



ZADÁNÍ BAKALÁ SKÉ PRÁCE

Název:	Detekce vad sklen ných tabulí
Student:	Kristýna Tauchmanová
Vedoucí:	doc. RNDr. Ing. Marcel Ji ina, Ph.D.
Studijní program:	Informatika
Studijní obor:	Teoretická informatika
Katedra:	Katedra teoretické informatiky
Platnost zadání:	Do konce letního semestru 2016/17

Pokyny pro vypracování

- 1) Seznamte se s procesem výroby sklen ných tabulí a zp soby, jakými mohou ve skle vznikat r zné druhy vad.
- 2) Prove te rešerši metod, které se používají pro detekci vad materiál , zejména skla. Prozkoumejte vybrané algoritmy pro zpracování obrazu využitelné pro danou úlohu.
- 3) Navrhn te postup a díl í metody pro zpracování snímk sklen ných tabulí. Zohledn te specifika snímacího procesu.
- 4) Navržené metody implementujte po dohod s vedoucím práce ve vhodném programovacím jazyku.
- 5) Implementované metody ov te na reálných datech, vyhodno te dosaženou p esnost a navrhn te možná zlepšení.

Seznam odborné literatury

Dodá vedoucí práce.

L.S.

doc. Ing. Jan Janoušek, Ph.D.
vedoucí katedry

prof. Ing. Pavel Tvrdík, CSc.
řídící kan

V Praze dne 19. února 2016

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE
FAKULTA INFORMAČNÍCH TECHNOLOGIÍ
KATEDRA TEORETICKÉ INFORMATIKY



Bakalářská práce

Detekce vad skleněných tabulí

Kristýna Tauchmanová

Vedoucí práce: doc. RNDr. Ing. Marcel Jiřina, Ph.D.

17. května 2016

Poděkování

Ráda bych poděkovala mamince a tatínkovi za neustálou podporu, svému vedoucímu Marcelu Jiřinovi za cenné rady a přátelům za pomoc a příjemný průchod studiem.

Prohlášení

Prohlašuji, že jsem předloženou práci vypracoval(a) samostatně a že jsem uvedl(a) veškeré použité informační zdroje v souladu s Metodickým pokynem o etické přípravě vysokoškolských závěrečných prací.

Beru na vědomí, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorského zákona, ve znění pozdějších předpisů. V souladu s ust. § 46 odst. 6 tohoto zákona tímto uděluji nevýhradní oprávnění (licenci) k užití této mé práce, a to včetně všech počítačových programů, jež jsou její součástí či přílohou a veškeré jejich dokumentace (dále souhrnně jen „Dílo“), a to všem osobám, které si přejí Dílo užít. Tyto osoby jsou oprávněny Dílo užít jakýmkoli způsobem, který nesnižuje hodnotu Díla a za jakýmkoli účelem (včetně užití k výdělečným účelům). Toto oprávnění je časově, teritoriálně i množstevně neomezené.

V Praze dne 17. května 2016

.....

České vysoké učení technické v Praze
Fakulta informačních technologií

© 2016 Kristýna Tauchmanová. Všechna práva vyhrazena.

Tato práce vznikla jako školní dílo na Českém vysokém učení technickém v Praze, Fakultě informačních technologií. Práce je chráněna právními předpisy a mezinárodními úmluvami o právu autorském a právech souvisejících s právem autorským. K jejímu užití, s výjimkou bezúplatných zákonných licencí, je nezbytný souhlas autora.

Odkaz na tuto práci

Tauchmanová, Kristýna. *Detekce vad skleněných tabulí*. Bakalářská práce. Praha: České vysoké učení technické v Praze, Fakulta informačních technologií, 2016.

Abstrakt

Tato bakalářská práce se zabývá detekováním vad skleněných tabulí. Na základě studie současných řešení je navržen algoritmus, který je schopen detekovat a klasifikovat různé typy vad. Algoritmus využívá metod zpracování obrazu, zejména detekci hran a segmentaci. Byl testován na snímcích skel pořízených řádkovou kamerou.

Klíčová slova algoritmus, zpracování obrazu, automatizace, detekce vad, výroba skla

Abstract

This bachelor's thesis deals with detection of glass defects. An algorithm able to detect and classify various types of defects is suggested based on literary research. The algorithm uses image processing methods, especially edge detection and image segmentation. It was tested on images of glass, which were shot by a line scan camera.

Keywords algorithm, image processing, automation, detection of defects, glass manufacturing

Obsah

Úvod	1
1 Analýza a návrh	3
1.1 Výroba plaveného skla	3
1.2 Druhy vad	4
1.3 Popis zadání	5
1.4 Současná řešení	5
1.5 Návrh řešení	10
2 Realizace	15
2.1 Prototyp skenovacího zařízení a metodika měření	15
2.2 Měření	18
2.3 Výsledky detekce vad	21
2.4 Zhodnocení	25
Závěr	27
Literatura	29
A Seznam použitých zkratk	31
B Obsah příloženého CD	33

Seznam obrázků

1.1	Příklady bodových vad a jejich grafů	6
1.2	Příklady čárových vad a jejich grafů	7
1.3	3D model nasvícení skla	10
1.4	Vývojový diagram řešení	11
2.1	Prototyp skenovacího zařízení	16
2.2	Detail osvětlení	16
2.3	3D model prototypu	17
2.4	Příklad měření (bodové vady)	19
2.5	Příklad měření (čárové vady)	20
2.6	Poměrové zastoupení tříd u bodových vad	22
2.7	Poměrové zastoupení tříd u čárovových vad	23
2.8	Poměrové zastoupení tříd u všech vad	23

Seznam tabulek

2.1	Rozmístění statistických hodnot	24
2.2	Výsledky - bodové vady	24
2.3	Výsledky - čárové vady	24
2.4	Výsledky - všechny vady	24

Úvod

Kontrola kvality je ve sklářském průmyslu stěžejní. Na kvalitu výrobků jsou stále kladeny větší nároky a vady ve skle mohou mít na finální výrobek různý dopad. Například bubliny mohou mít malý vliv na běžné okenní výplně, ale obrovský vliv na bezpečnost automobilových skel. Právě z tohoto důvodu je téměř nezbytné skla kontrolovat.

Tradiční kontrola skel vyškoleným pracovníkem továrny, který hledá vady očima za pomoci podsvíceného stolu, je namáhavá a ne vždy spolehlivá detekce vad. Během dne se koncentrace pracovníků snižuje a lidské oko postupně unavuje. I rychlost takovéto kontroly je omezená a objemu dnešní výroby přestává stačit.

Právě proto se čím dál častěji přechází k automatizované kontrole. Sklo je vhodným materiálem pro strojové vidění kvůli své homogenitě a průsvitnosti, a tak není složité na takovém povrchu vady odhalit. Častým řešením je detekce za pomoci laseru a jeho paprsku, který se v místě vad láme jinak než na bezchybném skle. Dalším řešením jsou kamerové systémy, které kontinuálně snímají povrch skla. Ty jsou na rozdíl od laseru méně náročné na použitou techniku a podávají srovnatelné výsledky.

