

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV AUTOMATIZACE A MĚŘICÍ TECHNIKY

DEPARTMENT OF CONTROL AND INSTRUMENTATION

FOKUSOVACÍ TECHNIKY OPTICKÉHO MĚŘENÍ 3D VLASTNOSTÍ

FOCUS TECHNIQUES OF OPTICAL MEASUREMENT OF 3D FEATURES

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Jan Macháček

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Ilona Janáková, Ph.D.

BRNO 2021

Diplomová práce

magisterský navazující studijní program **Kybernetika, automatizace a měření**

Ústav automatizace a měřicí techniky

Student: Bc. Jan Macháček

ID: 195678

Ročník: 2

Akademický rok: 2020/21

NÁZEV TÉMATU:

Fokusovací techniky optického měření 3D vlastností

POKYNY PRO VYPRACOVÁNÍ:

Cílem práce je teoreticky zpracovat fokusovací techniky (varianta triangulačních metod) optického měření vzdálenosti, resp. rekonstrukce 3D vlastností objektů, a vybrané techniky experimentálně ověřit. Práce by se měla zaměřit především na techniky: konfokální mikroskopie, kontrolované fokusování a metoda rozfokusování.

1. Provedte rešerši fokusovacích technik – zaměřte se na princip jednotlivých technik, jejich porovnání a současný stav poznání.
2. Provedte průzkum trhu nabízených snímačů využívajících tyto principy měření.
3. Nejméně dvě techniky experimentálně ověřte:
 - 3a. Nastudujte, případně navrhnete teoretický postup.
 - 3b. Sestavte experimentální pracoviště.
 - 3c. Zkalibrujte.
 - 3d. Vyberte vhodný měřený objekt.
- 3e. Navrhnete a implementujte algoritmy vyhodnocení vzdálenosti/měření 3D vlastností.
4. Výsledky zpracujte, stanovte omezující podmínky, zhodnoťte, porovnejte.

DOPORUČENÁ LITERATURA:

SUWAJANAKORN, Supasorn, Carlos HERNANDEZ a Steven M. SEITZ. Depth from focus with your mobile phone. In: 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2015, 2015, s. 3497-3506. DOI: 10.1109/CVPR.2015.7298972. ISBN 978-1-4673-6964-0.

YOON, Sang Youl, Ji-chul HYUN a Sung YANG. Simple refractometry using optical path separation via multiple pinholes. Micro and Nano Systems Letters. 2017, 5(1). DOI: 10.1186/s40486-017-0043-0. ISSN 2213-9621.

Termín zadání: 8.2.2021

Termín odevzdání: 17.5.2021

Vedoucí práce: Ing. Ilona Janáková, Ph.D.

doc. Ing. Petr Fiedler, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Tato práce se zabývá optickým měřením vzdáleností, resp. měřením 3D vlastností scény pomocí fokusovacích technik se zaměřením na metody: konfokální mikroskopie, kontrolované fokusování a metodu rozfokusování. Teoretická část práce pojednává o různých přístupech k rekonstrukci hloubky obrazu a také o technice mikro-rozfokusování obrazu pro měření refrakčního indexu transparentních materiálů. Následně je zde popsána problematika kalibrace kamery pro fokusovací techniky. V praktické části práce je experimentálně ověřena metoda kontrolovaného fokusování a metoda rozfokusování. Pro první metodu jsou zde ukázány výsledky rekonstrukce hloubky scény. Pro druhou metodu je zde porovnání naměřených hodnot vzdáleností se skutečnými hodnotami. Na závěr této práce jsou zkoumané metody porovnány a zhodnoceny.

KLÍČOVÁ SLOVA

Fokusovací techniky, konfokální mikroskopie, kontrolované fokusování, metoda rozfokusování, DFF, DFD, refrakční index, optické měření vzdáleností, hloubka scény, hloubková mapa

ABSTRACT

This thesis deals with optical distance measurement and 3D scene measurement using focusing techniques with focus on confocal microscopy, depth from focus and depth from defocus. Theoretical part of the thesis is about different approaches to depth map generation and also about micro image defocusing technique for measuring refractive index of transparent materials. Then the camera calibration for focused techniques is described. In the next part of the thesis is described experimentally verification of depth from focus and depth from defocus techniques. For the first technique are shown results of depth map generation and for the second technique is shown comparison between measured distance values and real distance values. Finally, the discussed techniques are compared and evaluated.

