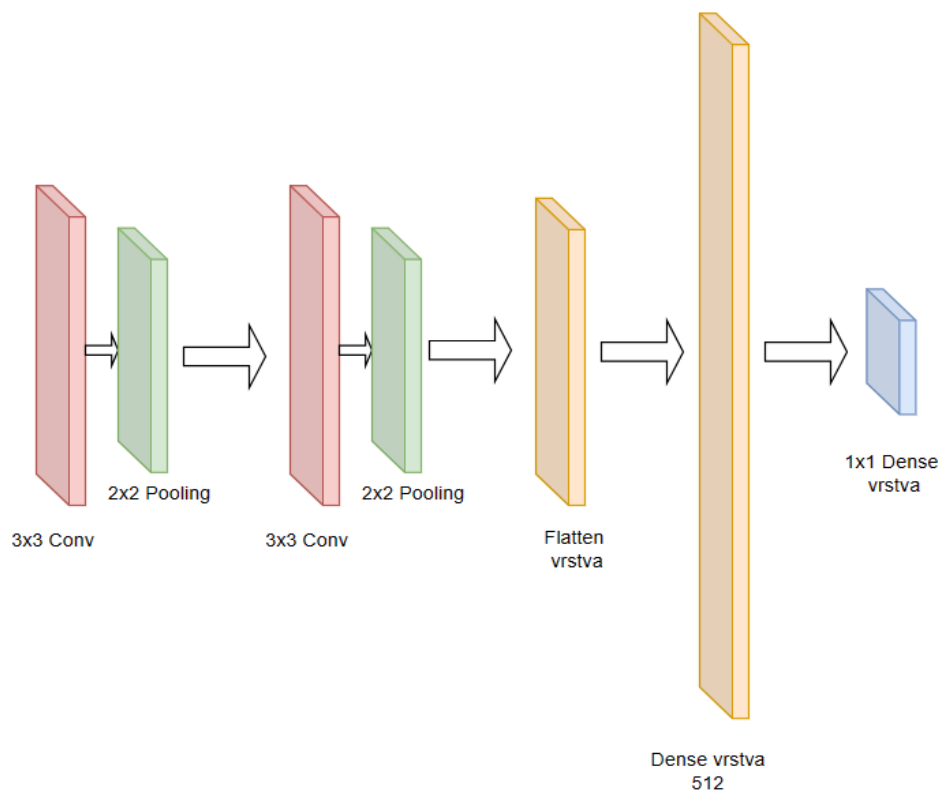
## 8 KONVOLUČNÍ NEURONOVÉ SÍTĚ

Pro účely této práce byly navrženy dvě různé topologie konvolučních neuronových sítí. První síť využívá 3 páry konvolučních a MaxPooling vrstev, zatímco druhá síť používá obdobně páry konvolučních a MaxPooling vrstev, avšak pouze dva takové páry. Při tréninku každé topologie byl počet filtrů v konvolučních vrstvách nastaven na koeficient  $k$ , ve druhé vrstvě na  $2k$  a ve třetí vrstvě na  $4k$ , kdy množina koeficientů  $k$  byla  $\{2,4,6,8,10,12,14,16\}$ . Pro každou kombinaci bylo provedeno 15 tréninků, přičemž každý trénink trval 100 epoch. Po každé etapě trénování byla síť ověřena na validačním datasetu, který obsahoval 75 NOK a 143 OK fotografií, což umožnilo posouzení schopnosti sítě správně klasifikovat kusy jako OK nebo NOK. Tento proces opakovaného tréninku a ověřování poskytl možnost získat reflexi o schopnosti sítě se učit a optimalizovat její výkon a přesnost.

Sítě s větším počtem filtrů, např. 14 a 16, jsou již poměrně veliké, některé přesahují velikost 0,5 GB. Vhodná síť má reflektovat následující požadavky: měla by správně a bez výkyvů vyhodnocovat fotografie dílů a měla by být co nejmenší. Nicméně navrhované sítě jsou ještě stále využitelné i při koeficientu  $k=16$ , protože mají maximálně 3 vrstvy a spolehlivě se vejdou na jakékoliv moderní paměťové médium.



Obrázek 8.1 Topologie sítě s třemi páry.



Obrázek 8.2 Topologie sítě s dvěma páry.