Tato práce si dává za cíl prozkoumat současná řešení detekce vad skla za pomoci kamerového systému a navrhnout algoritmus, který bude schopen s takovou technikou detekovat a klasifikovat vady skla. Pomocí řádkové kamery a vhodného nasvícení se sestaví prototyp, který skla nasnímá, aby bylo možné ověřit návrh řešení v praxi.

Moje bakalářská práce je rozdělena na dvě kapitoly, teoretickou a praktickou.

V první se zabývám výrobou skla a jeho problematikou. Děním druhy vad do dvou skupin podle tvaru a popisuji, za jakých okolností vznikají. Dále specifikuji zadaný problém detekce vad a studuji jeho současná řešení. Na jejich základě navrhuji vlastní algoritmus.

Druhá kapitola se zabývá realizací navrženého řešení. Popisuji skenovací prototyp, na kterém následně provádím měření. Výsledky hodnotím na základě

ÚVOD

představené metodiky a poté podle nich posuzuji efektivitu algoritmu.

V závěru práce vše shrnu a navrhnu postup dalšího vývoje.

Analýza a návrh

První kapitola je teoretickou částí mé bakalářské práce. V první sekci popisují výrobu plaveného skla, v druhé charakterizují vady, které při výrobě mohou vzniknout. Poukazují na kritické fáze výroby a druhy vad, které se typicky vyskytují. Třetí sekce specifikuje zadání práce. Předposlední sekce je literární rešerší současných řešení detekce vad, na jejímž základě navrhuji vlastní řešení, které je popsáno v poslední sekci.

1.1 Výroba plaveného skla

Tato sekce se zabývá výrobou plaveného skla a detailně popisuje jednotlivé fáze výroby.

Ploché sklo se v dnešní době nejčastěji vyrábí metodou Float (plavení). Tato technologie vznikla v roce 1957 ve Velké Británii, kde ji poprvé úspěšně představila společnost Pilkington Brothers. Je založená na principu plavení skla na hladině roztaveného kovu, který má vyšší měrnou hmotnost než sklo, ale jeho teplota tání je nižší. Takovéto vlastnosti splňuje například často používaný cín.

Sklovina se taví při teplotách 1200 °C až 1330 °C v závislosti na použitých materiálech. Při těchto teplotách má sklovina nejnižší viskozitu, a tedy i dobré podmínky pro čření.

Tavená sklovina se přivádí na hladinu roztaveného cínu při teplotě 1150 °C, kde vytváří nekonečný pás, který se podle potřeby rozšiřuje pomocí tvarovacích válců, nebo smršťuje tažením mezi grafitovými bariérami, aby se dosáhlo požadované tloušťky. Posouváním po pásu se sklovina postupně ochlazuje až na 600 °C. Při této teplotě má sklo dostatečnou viskozitu a nehrozí jeho deformace a poškrábání zvedacími válci při vyjmutí z cínové lázně.

Následně prochází chladicí pecí, kde je pás skla postupně ochlazován kvůli vyrovnání pnutí ve skle. Sklo má po chlazení teplotu přibližně 60 °C.

Dále pás prochází mycím procesem. Rotující kartáče, které se skla nedotýkají, ostříkují sklo horkou užitkovou vodou. Poté se opláchne demineralizo-

vanou vodou a suší se horkým vzduchem.

Po usušení následuje na některých výrobních linkách detekce vad prováděná pomocí laseru. Vady se na sklo barevně vyznačí a jejich velikost a rozmístění se uloží do optimalizačního systému. Ten na základě kvalitativních požadavků určí, která část skla se v další fázi vyřízne. Sklo s vadami se střepeje a znovu použije k tavení.

Díky lití skloviny na cín jsou obě strany skla téměř dokonale hladké a dosahují zrcadlové kvality. Výsledné sklo nevyžaduje další broušení ani leštění. [1]

1.2 Druhy vad

V této sekci popisuji, za jakých okolností vznikají vady skla. Ty následně dělím na dvě skupiny podle tvaru (bodové a čárové) a charakterizuji jejich vlastnosti.

Sklovina vyráběná procesem Float musí splňovat vysoké kvalitativní požadavky. Samozřejmostí je homogenita materiálu a dobré protavení bez bublinek. Toho lze docílit pouze striktním dodržováním technologické kázně ve všech fázích výroby.

Měl by být kladen velký důraz zejména na kontrolu parametrů dodávaných surovin, jejich přejímku a uskladnění. Další rizikovou fází je tavení skloviny, její vyčerení a homogenizace.

Nesplněním přísných pracovních postupů v některých z těchto stádií výroby může docházet k vadám ve skle, které negativně ovlivňují kvalitu produktu.

Vady ve skle lze podle tvaru rozdělit do dvou základních skupin: bodové vady (bezrozměrné, tzn. lze je definovat jedním bodem) a čárové vady, které opisují polynom maximálně druhého stupně (tzn. jednorozměrné až dvourozměrné, které lze definovat reálnou funkcí).

1.2.1 Bodové vady

Bodové vady jsou způsobeny během výroby skla, zejména kvůli nekvalitním surovinám, které obsahují nečistoty, nebo při nesprávném tavení, kdy není tavená sklovina dostatečně vyčereána. Jedná se hlavně o bublinky a kamínky uvnitř skla, ale i tečky na pokoveném povrchu.

Velikost bodové vady se pohybuje mezi 0,5 mm (bublinky, kamínky) a 1 cm (vady na pokoveném povrchu).

Příklady bodových vad můžete vidět na obrázku 1.1. Každý výřez má velikost 100 x 150 pixelů. V levém sloupci je snímek bodové vady pořízen sestaveným prototypem popsaném v sekci 2.1, v pravém sloupci je 3D graf tohoto snímku.

1.2.2 Čárové vady

Čárové vady vznikají především při manipulaci s hotovým sklem, typicky při řezání, broušení hran atp. Nejčastějším příkladem jsou škrábance a praskliny.

Rizikovou fází je i chlazení skla. Při nerovnoměrné teplotě dochází na krajích pásu k tahovému napětí, který má za následek vznik podélného lomu. Příčné lomy vznikají kvůli chybně nastaveným teplotám při chlazení.

Čárové vady dosahují velikosti od 5 mm do několika centimetrů a mají libovolnou orientaci. Hloubka vrypu u škrábanců může být různá.

Příklady čárových vad můžete vidět na obrázku 1.2. Každý výřez má velikost 100 x 150 pixelů. V levém sloupci je snímek vady pořízen sestaveným prototypem popsánem v sekci 2.1, v pravém sloupci je 3D graf tohoto snímku.

1.3 Popis zadání

Mým úkolem je detekovat a klasifikovat výše zmíněné vady.