KEYWORDS

Focusing techniques, confocal microscopy, depth from focus, depth from defocus, DFF, DFD, refractive index, optical distance measurement, scene depth, depth map

MACHÁČEK, Jan. *Fokusovací techniky optického měření 3D vlastností*. Brno, 2021, 99 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav automatizace a měřicí techniky. Vedoucí práce: Ing. Ilona Janáková, Ph.D.

PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma „Fokusovací techniky optického měření 3D vlastností“ jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského 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, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autora

PODĚKOVÁNÍ

Rád bych poděkoval vedoucí diplomové práce paní Ing. Iloně Janákové, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Obsah

Úvod	17
1 Optické 3D vidění	19
1.1 Měření doby letu (Time of Flight)	20
1.2 Interferometrie	20
1.3 Triangulace	21
1.3.1 Aktivní triangulace	21
1.3.2 Pasivní triangulace	22
2 Rešerše fokusovacích technik	23
2.1 Konfokální mikroskopie	23
2.1.1 Rastrující konfokální mikroskop	24
2.1.2 Konfokální mikroskop založen na metodě Nipkowova disku	25
2.1.3 Konfokální mikroskop založen na akusticko-optickém deflektoru	25
2.1.4 Konfokální snímače	26
2.2 Kontrolované fokusování	27
2.2.1 Literární rešerše	27
2.2.2 Kalibrace kamery	36
2.2.3 Estimace hloubkové mapy	37
2.3 Metoda rozfokusování	43
2.3.1 Hloubka ostrosti	44
2.3.2 Literární rešerše	45
2.3.3 Kalibrace kamery	47
2.3.4 Měření vzdálenosti	50
2.4 Technika mikro-rozfokusování obrazu	51
2.4.1 Vznik metody	51
2.4.2 Princip metody	51
2.4.3 Výsledky práce autorů S.Y.Yoon a S.Yang	54
2.4.4 Návrh možného použití metody pro měření vzdálenosti	55
3 Průzkum trhu nabízených snímačů	57
3.1 Konfokální snímače	57
3.1.1 Firma Micro-Epsilon	57
3.1.2 Firma Keyence	59
3.2 Konfokální mikroskopy	60
3.2.1 Firma Zeiss	60
3.2.2 Firma BioTek	62

4 Experimentální ověření	63
4.1 Experimentální pracoviště, vývojové prostředí	63
4.1.1 Komunikace s modulem Canon EF	65
4.1.2 Komunikace s kamerou	66
4.2 Kontrolované fokusování	66
4.2.1 Kalibrace kamery	67
4.2.2 Estimace hloubkové mapy	72
4.3 Metoda rozfokusování	79
4.3.1 Automatizované pořízení snímků	79
4.3.2 Kalibrace kamery	81
4.3.3 Měření vzdálenosti	82
4.4 Výsledky implementovaných metod	82
4.4.1 Kontrolované fokusování	82
4.4.2 Metoda rozfokusování	86
Závěr	87
Literatura	91
Seznam symbolů, veličin a zkratek	95
A Výsledky estimované hloubkové mapy	97
B Obsah přiloženého CD	99

Seznam obrázků

1.1	Základní rozdělení optického 3D vidění	19
1.2	Princip měření vzdálenosti pomocí měření doby letu	20
1.3	Princip interferometru	21
1.4	Princip aktivní triangulace	22
2.1	Konfokální mikroskop	24
2.2	Konfokální mikroskop	25
2.3	Princip akusticko-optického deflektoru	26
2.4	Schéma chromatického konfokálního snímače	27
2.5	Hloubková mapa (Valencia, Rodriguez-Dagnino)	28
2.6	Hloubková mapa (Ge Guo, Nan Zhang)	28
2.7	Test měření ostrosti (Malik, Shim)	29
2.8	Operátory pro měření ostrosti (Malik, Shim)	30
2.9	Výsledky segmentace (Li, Ngan)	30
2.10	Extrakce hloubkové mapy (Deng, Jiang)	31
2.11	Vývojový diagram (Huang, Cheng)	32
2.12	Vstupní snímky (Huang, Cheng)	33
2.13	Výstupní snímky (Huang, Cheng)	33
2.14	Výsledek (Huang, Cheng)	33
2.15	Aplikovaný Gaussův filtr na rozptylovou funkci (Chen, Wu)	34
2.16	Série snímků (Chen, Wu)	35
2.17	Hloubková mapa (Chen, Wu)	35
2.18	Schéma neuronové sítě typu enkodér-dekodér (Neurohive)	36
2.19	Estimace hloubky s porovnáním ostatních metod (Neurohive)	36
2.20	Znázornění optického toku	38
2.21	Typy hran	39
2.22	Operátor LoG	40
2.23	Odezva operátoru log na skok	41
2.24	Použití operátoru log na snímku	41
2.25	Znázornění lineárního míchání	42
2.26	Ukázka alfa míchání	42
2.27	Model kamery	43
2.28	Hloubka ostrosti	45
2.29	Vstupní snímky pro DFD (Ziou, Deschenes)	46
2.30	Estimace hloubkové mapy metodou DFD (Ziou, Deschenes)	46
2.31	Umělé rozostření obrázku pro test DFD (Rajagopalan, Chaudhuri)	47
2.32	Výsledek DFD (Rajagopalan, Chaudhuri)	47
2.33	Princip mikro-rozfoksování obrazu (Yoon, Yang)	52