## 8.1 TRÉNOVÁNÍ NEURONOVÝCH SÍTÍ.

Při trénování bylo původně zamýšleno využít 200 epoch, avšak kvůli rychlé konvergenci sítě k požadovaným výsledkům bylo pro další učení sníženo množství trénovacích epoch na polovinu. Tato optimalizace tréninku umožnila efektivní využití času při trénování a dosahování požadovaných výsledků. Jak již bylo zmíněno, pro každou síť bylo použito proměnné množství filtrů v konvolučních vrstvách.

Tato opakovaná testování umožnila získat důkladné poznatky o tom, která konfigurace sítě byla pro každou topologii nejvhodnější, a poskytla tak informace pro další optimalizaci a vylepšení výkonu neuronových sítí při vyhodnocování správnosti kusů.

Pro vyhodnocení nejlepší topologie byl užít tzv. confusion matrix. Tj. matice, která zaznamenává výsledky binární klasifikace. Pracuje se 4 hodnotami :

TP - True Positive, správně klasifikovaný obraz jako 1.

TN - True Negative, správně vyhodnocený obraz jako 0.

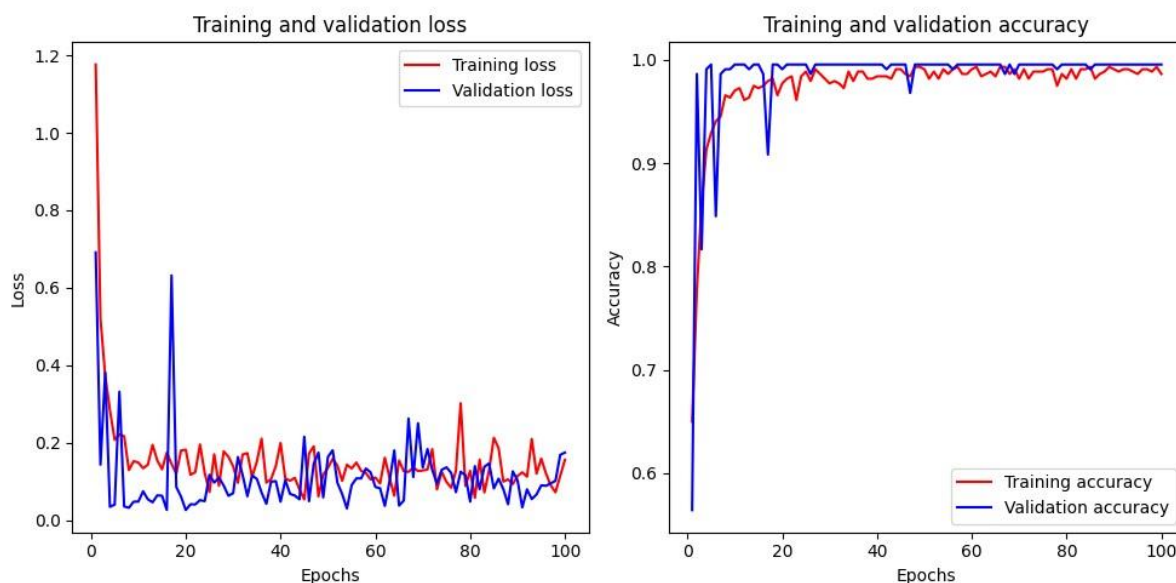
FP – False Positive, chybně vyhodnocený jako 1.

FN – False Negative, chybně vyhodnocený jako 0.

Z těchto údajů se pak dá vypočítat „Accuracy“, tedy přesnost detekce. Následně „Precision“, to je údaj, jenž hodnotí míru správnosti pozitivních předpovědí. Dalším údajem, který je vyhodnocován je „Recall“, ten udává poměr správně klasifikovaných pozitivních instancí, vůči celkovému počtu pozitivních instancí, v tomto případě jde o počet správně vyhodnocených OK kusů vůči celkovému počtu OK kusů. Poslední vyhodnocovanou metrikou je „F1-score“, toto skóre vyhodnocuje komplexní funkci binárního klasifikačního modelu (Evaluation Metrics for Classification, 2012).


## 8.2 TOPOLOGIE S TŘEMI PÁRY

V topologii se třemi páry vrstev se po natrénování neuronové sítě a po porovnání s validační množinou vytvořili soubory zachycující průběh tohoto tréninku. Pro vyhodnocení těchto dat byly vytvořeny grafy, které zobrazují průběhy těchto dějů a jsou dobrým vizualizačním nástrojem pro vyhodnocení, která síť se natrénovala tak, aby byla schopna rozpoznat OK či NOK kusy.