Dle dodaných testovacích vzorků se vady vyskytují jednotlivě, nepřekrývají se a jsou lehce viditelné pouhým okem. Díky vyloučení překryvu se vady vyskytují pouze jako body nebo přímky (resp. paraboly) (uvažujeme teoretickou rovinu) a je snadnější určit jejich polohu a směr.

K dispozici mám prototyp snímacího zařízení detailně popsáný v realizační části mé práce v sekci 2.1. Všechny dodané vzorky jsou tímto prototypem zaznamenatelné, tzn. žádná z vad není natolik malá (bodová vada, prasklina) nebo mělká (škrábanec), aby splynula s digitálním šumem snímacího zařízení.

V praxi jsou jednotlivé vady reprezentovány jako shluk odlišných pixelů od okolí, u kterých lze najít střed (u bodových vad) a určit směr (u čárových vad).


Výsledkem mé práce je seznam detekovaných vad, klasifikace (zda se jedná o bodovou, nebo čárovou vadu), velikost a souřadnice středu bodové vady, nebo reálná funkce reprezentující čárovou vadu.

1.4 Současná řešení

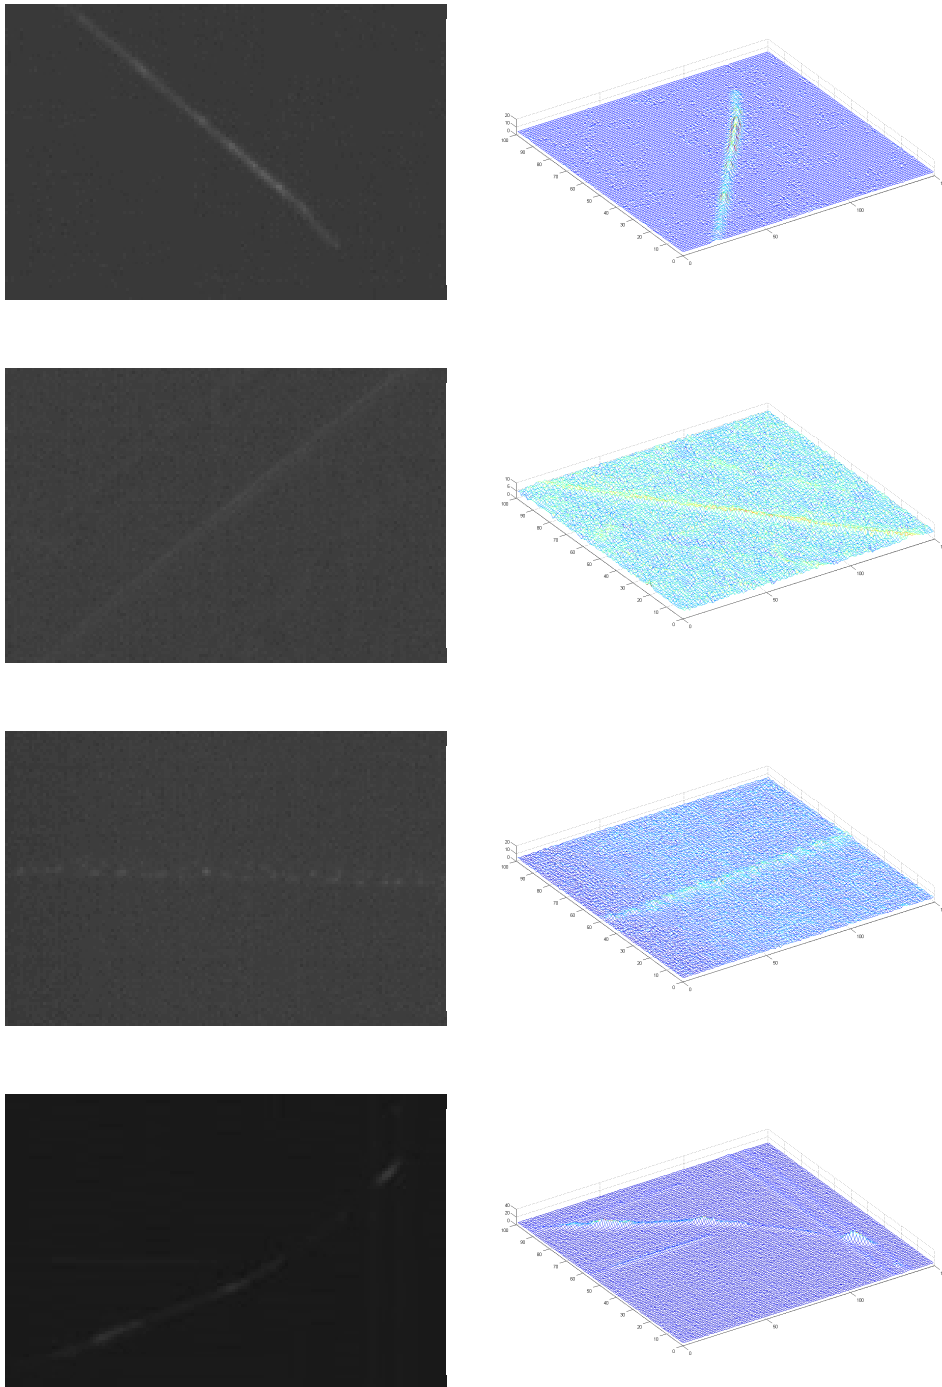
V této sekci se zabývám současnými řešeními detekce vad skla. Popisuji, jak probíhá ruční inspekce skleněných tabulí a jaká technika se využívá při automatické detekci. Detailně se věnuji detekci pomocí řádkové kamery a dělím ji na dva druhy podle způsobu nasvícení skla.

V současné době jsou vady detekovány vyškoleným pracovníkem továrny, který zrakem hledá vady na podsvícené tabuli skla. Tento lidský element může být pro efektivní výrobu problémový. Pracovník není vždy schopen podat v práci vyrovnaný výkon a v průběhu dne se může jeho soustředění snižovat. Oko se postupem času unaví a nemusí pokaždé objevit všechny vady výrobku. Kdybychom předpokládali, že se lidský zrak nikdy neunaví, stejně člověk není

1. ANALÝZA A NÁVRH



Obrázek 1.1: Příklad bodových vad a jejich grafů



Obrázek 1.2: Příklad čárových vad a jejich grafů (snímky byly kvůli lepší čitelnosti upraveny)

schopen zkontrolovat celou plochu skla, ale vždy jen zlomek. I rychlost tohoto způsobu kontroly je omezená, a tudíž pro velkovýrobu nedostačující.

Z tohoto důvodu přecházejí výrobní linky na automatizovanou detekci vad. Většina z nich využívá metody měření rozptylu laserového paprsku, kdy okolo vady má paprsek větší rozptyl než na místech bez vad. Povrch skla musí být v tomto případě absolutně suchý. Laser je schopen odhalit vady od 0,5 mm.