2.34	Efekt různých refrakčních indexů na kroužek (Yoon, Yang)	53
2.35	Optický model mikro-rozfokusování obrazu (Yoon, Yang)	53
2.36	Skleněná tabulka s chromovou vrstvou a dírkami (Yoon, Yang)	54
2.37	Změna kroužku v závislosti na RI a změně osy z (Yoon, Yang)	55
2.38	Principiální návrh měření vzdálenosti	56
3.1	Příklady použití konfokálních snímačů firmy Micro-Epsilon	58
3.2	Kontrolér od firmy Micro-Epsilon	59
3.3	Konfokální mikroskop firmy Zeiss	60
3.4	Princip metody Airyscan	61
3.5	Myší mozek pod konfokálním mikroskopem	61
3.6	Unikátní architektura konfokálního mikroskopu BioTek	62
4.1	Nákres experimentálního pracoviště	63
4.2	Ukázka způsobu focení kalibračního objektu	64
4.3	Modul Cannon EF	64
4.4	Formát řetězce pro ovládání objektivu	65
4.5	Vývojový diagram automatizovaného pořizování snímků	67
4.6	Nastavení vstupních parametrů pro zachycení snímků	68
4.7	Informativní okno pro nastavení vzdálenosti objektu	68
4.8	Ukázka kalibračního kříže	69
4.9	Vývojový diagram výpočtu kalibrace kamery pro metodu DFF	70
4.10	Závislost zaostření na vzdálenosti	71
4.11	Vývojový diagram metody DFF	72
4.12	Ukázka obrazového zásobníku	73
4.13	Příklad zarovnání snímků obrazového zásobníku	74
4.14	Detekce hran ve snímku zaostřeném na popředí	75
4.15	Detekce hran ve snímku zaostřeném na pozadí	75
4.16	Hloubková mapa estimovaná pomocí DFF bez vyhlazení	77
4.17	Hloubková mapa estimovaná pomocí DFF s vyhlazením	77
4.18	Sešití zaostřených vrstev	78
4.19	Hloubková mapa po segmentaci	79
4.20	Vývojový diagram automatizovaného pořizování snímků	80
4.21	Dialogové okno pro určení způsobu snímání	81
4.22	Ukázka referenčních snímků	81
4.23	První a poslední snímek zadních stran karet	83
4.24	Sešitý ostrý snímek karet	83
4.25	Hloubka scény s kartami ve formátu HSV	84
4.26	Hloubková mapa matiček a šroubků	84
4.27	Hloubková mapa klíče	85
4.28	Hloubková mapa malého úchyty	85

4.29	Hloubková mapa stroužku česneku	85
A.1	Hloubková mapa matiček a škoubků	97
A.2	Hloubková mapa klíče	97
A.3	Hloubková mapa malého úchytu	98
A.4	Hloubková mapa stroužku česneku	98

Úvod

Měření vzdáleností, resp. 3D vlastností objektů je dnes velmi žhavé téma, které hraje svou velkou roli jak v průmyslu při měření kvality a zpracování výrobků, tak v televizním a herním odvětví. Při pořizování snímků 3D scény běžnou kamerou dochází k redukci tří složek (x, y, z) pouze na dvě složky (x, y) . Dochází tedy ke ztrátě z složky. Přesto jsou lidé schopní na základě svých zkušeností a dosavadního poznání trojrozměrného světa identifikovat, které objekty se nachází v popředí, a které v pozadí. V sektoru počítačového vidění existuje celá řada způsobů zabývajících se rekonstrukcí 3D scény, přičemž některé přístupy dokáží rekonstruovat 3D vlastnosti pouze z jednoho či několika 2D snímků a jiné přístupy vyžadují dodatečné informace o scéně již při snímání.