Obrázek 8.3 Síť pro tři páry vrstev, kde  $k=6$ , 12. trénování.

Na obrázku 8.3 lze pozorovat graf průběhu trénování neuronové sítě, konkrétně se jedná o síť, kde  $k$ , jakožto koeficient počtu filtrů bylo 6. V grafu je krásně patrné, že síť při zkouškách na validační množině neprokazovala žádné velké výkyvy a úspěšnost vyhodnocení, vyjádřené parametrem „Validation accuracy“, konverguje ke 100%. Tato síť zároveň není ještě tak náročná pro paměť počítače, jelikož neobsahuje velké množství filtrů. Další věcí, na kterou je nutno se zaměřit je ta, že hodnoty „Validation loss“ a „Training loss“ nejsou velmi rozlišné, to by totiž znamenalo možné přetrénování sítě.



Obrázek 8.4 Síť pro tři páry vrstev, kde  $k=10, 11$ . trénování.

Další model sítě, který by byl vhodný pro použití, je model s koeficientem  $k$  rovným 10. Během svého 11. trénování prokázal schopnost správně vyhodnocovat předložené fotografie dveřního panelu na validační množině. Z grafu lze vyčíst, že existují výkyvy, avšak s narůstajícím počtem epoch postupně mizí. Mezi epochami 70 a 100 model správně určil předložené snímky z validační množiny.

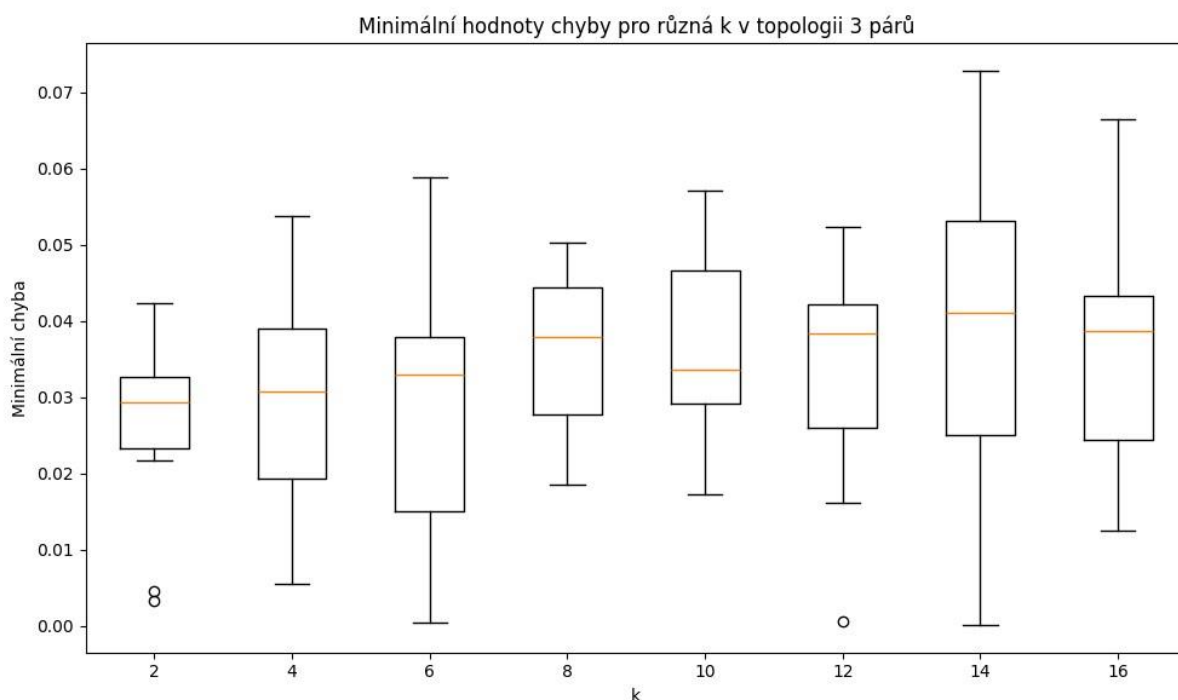
Tento model se zdá být poměrně stabilní a účinný. Výkyvy v průběhu trénování jsou totiž běžné, zejména v počátečních fázích, kdy se síť učí reprezentovat a vyhodnocovat předložená data. Důležité je, že tyto výkyvy postupně klesají, což naznačuje, že síť se přizpůsobuje a zlepšuje své schopnosti.