Další možností automatizace je skenování skla řádkovou kamerou. Staticky umístěná kamera (skener) kontinuálně snímá tabuli skla, kterou je možné nasvítit dvěma způsoby - spodním (sekce 1.4.2), nebo vrchním nasvícením (sekce 1.4.3). Princip skenování je popsán níže (sekce 1.4.1). Oproti detekci pomocí laseru je skenování pomocí řádkové kamery bez pohyblivých částí, a tedy i méně náročné na použítou technologii.

1.4.1 Princip skenování řádkovou kamerou

Tabulové sklo je opticky homogenní, což zaručuje stejné vlastnosti lomu světla po celé ploše. Světlo by proto mělo být umístěno staticky, aby se zaručil rovnoměrně nasvícený výsledný obraz.

Když se ve skle vyskytne defekt, světlo se láme jinak kvůli změně optických vlastností okolo vady. Díky tomu dojde k lokální odlišnosti intenzity světla, kterou kamera zaznamená.

Vady jsou pak v konečném snímku detekovány jako změny ve zvoleném barevném spektru. [2]

Všechny citované odborné články pracují s obrazem v odstínech šedi.

Fáze algoritmů detekce vad za použití řádkové kamery je u většiny současných řešení velmi podobná. Na začátku se ze snímku odstraní rušivé pozadí (pokud je to nutné), potom se snímek převede na binární obraz a nakonec se vyfiltrují falešné vady (hmyz, prach atp.). Některé algoritmy pak vady ještě klasifikují.

1.4.2 Spodní nasvícení

První možností, jak nasvítit sklo při skenování, je umístění zdroje světla pod sklo a jeho nasměrování kolmo na kameru, jak je znázorněno na obrázku 1.3. Toto řešení vytváří díky rozdílným frekvencím kamery a světla moirový efekt, který se projevuje jako pravidelné kontrastní pruhy. Tyto pruhy zvýrazňují vady skla, ale zároveň i přidávají šum do naskenovaného snímku.

Za těchto podmínek je v článku [2] popsána detekce bublin, kamínků a optické nehomogenity. Článek [3] detekuje kamínky a různé optické distorze a článek [4] kromě výše popsaného detekuje i praskliny.

Aby bylo možné vady detekovat, je potřeba pruhy ze snímku odstranit. Lze použít metodu dolního prahování, kde se hodnota prahu vypočítá na základě statistiky hodnot pixelů ve sloupcích [2] [4], nebo zabalenou fází vypočíta-

nou pomocí Fourierovy transformace a následnou rozbalenou fází [3]. Nyní je snímek připraven k detekci vad.

V další fázi se převádí obraz do binární podoby. Často se využívá matematické morfologie a segmentace obrazu. Jedna z metod binarizace je Otsův algoritmus používaný v [4], který je možno ještě předtím doplnit dolním prahováním [2], které rozliší jádro vady od optického zkreslení kolem ní. Jádrem vady se myslí samotná vada bez okolního šumu způsobeného moirovým efektem a optickými vlastnostmi kolem vady. Postačí i samotné prahování s kombinací nízkého a vysokého prahu a výběrem elementů s minimálním průměrem 7 pixelů jako v [3]. Konečným výsledkem je binární obraz, kde hodnota 1 znamená defekt.

Aby se eliminovala chybovost detekce, tak některé články ještě rozlišují skutečné vady od falešných (např. prach, hmyz, ...). Jak už bylo zmíněno, kolem každé vady se vytváří specifický šum způsobený změnou optických vlastností skla, který se ale u falešných vad nevyskytuje. Jednoduchým prahováním lze zjistit, zda se jedná o skutečnou vadu (kolem jádra je optické zkreslení), či nikoliv (jádro je osamoceno) [2].

Klasifikaci používá pouze článek [4]. Využívá MRA (Multiresolution analysis), kdy obraz rozloží pomocí diskretní vlnkové transformace na 4 další obrazy podle řádků a sloupců. S pomocí kombinace neuronové sítě a metody fuzzy k-nejbližších sousedů zhodnotí detekované vady.

Žádné z citovaných prací, které používaly spodní nasvícení, neodhalovaly škrábance. Tato povrchová vada totiž nemění strukturu skla tak zřetelně jako ostatní vady a při spodním nasvícení prakticky nelze detekovat. Z tohoto důvodu není spodní nasvícení vhodné pro mé použití.

1.4.3 Vrchní nasvícení

Druhou možností je nasvícení shora. Světlo se umístí nad sklo tak, aby svíralo se skleněnou tabulí ostrý úhel. Toto řešení napodobuje současnou kontrolu tabulových skel, kde si zaměstnanec na sklo svítí z různých úhlů a zrakem hledá vady. Pro ilustraci je nasvícení ukázáno na obrázku 1.3.


Prezentovaná řešení detekují různé bodové vady a škrábance ([5]) nebo bublinky a kamínky ([6]).

Tento způsob nasvícení nezpůsobuje moirový efekt (pruhy), a tak je pozadí jednolitě a ve většině případů ho není třeba filtrovat.

Pro detekci vad je hojně využívána Cannyho metoda [6][5]. [6] k převodu na binární obraz používá svou metodu založenou na konvoluci.

Klasifikování vad na bublinky a ostatní vady je možné provést s pomocí AdaBoost algoritmu založeném na BFH (Binary feature histogram) jako je uvedeno v [6].

Pomocí těchto řešení s vrchním nasvícením je možné detekovat bodové i čárové vady.



Obrázek 1.3: 3D model nasvícení skla

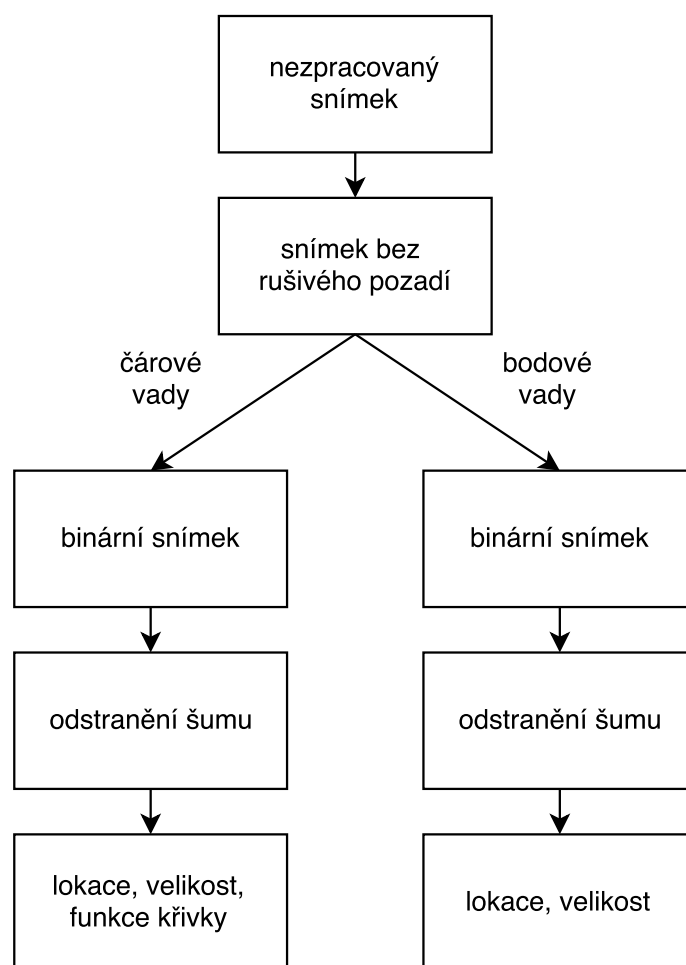
1.5 Návrh řešení

V této sekci popisuji mnou navržený algoritmus detekce vad skleněných tabulí. Jeho fáze jsou podobné jako u jiných současných řešení detekce vad popsáných v sekci 1.4. Algoritmus se skládá ze tří částí:

1. odstranění pozadí,
2. binarizace,
3. odstranění šumu.