Cílem této práce je teoretické zpracování fokusovacích technik pro optické měření vzdáleností, resp. rekonstrukce 3D vlastností objektů se zaměřením na metody konfokální mikroskopie, kontrolovaného fokusování a metodu rozfokusování. Dále je potřeba vybrat a nasnímat vhodné měřené objekty a vybrané techniky na nich experimentálně ověřit.

Na začátku této práce jsou obecně představeny metody optického měření vzdáleností a 3D vlastností scény. Dále jsou popsány fokusovací techniky a metody spadající do této kategorie. Jsou zde rozebrány různé principy konfokálních mikroskopů. Dále je v práci rozebrána metoda kontrolovaného fokusování a metoda rozfokusování. Jsou zde popsány různé přístupy autorů ostatních prací na tato témata. Na závěr teoretické části je popsána metoda mikro-rozfokusování obrazu, která pomocí měření světelných vlastností materiálů slouží k získání chemických vlastností.


Pro praktické otestování metod je nutné sestavit experimentální pracoviště. Pro metodu kontrolovaného fokusování a metodu rozfokusování je potřeba připravit obrazový zásobník, který bude obsahovat daný objekt nasnímaný s různým nastavením zaostření kamery dle potřeb jednotlivých metod. To je vhodné provést s laboratorní kamerou, která umožňuje přesné nastavení zaostření, především z důvodu následné kalibrace reálné vzdálenosti a vytvoření hloubkové mapy scény. Pro pořizování snímků je zapotřebí rozdílných algoritmů pro obě výše zmíněné metody. Také je vhodné u každé metody použít oddělené algoritmy pro pořizování snímků a výpočet vzdálenosti, resp. vytvoření hloubkové mapy zejména z důvodu variability možných řešení.

Pro experimentální ověření metod se jeví jako dostačující použít prostředí Matlab s rozšířením o knihovny počítačového vidění a také z tohoto prostředí přímo ovládat nastavení objektivu a pořizování snímků.

1 Optické 3D vidění

Lidé dokáží rozeznat 3D vlastnosti scény z 2D obrazu aniž by si to přímo uvědomovali nebo se na to více soustředili. Lidský mozek totiž dokáže díky zkušenostem z reálného světa a různým prvkům ve scéně rekonstruovat hloubku scény. V oblasti počítačového vidění existuje řada metod pro tyto účely. Některé metody se zaměřují na rekonstrukci třetího rozměru z 2D snímku, jiné používají již při snímání dodatečné nástroje pro záznam třetího rozměru. Například metody spadající do kategorie aktivní triangulace, které dokáží zachytit originální obraz dané scény a současně detekovat hloubku každého bodu. Tyto kamery tedy potřebují další snímač případně zdroj světla (např. laser) k získání hloubkové mapy, a tím pádem jsou dražší v porovnání s ostatními přístupy jako jsou například metody z oblasti pasivní triangulace. Nevýhoda vyšší ceny je ovšem u aktivní triangulace vykompenzována vyšší kvalitou a přesností detekce hloubkové mapy. Dalšími metodami spadajícími do oblasti triangulačních technik jsou fokusovací techniky, u kterých je velkou výhodou použití pouze jedné kamery umožňující změnu zaostření, příp. změnu clony. Základní rozdělení optického 3D vidění lze vidět na obr. 1.1.


Nevýhodou pasivní triangulace a fokusovacích technik je nutnost snímky po záznamu digitálně zpracovat. To vede k vyšším výpočetním nárokům a také k delší době pro získání informace o hloubce scény. K pasivní triangulaci se řadí zejména techniky stereoskopie, fotometrické techniky a fotogrammetrie. [1][2]



Obr. 1.1: Základní rozdělení optického 3D vidění. [3]

1.1 Měření doby letu (Time of Flight)

Princip měření vzdálenosti objektu u této metody spočívá v jednoduchém měření doby letu světelného paprsku, který je nejprve vyslán ze zdroje světla (typicky laser) směrem k objektu, od kterého se následně odráží zpět do snímače [3]. To lze vidět na obr. 1.2.