Pokud model dokáže správně identifikovat fotografie dveřního panelu ve finálních epochách trénování, je to velmi dobré znamení jeho schopnosti adaptability. To v praxi znamená, že síť není příliš specializovaná na tréninkovou sadu a je schopná dobře se vypořádat s novými daty.

### 8.3 VÝSLEDKY TOPOLOGIE TŘECH PÁRŮ

Tato topologie prokázala svoji schopnost při detekci OK a NOK dílů. Sít' se poměrně rychle učila a výše zmíněné pokusy byly v pozdních fázích učení schopny bezpečně rozeznat předloženou OK či NOK fotografii dveřního panelu. Podle výsledků jednotlivých modelů byly vybrány ty modely, které byly schopny správně vyhodnotit kus bez většího kolísání v pozdních epochách na validační sadě.

Sítě, které na validační množině prokázaly schopnost správně vyhodnotit předložený díl, by bylo možno nasadit i na stanici finální kontroly. Důležitým ukazatelem je právě stabilita vyhodnocování fotografií z validační množiny. Tento aspekt splňují obě sítě popsané v kapitole zabývající se topologií tří párů.



Obrázek 8.5 3 páry - BOX graf minimální chyby pro každé  $k$ .

TN-True Negative FP - False Positive FN - False Negative TP - True Positive	Confusion matrix - 3 páry, k=14	
	TN	FP
	75	4
	FN	TP
	0	139
Accuracy = $(TP+TN)/(TP+TN+FP+FN)$		0,9817
Precision = $TP / (TP+FP)$		0,9720
Recall = $TP/(TP+FN)$		1,0000
F1 Score = $2 * (precision * recall) / (precision + recall)$		0,9858

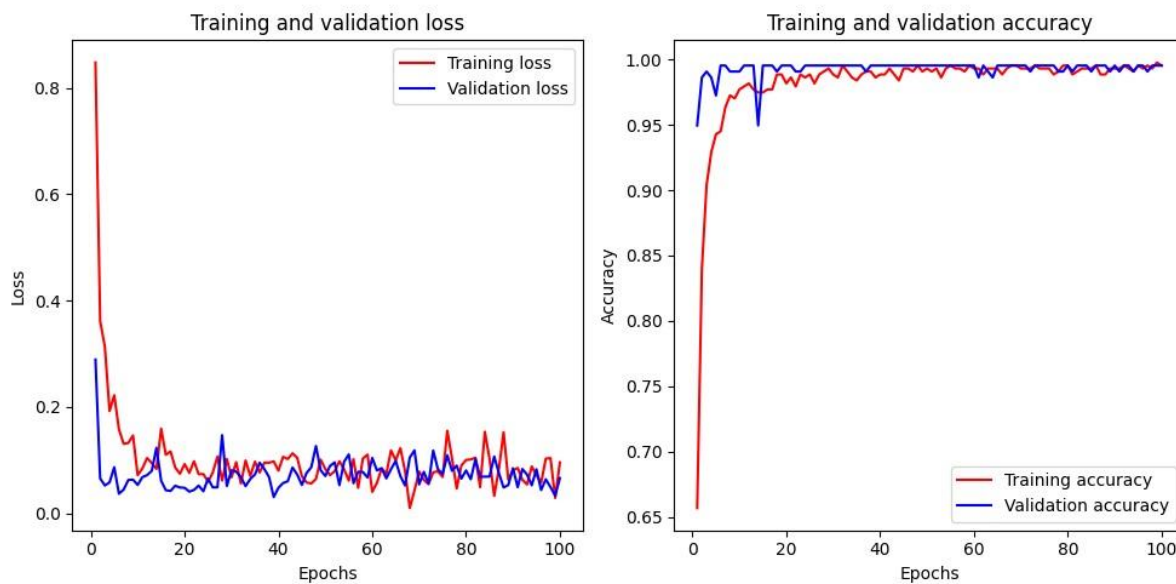
Obrázek 8.6 Confusion matrix pro 3 páry k =14.

Z obrázku 8.6 je dobře patrné, že tato topologie má velmi vysokou přesnost a všechny ukazatele ukazují, že tato síť má velmi dobrou schopnost rozpoznat OK či NOK díl. Přesnost přesahuje 98 % a F1 skóre je též vysoké, což naznačuje dobrou funkci sítě.