První část je společná pro všechny vady, další dvě mají rozdílná řešení pro bodové a čárové vady. Grafické znázornění algoritmu můžete vidět níže (obrázek 1.4).

Na základě prototypu (sekce 2.1) jsou všechny vstupní snímky v odstínech šedi. Právě tento barevný prostor je podle [7], narozdíl od RGB, HSV a dalších, nejvhodnější pro detekci vad skla za použití hranové detekce, kterou (jak je popsáno v sekci 1.5.2) sama používám.



Obrázek 1.4: Vývojový diagram řešení

1.5.1 Odstranění pozadí

Ze zadání mého problému vyplývá, že je nutné detekovat všechny výše definované vady (sekce 1.2). Jak již bylo zmíněno, spodní nasvícení skla není vhodné pro odhalení škrábanců a konstrukce prototypu ho navíc neumožňuje. Proto jsem se rozhodla pro vrchní nasvícení, které je vzhledem k zadání práce vhodné.

Díky zvolenému nasvícení nedochází k moirovému efektu. Naskenovaný snímek však obsahuje rušivé elementy, které vznikly nedokonalým pozadím pod skenovaným sklem. Řádková kamera tak zachytí i světlejší podklad, který se na snímku projevuje svislými nekontrastními pruhy, které je nutné odstranit.

K tomu jsem využila metodu dolního prahování založenou na statistice hodnot pixelů ve sloupcích.

Pro každý pixel $p(i, j)$ se vypočítá nová hodnota $n(i, j)$,

$$n(i, j) = \begin{cases} p(i, j) - \text{median}(j), & \text{když } \text{median}(j) < p(i, j), \\ 0, & \text{jinak,} \end{cases} \quad (1.1)$$

kde $p(i, j)$ je hodnota pixelu na souřadnicích i (řádky) a j (sloupce) ve stupních šedi. $\text{Median}(j)$ je mediánem hodnot ve sloupci j .

Po detailní analýze matice nově vzniklého snímku jsem zjistila, že obraz stále obsahuje mnoho šumu, který na místech bez vad nabývá hodnot 1 stupně šedi. Snížením jasu o tuto hodnotu byl problém vyřešen.

Snímek je po odstranění pozadí bez rušivých elementů, které by mohly ovlivnit výsledek, a připraven k detekci. Bodové a čárové vady jsem se rozhodla detekovat zvlášť. Díky tomuto postupu není nutné vady na závěr klasifikovat - objevené vady budou klasifikovány na základě použitého algoritmu.

1.5.2 Binarizace

Po analýze matice snímku s odstraněným pozadím jsem zjistila, že bodové a čárové vady mají rozdílné vlastnosti. Bodové vady jsou zpravidla světlejší (mají vyšší hodnoty odstínu šedi) a rozdíl stran pomyslného obdélníku, který je ohraničuje, není velký. Naproti tomu čárové vady jsou oproti okolí méně kontrastní (hodnoty šedi jsou nižší) a poměr stran je větší.

Z toho důvodu jsem se rozhodla implementovat binarizaci snímku pro každý druh vad odlišně.

U čárových vad jsem podle literární rešerše zvolila Cannyho hranovou detekci. Tato metoda se ze všech vyzkoušených hranových detektorů jevila nejúčinnější. Vyzkoušela jsem i Sobelův a Prewittův operátor v různých velikostech, ale ani jeden nedokázal detekovat všechny vady (hrany) tak uspokojivě jako právě Canny.

Na bodové vady jsem se rozhodla použít prahování. Důvodem je vlastnost bodových vad, které jsou na snímku většinou světlejší než čárové vady, i než digitální šum snímku nebo prach. Po vyzkoušení několika prahů jsem se rozhodla pro hodnotu 15 stupně šedi, která odhalí všechny bodové vady. Hledání optimálního prahu Otsuovou metodou nebylo aplikovatelné, protože drtivá většina pixelů je hodně tmavá (0 - 5 v odstínech šedi) a histogram, který tato metoda používá, je značně nevyvážený.

Po těchto krocích reprezentují hodnoty 1 v binárním obraze vadu a hodnoty 0 místo bez vad. Na obraze ale stále zůstává mnoho falešně pozitivních vad (zvláště šum a prach), které odstraním v další části algoritmu.

1.5.3 Odstranění šumu

Metody odstranění šumu u bodových a čárových vad se od sebe liší stejně jako v minulé části. Sjednocujícím prvkem je použití matematické morfologie v obou případech.

K odstranění šumu u čárových vad jsem použila dilataci. Strukturním elementem byl obdélník o rozměrech 8 x 2 pixelů, který zaručil spojení sousedících komponent (shluku dotýkajících se hodnot 1 v binárním obraze), které by mohly tvořit souvislou čárovou vadu, ale díky nízkému kontrastu je Cannyho detektor vyhodnotil jako přerušované. Komponenty, které měly poměr stran menší než 1:5, byly smazány. Poměr stran se určí jako kratší strana ku delší straně pomyslného obdélníku, který ohraničuje komponentu a jehož strany jsou rovnoběžné s kartézskými souřadnicemi obrazu. Podobu strukturního elementu a poměr stran k filtraci komponent jsem určila na základě experimentů.

Tuto filtraci jsem postupně aplikovala 12x, pokaždé na obraz rotovaný o 15°. Všechny 12 obrazů jsem nakonec logicky sečetla. Tím se zaručila detekce různě směřovaných čárových vad.

Bodové vady jsem filtrovala také pomocí poměru stran, který nesměl být větší než 1:2. Dále jsem odstranila komponenty menší než 3 pixely a komponenty, které vyplňovaly svůj pomyslný ohraničující obdélník z méně než 50 %.

Výsledkem je binární obraz s komponentami, které reprezentují vady, a s odstraněným přebytečným šumem.

1.5.4 Implementační prostředí

Navržený algoritmus jsem se rozhodla implementovat ve skriptovacím jazyku Matlab.