Obr. 1.2: Princip měření vzdálenosti pomocí měření doby letu. [4]

Pro vzdálenost platí rovnice $s = vt$, za rychlost v lze dosadit konstantu rychlosti světla c . Pokud paprsek urazí ze zdroje světla k objektu a od objektu ke snímači stejnou dráhu, lze za čas t dosadit $\frac{t}{2}$ pro určení doby letu pouze jedné dráhy. Výsledná rovnice pro výpočet dráhy letu paprsku tedy bude:

$$s = \frac{c}{2}t \quad (1.1)$$

1.2 Interferometrie

Interferometrie je technika měření vzdálenosti, ve které se využívají měřicí a referenční koherentní vlnoplochy. Ty se navzájem v detektoru překrývají a tím vznikne interferogram indikující fázový posuv vlnoploch. Jelikož interferogram reprezentuje periodicky opakující se signál, nelze touto technikou měřit absolutní vzdálenost v celém rozsahu interferometru, ale vždy pouze v rozsahu $\lambda/2$. Homodynní interferometry dosahují přesnosti $\lambda/100$ a heterodynní až $\lambda/1000$. Přesné měření touto metodou vyžaduje mechanicky velmi stabilní soustavu. [3]



Obr. 1.3: Princip interferometru.

1.3 Triangulace

Triangulační techniky jsou jedny z nejpoužívanějších způsobů optického měření vzdáleností a 3D vlastností scény. Patří zde zejména aktivní triangulace, pasivní triangulace a fokusovací techniky, kterými se dále zabývá tato práce. Dále do triangulačních technik patří měření vzdáleností pomocí teodolitu a podoba ze stínování.

1.3.1 Aktivní triangulace

U aktivní triangulace paprsek ze zdroje světla zaostřený čočkou, detektor a zkoumaný objekt vytvoří triangulační trojúhelník viz obr. 1.4. Na straně zdroje světla je úhel emitovaného paprsku přesně definovaný a na straně detektoru je úhel měřen CCD senzorem nebo pomocí fotodetektoru (PSD). Díky takto změřenému úhlu lze určit hloubku scény. [3]


Rozlišení hloubky scény δz osvětlené laserem je dána jako

$$\delta z = \frac{\lambda}{2\pi \sin \theta \sin \alpha_d} \quad (1.2)$$

Měřicí rozsah Δz (dvojnásobná hloubka ostroty) je dán jako

$$\delta z = \frac{2\lambda}{\sin^2 \alpha_d} \quad (1.3)$$

kde $\sin \alpha_d$ a θ je velikost clony optiky detektoru a triangulační úhel. Pro estimaci hloubkové mapy scény pomocí 1D laseru je vyžadován sken v ose x i y . Jedním z dalších přístupů je rozšířit paprsek pomocí cylindrické čočky do 2D roviny, kdy



Obr. 1.4: Princip aktivní triangulace. [3]

průřez světelného paprsku a objektu vytvoří výškový profil, který je zobrazen pomocí 2D detektoru. Tím pádem lze pomocí 1D skenování získat 3D vlastnosti scény, což lze vidět na obr. 1.4. [3].

1.3.2 Pasivní triangulace

Do pasivní triangulace patří metody měření 3D vlastností scény, které ke své funkci nevyžadují žádný druh přídavného zdroje světla nebo záření, ale detekují pouze okolní osvětlení. Většina metod spadajících do této kategorie detekují viditelné světlo, zejména z důvodu jeho snadné dostupnosti. Další typy, například jako infračervené kamery mohou být taky použity. Pasivní metody jsou v porovnání s ostatními metodami velmi levné, protože ve většině případů nepotřebují dodatečný hardware, ale pouze jednoduché kamery. [2]

Stereoskopické techniky většinou používají dvě kamery umístěné v malé vzdálenosti od sebe, namířené na stejnou zkoumanou scénu. Analýzou malých změn mezi snímky pořízenými každou z kamer, je možné určit vzdálenost v každém bodě snímku. Tyto metody jsou založeny na stejném principu jako lidské vnímání prostředí pomocí dvou očí.

Fotometrické techniky většinou používají jednu kameru, která pořídí několik snímků se změněným osvětlením.