## 8.4 TOPOLOGIE S DVĚMA PÁRY

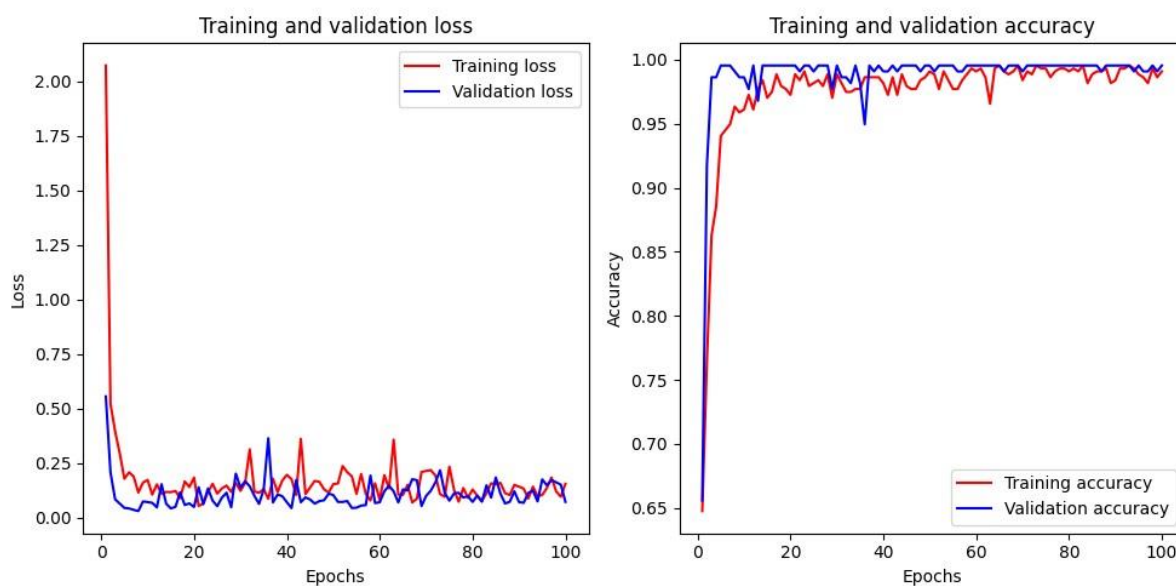
Stejně jako v topologii tří vrstev, tak i v této dvouvrstvé topologii byly zaznamenány průběhy testování. Tato topologie má nižší nároky na výkon počítače a na jeho úložiště, jelikož je méně rozsáhlá.

Rovněž jako pro topologii se třemi vrstvami bylo provedeno 15 učicích cyklů pro každý koeficient k. Jsou popsány pouze experimenty s nejlepšími výsledky v rámci požadavků, tudíž s nejstabilnějším průběhem přesnosti na validační množině.



Obrázek 8.7 Síť pro dva páry vrstev, kde  $k=4$ , 14. trénování.

Při tomto experimentu pro dva páry vrstev a  $k=4$ , je v grafu na obrázku 8.7 vidět mírná rozkolísanost „Validation accuracy“, tudíž přesnosti na validační množině. Nicméně i tak je síť schopna rozpoznávat předložené fotografie s relativně dobrou přesností.



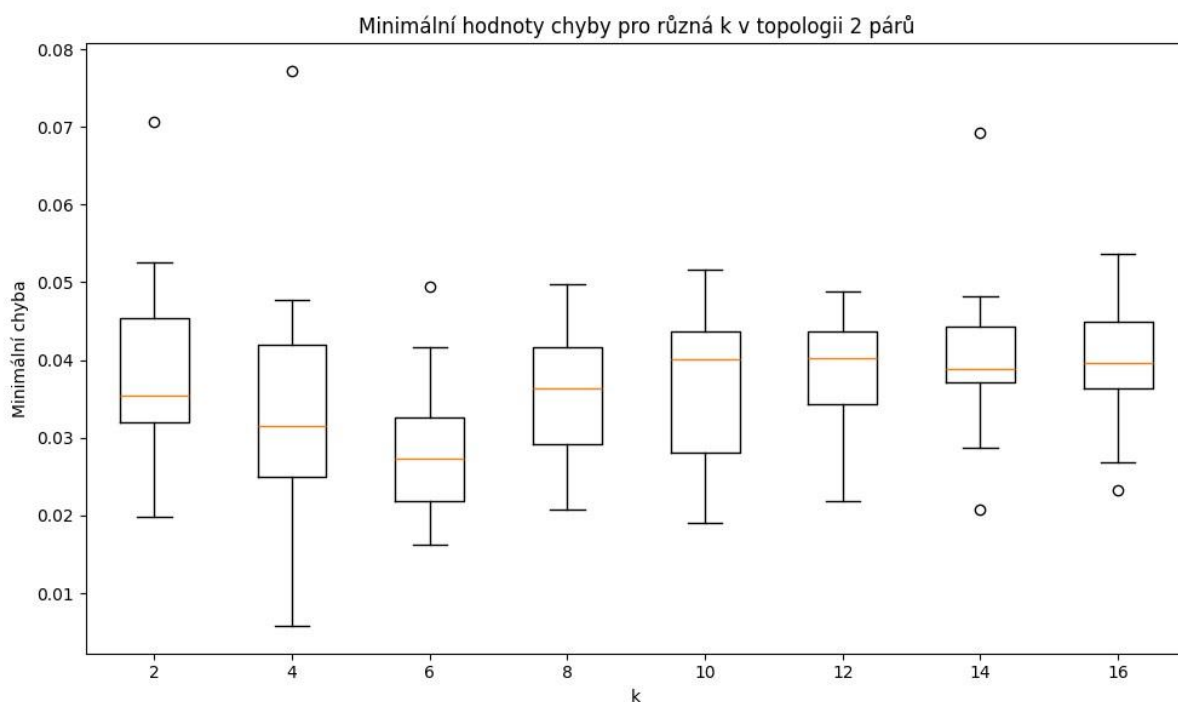
Obrázek 8.8 Síť pro dva páry vrstev, kde  $k=16$ , 6. trénování.