Knihovna Image Processing Toolbox obsahuje mnoho algoritmů a funkcí pro zpracování obrazu, které jsou pro moji práci nezbytné.

Ačkoliv se předpokládá, že se v ostrém provozu použije Java, je tento nástroj pro vývoj velmi užitečný. Díky vizualizaci je prostředí interaktivnější a pohodovější pro ladění algoritmů.

Realizace

Tato kapitola je praktickou částí bakalářské práce. V první sekci popíšu prototyp skenovacího zařízení a metodiku měření, v druhé otestuji navržený algoritmus na reálných datech. Třetí sekce se věnuje metodice hodnocení a výsledkům naměřených dat. Na konci výsledky analyzuji a zhodnotím.

2.1 Prototyp skenovacího zařízení a metodika měření

K simulaci výrobní linky byl sestaven prototyp skenovacího zařízení (obrázek 2.1). Jeho komponenty jsou:


- průmyslová řádková kamera,
- LED pracovní světlo,
- odrazná deska,
- kapsa s černým sametem,
- kolejnice s rámem pro sklo,
- navíjecí cívka s motorem.

Řádková kamera snímá odstíny šedi v rozlišení 4k objektivem Kowa s délkou ohniska 35 mm. Clona byla nastavena přibližně na F3,7.

Rozlišení kamery vzhledem k velikosti snímaných skel odpovídá současným řešením v reálném provozu. V článku [2] používají osm 6k pixelových řádkových kamer, které jsou schopné snímat až 4,5 m široké sklo. Rozlišení je v takovém případě (0,1 mm x 0,1 mm)/pixel, stejně jako v článku [3].

Pracovní LED osvětlení s čočkami a difuzérem je umístěno nad sklo, naproti odrazné desce. Světlo tak dopadá na tabulové sklo pod ostrým úhlem ze dvou směrů. Bylo vyzkoušeno několik způsobů nasvícení - z různých směrů


2. REALIZACE



Obrázek 2.1: Prototyp skenovacího zařízení



Obrázek 2.2: Detail osvětlení a černé kapsy



Obrázek 2.3: 3D model prototypu

a pod různými úhly. Nejlepších výsledků dosahovalo řešení se světlem položeným vodorovně, směřující na odraznou desku, která svírala se sklem přibližně 68° . Detail osvětlení s odraznou deskou a černou kapsou je na obrázku 2.2.

Sklo je umístěno do rámu, který se posouvá po kolejnici za pomoci provázku a navíjecí cívky s motorem.

K zaručení co nejtmašího pozadí směřuje kamera na kapsu z černého sametu, přes kterou sklo přejíždí. Kapsa simuluje černé těleso a v ideálním případě pohlcuje veškeré záření, které do ní vniká. Nahrazuje původní řešení, kdy pod sklem byl samet pouze položen. Tento způsob byl ovšem nevyhovující kvůli vysokému šumu (výskytu podélných pruhů).

Celý prototyp je zakrytovaný tvrdým kartonem (jak je vidět na obrázku 2.1) a během skenování je přes kameru položena černá textilie. Toto opatření by mělo omezit průnik vnějšího světla na skenované sklo, a tak i zajistit stabilní

podmínky pro snímání.

Pro lepší názornost konstrukce prototypu jsem nakreslila 3D model (na obrázku 2.3).

2.2 Měření

Měření proběhlo na dodaných vzorcích skel s vadami z výroby a vlastních sklech s uměle vytvořenými vadami.

Na 6 vzorcích dodaných skel se vyskytuje 7 čárových a 3 bodové vady. Na 4 vlastních sklech je 22 čárových a 15 bodových vad, 4 vlastní skla jsou bez vad. Některá skla byla skenována vícekrát.

Dodaná skla mají tloušťku od 3 mm po 8 mm a 3 z nich mají pokovený povrch. Vlastní skla jsou čirá a 3 mm, 4 mm a 8 mm tlustá, 1 tmavé sklo má tloušťku 4 mm. Stejně vypadají vlastní skla bez vad.

Velikost testovacích snímků je v rozmezí od 1106x1380 pixelů do 3064x5000 pixelů. Nejvíce snímků má přibližně 2200x3000 pixelů. Rozlišení všech snímků je zhruba 250 DPI, což odpovídá cca 100 pixelům na 1 cm.

Velikost nejmenších vad (komponent) se pohybuje okolo 20 pixelů. Bodové vady měří od 5 do 45 pixelů, délka čárových vad se různí od 45 po 570 pixelů.

Všechny vady jsou na snímcích z řádkové kamery čitelné. Snímky obsahují kromě vad nezanedbatelné množství prachu. Ačkoliv jsem se tomu snažila předejít, nebylo možné vytvořit bezprašné prostředí pro skenování.

Příklady měření můžete vidět na obrázcích 2.4 (bodové vady) a 2.5 (čárové vady).


Obrázek 2.4 ukazuje ve čtyřech řádcích výřezy ze snímků s bodovými vadami. Fáze algoritmu všech vad jsou znázorněny ve třech sloupcích. Sloupce postupně obsahují:

1. nezpracovaný snímek z řádkové kamery,
2. snímek s odstraněným pozadím a zvýšeným kontrastem pro lepší čitelnost ukázky,
3. binární obraz detekované vady.


Na binární obraz jsem pro demonstraci použila dilataci se strukturálním elementem ve tvaru kruhu o poloměru 6 pixelů. Rozměr výřezů je 100x100 pixelů.

Na obrázku 2.5 můžete vidět čtyři výřezy čárových vad. Oproti obrázku s bodovými vadami obsahuje pouze snímky ve dvou sloupcích:

1. snímek s odstraněným pozadím a zvýšeným kontrastem pro lepší čitelnost ukázky,
2. binární obraz detekované vady.



Obrázek 2.4: Příklad měření (bodové vady)



Obrázek 2.5: Příklad měření (čárové vady)

V ukázce není nezpracovaný snímek z řádkové kamery z důvodu malého kontrastu vady, která by tedy nebyla čitelná. Rozměr výřezů je 100x150 pixelů.

Výsledky mého algoritmu jsou prezentovány v následující sekci.

2.3 Výsledky detekce vad

Tato sekce má dvě části. V první popisují metodiku hodnocení úspěšnosti detekce a v druhé prezentují výsledky naměřené podle této metodiky.

2.3.1 Metodika hodnocení

Detekované vady dělím na pozitivní (positives) a negativní (negatives) podle toho, jak byly algoritmem vyhodnoceny. Negativní vadou je ta, která byla při odstranění šumu smazána (považována za falešnou vadu - šum), a pozitivní je ta, kterou algoritmus po odstranění šumu vyhodnotil jako opravdovou (a je tedy ve výsledné binární matici). Abych mohla určit úspěšnost navrženého algoritmu, rozdělila jsem si vady do čtyř tříd:

- TP (True Positives),
- TN (True Negatives),
- FP (False Positives),
- FN (False Negatives).