Další technikou spadající do pasivní triangulace je fotogrammetrie, která poskytuje informace o 3D tvarech fyzických objektů založené na analýze několika snímků. Výsledná 3D data poskytují mračna bodů nesoucí informaci o poloze. Dnes existuje řada fotogrammetrických softwarů, které automaticky analyzují velké množství snímků a rekonstruují tak 3D vlastnosti scény. [2]

2 Rešerše fokusovacích technik

Tyto techniky spadají do kategorie triangulačních metod a jsou zaměřené na získání hloubkové mapy scény z jednoho místa snímání bez použití přídavných kamer a zdrojů světla. Toho je dosaženo změnami parametrů kamery, a to zejména aktivním ostřením, změnou ohniska kamery nebo změnou nastavení clony. Také lze pomocí těchto technik měřit 3D vlastnosti objektu změnou jeho vzdálenosti od kamery.

Existují tři základní fokusovací techniky:

- 1) konfokální mikroskopie
- 2) kontrolované fokusování (angl.: “Depth From Focus” ve zkr.: “DFF”)
- 3) metody rozfokusování (angl.: “Depth From Defocus” ve zkr.: “DFD”)

V oblasti triangulace může být použití fokusovacích technik velkou výhodou. Jedním z důvodů je, že se díky použití jediné kamery s možností zaostření jedná o levné a jednoduché řešení. Nicméně chybějící informace z dalších senzorů, příp. zdrojů světla dělají estimaci hloubkové mapy pomocí jedné kamery a jedné zaostřené roviny velmi komplikovaný. Pro kompenzaci tohoto problému se provádí snímání na několika fokusovacích rovinách pro získání více informací o dané scéně. [1]

Při pořizování snímku dané scény jsou nejostřejší ty objekty, které leží v zaostřené rovině než ty, které leží mimo ní. Vědecké práce nebo algoritmy založené na analýze ostrosti nebo rozmazanosti jednotlivých částí obrazu jsou rozděleny na metody kontrolovaného fokusování, metody rozfokusování a případně konfokální mikroskopii. Pro měření ostrosti částí snímků existuje řada metod, z nichž některé jsou založeny na prostorové analýze a některé na frekvenční analýze. [1]

2.1 Konfokální mikroskopie


Jednou z prvních verzí konfokální mikroskopie se zabýval Marvin Minsky již v roce 1955. Jeho snaha byla vyvinout přístroj, který by dokázal bod po bodu zrekonstruovat sledovaný objekt pomocí zaznamenávání odražených paprsků od objektu. To vyžadovalo zdroj světla zaostřený do jednoho bodu pozorovaného objektu a také snímač odraženého světla procházející přes malý otvor. Díky tomuto otvoru se všechny nežádoucí paprsky odraženého světla odfiltrovaly a prošly pouze paprsky nesoucí informaci o pozorovaném bodu. Žádoucí paprsky poté mohly být pomocí fotonásobiče zobrazeny na obrazovce. Minsky využíval pro sestavení obrazu pohyb sledovaného objektu namísto pohybu optické soustavy. Objekt byl umístěn na pohyblivé desce, se kterou pohybovaly elektromagnety a při určité frekvenci napájecího napětí se objekt harmonicky pohyboval. [5]

V této práci jsou objasněny tři základní typy konfokálních mikroskopů. Prvním z nich je rastrující mikroskop, který se způsobem provedení řadí mezi pomalejší konfokální mikroskopy. Druhým typem je konfokální mikroskop založen na metodě Nipkowova disku. Třetím typem je konfokální mikroskop založen na akusticko-optickém deflektoru. Druhý a třetí typ se řadí svým provedením mezi rychlejší konfokální mikroskopy.

Rychlejší konfokální mikroskopy se používají zejména u dynamických aplikací, kde by mohl být problém dlouhý čas snímání jednotlivých vrstev 3D objektu pomocí rastrovacích konfokálních mikroskopů, případně sledované objekty citlivé na dlouhou expozici laseru by mohly být nenávratně poškozeny. [5]

2.1.1 Rastrující konfokální mikroskop

Dnešní konfokální mikroskopy používají zdroje světla o velké intenzitě, a to zejména lasery. Ty mají mimo jiné výhodu, že jsou dostupné v mnoha vlnových délkách. Základní princip rastrujícího konfokálního mikroskopu je znázorněn na obr. 2.1.