Tato síť, jejíž graf je na obrázku 8.8 se i přes vysoký počet filtrů stále chová mírně rozkolísaně, nicméně stejně jako předchozí síť je schopna celkem dobře rozpoznávat předložené fotografie a provádět jejich vyhodnocení. Není ani patrný náznak přetrénování, což naznačuje dobrou vizi do budoucna, že síť použitá při tomto experimentu by byla schopna dobře hodnotit fotografie dveřních panelů.

## 8.5 VÝSLEDKY TOPOLOGIE DVOU PÁRŮ

Ačkoliv tyto sítě stále celkem dobře rozpoznávají předložené snímky a jsou menší než dříve zmíněné sítě se třemi páry vrstev, je u výsledků testu na validační množině patrné rozkolísání, a to i při použití velkého množství filtrů při  $k=16$ . Toto rozkolísání není velké, ale v kontextu kontroly kvality v automobilovém průmyslu je potřeba zajištění 100% spolehlivosti. Tudíž síť se dvěma vrstvami není vhodná pro použití na stanici finální kontroly.

Na následujících grafech, stejně jako v případě topologie třech párů sítí je zobrazena hodnota ztráty při učení, a to pro každé  $k$ .



Obrázek 8.9 2 páry - BOX graf minimální chyby pro každé  $k$ .

TN-True Negative FP - False Positive FN - False Negative TP - True Positive	Confusion matrix - 2 páry, k=4	
	TN	FP
	72	18
	FN	TP
	3	125
<b>Accuracy = (TP+TN)/(TP+TN+FP+FN)</b>		<b>0,9037</b>
<b>Precision = TP / (TP+FP)</b>		<b>0,8741</b>
<b>Recall = TP/(TP+FN)</b>		<b>0,9766</b>
<b>F1 Score = 2* (precision * recall) / (precision + recall)</b>		<b>0,9225</b>

Obrázek 8.10 Confusion matrix pro 2 páry k = 4.

Obrázek 8.10 zobrazuje matici pro topologii 2 párů, kde k=4. Tato síť vyšla z trénování nejlépe. Tato síť byla schopna rozpoznat poměrně vysoké procento předložených fotografií. Na druhou stranu, síť neprokázala tak vysokou přesnost. Hodnota přesnosti byla 90,3 %. Což nesplňuje požadavky kladené na tuto síť.

## 8.6 ZHODNOCENÍ APLIKACE NEURONOVÝCH SÍTÍ

Při aplikaci neuronových sítí bylo dosaženo výsledku, který byl předpokládán. Neuronové sítě byly schopny zaznamenat, vyhodnotit a správně klasifikovat předložené fotografie. Osvědčila se zejména topologie se třemi páry vrstev, která dosáhla lepších výsledků než druhý typ sítí, který obsahoval pouze dva páry vrstev.

Pro aplikaci na stanici finální kontroly by se hodily pouze sítě, které měly páry tři, a to díky tomu, že jejich schopnost rozpoznat NOK kus by se dala označit za velmi dobrou. Dva páry sice též prokázaly schopnost detekce, nicméně jejich výsledky byly i tak lehce nestabilní, což se v kontextu kontroly kvality v prostředí automobilového průmyslu nedá tolerovat.