Do třídy TP patří vada správně označená za opravdovou vadu, ve třídě TN jsou vady správně označené za falešnou vadu, FP jsou falešné vady označené za správné a ve FN jsou opravdové vady označeny za falešnou.

Počet vad ve třídách TP, FP a FN jsem počítala ručně podle toho, zda se vady na sklech opravdu vyskytovaly. Třída TN byla počítána automaticky jako součet vad, které byly vyřazeny při odstranění šumu.

Pro větší názornost efektivity mého algoritmu je nutně vypočítat několik statistických hodnot. Jako první TPR (True Positive Rate) neboli senzitivitu

$$TPR = \frac{TP}{TP + FN} \quad (2.1)$$

která měří poměr opravdových vad a vad, které tak byly skutečně označeny, dále TNR (True Negative Rate) neboli specificitu

$$TNR = \frac{TN}{TN + FP} = 1 - \frac{FP}{FP + TN} \quad (2.2)$$

což je schopnost testu přesně definovat ty vady, které jsou jen šumem snímku, poté PPV (Positive Predictive Value) neboli přesnost

$$PPV = \frac{TP}{TP + FP} \quad (2.3)$$

kteřá určuje, nakolik je algoritmus úspěšný v predikci opravdových vad, jako předposlední FOR (False Omission Rate)

$$FOR = \frac{FN}{FN + TN} \quad (2.4)$$

kteřá ukazuje neúspěšnost v predikování falešných vad a nakonec ACC (Accuracy)

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.5)$$


kteřá ukazuje poměr správně určených vad.

2.3.2 Naměřené hodnoty


Výsledky hodnot, které byly vypočítány podle metodiky hodnocení popsané výše (sekce 2.3.1), a součty vad ve třídách pro bodové vady jsou zobrazeny v tabulce 2.2, pro čárové vady v tabulce 2.3 a společné výsledky jsou v tabulce 2.4. Rozmístění vypočítaných hodnot je určeno tabulkou 2.1.

Poměrové zastoupení tříd je zobrazeno v koláčových grafech na obrázcích 2.6 (bodové vady), 2.7 (čárové vady) a 2.8 (všechny vady).


Analýza všech vypočítaných hodnot je provedena v následující sekci 2.4.



Obrázek 2.6: Poměrové zastoupení tříd u bodových vad



Obrázek 2.7: Poměrové zastoupení tříd u čárovových vad



Obrázek 2.8: Poměrové zastoupení tříd u všech vad

2. REALIZACE

		Predikce		
		pozitivní	negativní	
Skutečnost	pozitivní	TP	FN	TPR
	negativní	FP	TN	TNR
ACC		PPV	FOR	

Tabulka 2.1: Rozmístění statistických hodnot

		Predikce		
		pozitivní	negativní	
Skutečnost	pozitivní	35	8	0,8139
	negativní	246	320	0,5654
0,5829		0,1245	0,0243	

Tabulka 2.2: Výsledky - bodové vady

		Predikce		
		pozitivní	negativní	
Skutečnost	pozitivní	155	7	0,9567
	negativní	20	7046	0,9972
0,9962		0,8857	0,0009	

Tabulka 2.3: Výsledky - čárové vady

		Predikce		
		pozitivní	negativní	
Skutečnost	pozitivní	190	15	0,9268
	negativní	266	7366	0,9652
0,9641		0,4166	0,0020	

Tabulka 2.4: Výsledky - všechny vady

2.4 Zhodnocení

V této sekci analyzuji výše naměřené statistické hodnoty pro jednotlivé druhy vad a pro všechny vady společně.

2.4.1 Bodové vady

V tabulce 2.2 a grafu na obrázku 2.6 je vidět, že počet vad ve skupině FP je několika násobně větší než vady ve skupině TP. Následkem toho je přesnost (PPV) velmi nízká (12,45 %). Znamená to, že můj algoritmus má tendenci označovat vady za opravdové, i když to tak doopravdy není. Myslím si, že je to způsobeno kvalitou naskenovaných snímků. Při skenování nebylo možné vytvořit dokonale bezprašné prostředí a na sklech zůstávala zrnka prachu, která mají podobnou velikost jako bodové vady. Ta byla následně vyhodnocena jako vada ve skle, ačkoliv opravdových vad tam bylo daleko méně. Předpokládám, že v ostrém provozu by k takovému jevu nedošlo a přesnost mého algoritmu by byla vyšší.

Následkem toho je i specifita (TNR) značně ovlivněna, ale nemyslím si, že by to bylo pro efektivitu navrženého algoritmu zásadní, protože cílem továren je co nejvíce snížit dodávku vadných skel, což si s nízkou specificitou neodporuje.

Algoritmus se spletl v osmi případech, kdy opravdovou vadu označil za falešnou. Oproti vadám v TN je toto číslo malé, a tak je neúspěšnost v predikci opravdových vad (FOR) nízká (2,43 %). Senzitivita je pak s 81,39 % uspokojivá.

Procento správně určených vad (ACC) je 58,29 %, což se dá považovat za téměř náhodný detektor bodových vad. Jak už jsem psala výše, předpokládám, že v bezprašném prostředí by byla tato hodnota daleko vyšší.

2.4.2 Čárové vady

Na rozdíl od bodových vad jsou statistické hodnoty čárových vad v tabulce 2.3 a grafu na obrázku 2.7 o poznání pozitivnější.

Z grafu na obrázku 2.7 je jasně vidět, že dominuje třída TN. Právě ta ovlivní téměř všechny následující hodnoty.

Algoritmus neodhalil pouze sedm opravdových vad, a tak je senzitivita testu (TPR) vysoká (95,67 %). Ve srovnání s počtem vad ve třídě TN je toto číslo více než 1000x menší, což způsobuje neúspěšnost v predikování falešných vad (FOR) téměř zanedbatelnou (0,09 %).

S tím souvisí i specifita (TNR), která je v tomto případě 99,72 %. Odstranění šumu u čárových vad je tedy velice přesné.

Za opravdové vady bylo označeno jenom dvacet skutečně falešných vad. Přesnost algoritmu (PPV) je pak 88,57 %.

Ze všech součtů vad ve třídách mohu říci, že procento správně určených vad (ACC) je velmi vysoké (99,62 %) a detekce čárových vad téměř dokonalá.

2.4.3 Celková úspěšnost

V tabulce 2.4 jsou na místech TP, TN, FP a FN součty hodnot z tabulek 2.2 (bodové vady) a 2.3 (čárové vady). Poměr těchto hodnot je znázorněn v koláčovém grafu na obrázku 2.8. Ostatní hodnoty jsou podle těchto součtů dopočítány.

Stejně jako u bodových vad, i tady je počet falešných vad predikovaných jako pozitivní větší než počet opravdových vad predikovaných jako pozitivní, a tak i zde je přesnost (PPV) poměrně malá (41,66 %).