Stejně výsledky potvrzují i „confusion matrixy“, které potvrzují schopnost sítě se třemi páry vrstev vyhodnocovat kusy lépe než sítě se dvěma páry.

Ačkoliv v současné době hardwarová konfigurace na stanici finální kontroly nedovoluje aplikaci neuronových sítí, experimenty potvrdily, že by se tato metoda vyhodnocování dala aplikovat. Pouze by se muselo upravit hardwarové uspořádání stanice. Do budoucna je tato metoda rozhodně zajímavým nástrojem nejen pro tuto stanici, ale i pro použití na jiných výrobních linkách.

## ZÁVĚR

Tato práce měla za cíl navrhnout, vytvořit a aplikovat algoritmy pro zpracování obrazu za účelem kontroly kvality dílu dveřního panelu. V teoretické části byla prostudována oblast kontroly kvality a technik zpracování obrazu, včetně možnosti použití moderních neuronových sítí.

První segment praktické části se věnoval aplikaci konvenčních algoritmů, tedy zpracování obrazu bez použití konvolučních neuronových sítí. Úvodní dva jednodušší algoritmy prokázaly, že jsou schopny detekovat přítomnost či nepřítomnost bílého komponentu. Nicméně stále chybovaly, zejména při měnících se světelných podmínkách. Pro aplikaci těchto algoritmů by se muselo zajistit, aby se tyto podmínky neměnily. Tudíž by byly třeba jisté úpravy stanice finální kontroly.

Dalším konvenčním algoritmem byl zvolen princip detekce hran v obrazu za použití adaptivního prahování. Tento postup se dobře osvědčil a byl schopen velmi spolehlivě detekovat přítomnost komponentu, či dokonce přítomnost cizích těles na obraze.

V druhé polovině praktické části se práce věnovala aplikaci konvolučních neuronových sítí. Dvě vytvořené topologie byly trénovány na trénovacím datasetu. Jejich ověření na validační množině ukázalo, že obzvláště topologie třech párů vrstev dokázala velmi dobře rozpoznat, zda je díl OK či NOK. Topologie dvou vrstev sice také dokázala rozpoznat, zda je kus OK či NOK, ale již ne tak spolehlivě jako její sesterská varianta. Pro aplikaci by tedy byla vhodná topologie třech párů vrstev.

Pro využití na stanici finální kontroly by byl vhodný algoritmus na bázi detekce hran a konvoluční neuronová síť se třemi páry vrstev. Zejména ověření, že i neuronová síť je schopna rozpoznat kvalitu dveřního panelu, přineslo příslib, že neuronové sítě mohou být využity v kontextu ověření kvality v automobilovém průmyslu, tudíž nejen na této stanici.

Cíle této práce byly splněny, jelikož navrhované algoritmy byly schopny rozpoznat, zda se jedná o vadný či dobrý kus. Zároveň se zvyšovala sofistikovanost těchto algoritmů od jednodušších až po komplexní neuronové sítě, které představují moderní a velmi komplexní algoritmy.

## POUŽITÁ LITERATURA

Automatizace výroby a kontrola kvality, c2001-2024. *MM Průmyslové spektrum* [online]. [cit. 2024-02-06]. Dostupné z: <https://www.mmspektrum.com/clanek/automatizace-vyroby-a-kontrola-kvality>

Automobilový průmysl (Automotive Industry), c2011-2016. *MANAGEMENT MANIA* [online]. [cit. 2024-02-06]. Dostupné z: <https://managementmania.com/cs/automobilovy-prumysl>

Evaluation Metrics for Classification, 2012. *Medium* [online]. [cit. 2024-05-01]. Dostupné z: <https://medium.com/@impythonprogrammer/evaluation-metrics-for-classification-fc770511052d>

GONZALEZ, Rafael C. a Richard E. WOODS, 2018. *Digital Image Processing*. 4. New York: Pearson. ISBN 978-3-319-94462-3.