Ostatní hodnoty jsou srovnatelné s tabulkou čárových vad (tabulka 2.3). Díky velikému rozdílu počtu vad ve třídách FN a TN je opět neúspěšnost v predikování vad (FOR) velmi nízká (0,2 %). Senzitivita (TPR) je opět vysoká (92,68 %) díky nízkému počtu opravdových vad, které byly vyhodnoceny jako falešné. Specificita (TNR) je s významným příspěvkem třídy TN od čárových vad 96,52%.

Procento správně určených vad (ACC) vychází na 96,41 %.

V konečném důsledku je můj algoritmus na testovaných sklech téměř bezchybný. Je ale nutno říci, že počet bodových a čárových vad byl nevyvážený, proto není vhodné měřit úspěšnost na základě procenta správně určených vad (ACC). Vysoká čísla ve třídě FP u bodových vad a ve třídě TN u čárových vad významně ovlivňují celkový výsledek. Důvodem je již několikrát zmíněný prach na skle a také odstraňování šumu u čárových vad, kde Cannyho hranový detektor zachytí i některé bodové vady, které jsou pak vyfiltrovány (a tedy započítány do třídy TN, kterou významně navyšuje). Naproti tomu při prahování u bodových vad nemusí být čárová vada vůbec zachycena. Tato čísla pak ovlivňují všechny statistické hodnoty až na senzitivitu (TPR). Ta pracuje pouze s počtem opravdových vad predikovaných jako opravdové a počtem opravdových vad predikovaných jako falešné. Algoritmus se v těchto testech změnil dohromady jenom 15x a 190x predikoval správně, což lze považovat za velice úspěšné.

Závěr

Cílem mé bakalářské práce bylo navrhnout a implementovat algoritmus, který by byl schopný detekovat vady skla.

Nastudovala jsem metody zpracování obrazu a jejich implementaci ve jazyku Matlab. Tento skriptovací jazyk jsem si zvolila za své implementační prostředí, protože je vhodný pro vývoj aplikací zpracování obrazu.

Během analýzy současných řešení zadaného problému jsem se seznámila s procesem výroby plaveného skla a jeho rizikových fází, ve kterých mohou vady vznikat. Podle dodaných vzorků vadných skel jsem rozdělila vady do dvou kategorií na bodové a čárové. Popsala jsem podmínky, za kterých vznikají, a určila jejich vlastnosti.

Dále jsem zkoumala různá řešení jejich detekce. Na základě těchto znalostí jsem navrhla své řešení detekce vad a implementovala ho v Matlabu. Jeho funkčnost jsem vyzkoušela na dodaných a vlastních vzorcích skel. Změřila jsem efektivitu detekce a zhodnotila výsledky.

Výsledkem práce je algoritmus, který dokáže detekovat a klasifikovat vady skla.

Pro účely reálného nasazení v praxi bylo by příhodné přepsat algoritmus do vhodnějšího programovacího jazyka (např. Java, C++, ...). Současná implementace není schopná detekovat vady dostatečně rychle, a proto je nutné ji optimalizovat, aby stačila reálnému provozu továrny.

Dále by bylo vhodné otestovat algoritmus na reálných datech (nejlépe snímky z výroby, které neobsahují rušivé elementy, např. prach) a na základě výsledků algoritmus doladit. Také by se dalo uvažovat o vylepšení detekce bodových vad, aby se redukoval počet falešných vad označených jako opravdové, čímž by se zvýšila specifická a přesnost celého detektoru vad.

Způsob detekce vad pomocí vrchního nasvícení je alternativou k detekci pomocí laseru. Neobsahuje žádné pohyblivé části, a hardware je tak mnohem levnější. Přesností se laseru vyrovná, protože je také schopen detekovat vady okolo 0,5 mm.

Do budoucna by se dalo uvažovat o rozšíření algoritmu na jiné transpa-

ZÁVĚR

rentní materiály než sklo nebo hladké povrchy jako ploché monitory (LCD, OLED) a kovové pláty.

Literatura

- [1] Štěpán POPOVIČ: *Výroba a zpracování plochého skla*. Praha: Grada, 2009.
- [2] PENG Xiangqian, W. Y. Z. Z. a. G. S., Youping CHEN: An online defects inspection method for float glass fabrication based on machine vision. *The International Journal of Advanced Manufacturing Technology*, ročník 39, č. 11–12, 2008: s. 1180–1189, doi:10.1007/s00170-007-1302-7, [online]. Dostupné z: <http://link.springer.com/10.1007/s00170-007-1302-7>
- [3] JIN Yong, Y. C. X. K. L. W. a. W. Q., Zhaoba WANG: Study on inspection method of glass defect based on phase image processing. *Optik - International Journal for Light and Electron Optics*, ročník 125, č. 19, 2014: s. 5846–5849, doi:10.1016/j.ijleo.2014.07.021, [online]. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0030402614007621>
- [4] LIU Huai-guang, X.-q. P. a. J.-m. X., You-ping CHEN: A classification method of glass defect based on multiresolution and information fusion. *The International Journal of Advanced Manufacturing Technology*, ročník 56, č. 9–12, 2011: s. 1079–1090, doi:10.1007/s00170-011-3248-z, [online]. Dostupné z: <http://link.springer.com/10.1007/s00170-011-3248-z>
- [5] ADAMO Francesco, A. D. N. a. M. S., Filippo ATTIVISSIMO: A low-cost inspection system for online defects assessment in satin glass. *Measurement*, ročník 42, č. 9, 2009: s. 1304–1311, doi:10.1016/j.measurement.2009.05.006, [online]. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0263224109001134>
- [6] ZHAO Jie, X. Z. J. L. a. Y. L., Qing-Jie KONG: A Method for Detection and Classification of Glass Defects in Low Resolution Images. doi:10.1109/ICIG.2011.187. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6005627>

LITERATURA

- [7] SINGH Tribhuwan, S. A. a. A. A., Rajeshwar LAL DUA: Detection of Defects in Glass Sheet using C. S. C based Segmentation Method. *International Journal of Computer Applications*, ročník 68, č. 14, 2013: s. 29–32, doi:10.5120/11650-7152, [online]. Dostupné z: <http://research.ijcaonline.org/volume68/number14/pxc3887152.pdf>

Seznam použitých zkratk

- MRA** Multiresolution Analysis
ICA Independent Component Analysis
BFH Binary Feature Histogram
LED Light-Emitting Diode
DPI Dots Per Inch
TP True Positive
TN True Negative
FP False Positive
FN False Negative
TPR True Positive Rate
TNR True Negative Rate
PPV Positive Predictive Value
FOR False Omission Rate
ACC Accuracy

Obsah přiloženého CD

	readme.txt.....	stručný popis obsahu CD
	data.....	nezpracované snímky skel
	src	
	impl.....	zdrojové kódy implementace
	thesis.....	zdrojová forma práce ve formátu L ^A T _E X
	text	
	assignment.pdf.....	zadání práce ve formátu PDF
	thesis.pdf.....	text práce ve formátu PDF