HAVLE, Otto, 2008. Strojové vidění I: Principy a charakteristiky. *AUTOMA* [online]. **14**(1), 43-45 [cit. 2024-02-19]. ISSN 1210-9592. Dostupné z: [https://automa.cz/Aton/FileRepository/pdf\\_articles/36550.pdf](https://automa.cz/Aton/FileRepository/pdf_articles/36550.pdf)

*IT Systems* [online], 2014. [cit. 2024-05-01]. ISSN 1802-002X. Dostupné z: <https://www.systemonline.cz/business-intelligence/neuronove-site-a-jejich-vyuziti-1.htm>

Kontrola kvality výroby: 5 předností kamerových systémů pro bezkontaktní měření, c2022. *Jetty Vision* [online]. [cit. 2024-02-06]. Dostupné z: <https://jettyvision.cz/clanky/kontrola-kvality-vyroby-5-prednosti-kamerovych-systemu-pro-bezkontaktni-mereni/>

*MM Průmyslové spektrum: Technologie pro produktivní obrábění*, 2020. ISSN 1212-2572.

PILÁT, Martin, b. r. a. Neuronové sítě - konvoluční sítě a zpracování obrazu. *Martin Pilát* [online]. [cit. 2024-02-08]. Dostupné z: <https://martinpilat.com/cs/prirodou-inspirovane-algoritmy/neuronove-site-konvolucni-site-zpracovani-obrazu>

PILÁT, Martin, b. r. b. Neuronové sítě - úvod. *Martin Pilát* [online]. [cit. 2024-02-08]. Dostupné z: <https://martinpilat.com/cs/prirodou-inspirovane-algoritmy/neuronove-site-uvod>

REYNOLDS, Anh H., c2022. Convolutional Neural Networks (CNNs). *ANH H. REYNOLDS* [online]. [cit. 2024-02-19]. Dostupné z: <https://anhreynolds.com/blogs/cnn.html>

ŘEHÁČEK, Jan, c2024. Matykání: Hod'te na problém neuronovou sít'. *Matfyz* [online]. [cit. 2024-02-07]. Dostupné z: <https://www.matfyz.cz/clanky/matykani-hodte-na-problem-neuronovou-sit>

SEDLÁČEK, Milan, Petr SUCHÁNEK, Jiří ŠPALEK a Petra ŠTAMFESTOVÁ, 2011. *Kvalita jako faktor konkurenceschopnosti podniku* [online]. 1. Brno: MUNI PRESS [cit. 2024-02-05]. ISBN 978-80-210-8173-4. Dostupné z: <https://www.bookport.cz/e-kniha/kvalita-jako-faktor-konkurenceschopnosti-podniku-1653426/>

ŠPANĚL, Michal a Vítězslav BERAN, 2005. *Obrazové segmentační techniky Přehled existujících metod* [online]. 2006 [cit. 2024-02-07]. Dostupné z: <https://www.fit.vutbr.cz/~spanel/segmentace/>

VEBER, Jaromír, Marie HŮLOVÁ, Helena KOŘÁNOVÁ a Alena PLÁŠKOVÁ, 2011. *Řízení jakosti a ochrana spotřebitele* [online]. 2., aktualizované vydání. Praha: Grada Publishing [cit. 2024-02-05]. ISBN 978-80-247-6664-5. Dostupné z: <https://www.bookport.cz/e-kniha/rizeni-jakosti-a-ochrana-spotrebitele-1654064/>

VLACH, Jaroslav, c2024a. Strojové zpracování obrazu: Využití neuronových sítí II. *Matfyz* [online]. [cit. 2024-02-07]. Dostupné z: <https://www.matfyz.cz/clanky/strojove-zpracovani-obrazu-vyuziti-neuronovych-siti-ii>

VLACH, Jaroslav, c2024b. Strojové zpracování obrazu: Využití neuronových sítí I. *Matfyz* [online]. [cit. 2024-02-07]. Dostupné z: <https://www.matfyz.cz/clanky/strojove-zpracovani-obrazu-vyuziti-neuronovych-siti-i>

VLACH, Jaroslav, c2024c. Strojové zpracování obrazu: Fuzzy logika. *Matfyz* [online]. [cit. 2024-02-07]. Dostupné z: <https://www.matfyz.cz/clanky/strojove-zpracovani-obrazu-fuzzy-logika>

Vysokorychlostní kamera 16×, 0,47 megapixelu (černobílá), c2024. *KEYENCE* [online]. [cit. 2024-02-07]. Dostupné z: <https://www.keyence.eu/cscz/products/vision/vision-sys/xg-x/models/ca-h048mx/>

## **9 SEZNAM PŘÍLOH**

Příloha A: KÓDY

## **PŘÍLOHA A: KÓDY**

Soubor obsahující algoritmy pro detekci komponentů – ONLINE soubor KÓDY.zip