Obr. 2.1: Konfokální mikroskop schématicky. [5]

Zdroj světla (laser) prochází přes díрку o definovaném průměru a odráží se od dichromatického zrcadla na sérii dvou elektronicky pohyblivých zrcadel, přičemž jedno z těchto zrcadel určuje pohyb laserového paprsku v ose X a druhé v ose Y. Poté paprsek prochází přes dvě čočky typu spojka. Jejich úkolem je pouze posun ohniska v ose Z, přičemž posun spodní čočky je roven posunu ohniska. Paprsek dopadá na pozorovaný objekt ideálně pod nulovým úhlem a odráží se zpět přes čočky, otočná

zrcadla, dále prochází přes dichromatické zrcadlo a díрку o definovaném průměru do fotonásobiče. Kolmý dopad paprsku na objekt není u tohoto principu snímání možné dodržet v celé rovině kvůli úhlům způsobeným pohyblivými zrcadly. Skenování 3D objektu je prováděno po jednotlivých vrstvách. U rozmanitého objektu má zpravidla jedna naskenovaná vrstva velmi malou plochu a je tedy nutné mít velké množství vrstev. [5]

2.1.2 Konfokální mikroskop založen na metodě Nipkowova disku

Jedná se o nejrychlejší metodu skenování 3D objektů. V principu jde o kotouček s velkým množstvím malých děrek poskládaných do spirály. V každém okamžiku skenování je objekt osvětlen přes malé množství děrek. Paprsky dopadající na disk procházejí těmito dírkami, a to až na sledovaný objekt. Od něj se odrážejí a procházejí těmi stejnými dírkami zpátky. Sledovaný objekt je během jedné otáčky disku pokryt několikrát. Jedna z hlavních nevýhod je ta, že velmi malá frakce zdrojového světla projde přes dírky až na sledovaný objekt. To může vést k velmi slabým signálům. [5]




Obr. 2.2: Princip Nipkowova disku. [6]

2.1.3 Konfokální mikroskop založen na akusticko-optickém deflektoru

Problém u rastrujícího konfokálního mikroskopu je nízká rychlost, jakou mohou pohybovat galvanometry s odrazovými zrcadly. Většinou jde o kombinaci s rychlým horizontálním snímáním a pomalým vertikálním snímáním. Celkovou rychlost snímání

tedy nejvíce ovlivňuje rychlost snímání v horizontálním směru. U této metody je klasické horizontální zrcadlo poháněné galvanometrem nahrazeno akusticko-optickým deflektorem. Ten funguje na principu změny indexu lomu monochromatického světla procházejícího přes krystal v závislosti na akustických vlnách procházejících napříč tímto krystalem, viz obr. 2.3. Výsledný úhel výstupního paprsku bude tedy závislý na vlnové délce ovládajícího zvuku. [5]




Obr. 2.3: Princip akusticko-optického deflektoru. [7]

Tato metoda představuje velmi přesné a rychlé řízení paprsku v horizontálním směru. Nevýhodou této metody je závislost lomu světla na vlnové délce světla. Například u fluorescenční mikroskopie má světlo z fluorescence různé vlnové délky a akusticko-optický deflektor nelze použít a musí být použita zrcadla. [5]

2.1.4 Konfokální snímače

V praxi se pro přesné měření malých vzdáleností běžně používají konfokální snímače. Jejich principem je, že bílé polychromatické světlo prostupuje ze zdroje přes soubor chromatických čoček k získání spojitého monochromatického světla podél osy z , která je tímto barevně zakódována. Pokud je objekt v určité barevné oblasti, odráží se od něj pouze odpovídající světlo o dané vlnové délce. To prochází zpět do optické soustavy a přes rozdělovač paprsků a filtrační otvor do spektrometru. Díky filtračnímu otvoru vstupuje do spektrometru světlo o vlnové délce, které je právě odraženo od zkoumaného objektu. Pomocí spektrometru se následně zjistí vlnová délka a tomu se přiřadí odpovídající vzdálenost dle kalibrace snímače. Tyto snímače běžně mají zdroj světla a spektrometr mimo tělo. Snímač tedy neobsahuje žádnou elektroniku a je možné jej použít i ve výbušném prostředí a ve vakuu. [8]



Obr. 2.4: Schéma chromatického konfokálního snímače. [8]

2.2 Kontrolované fokusování

Anglicky “Depth From Focus” (ve zkratce DFF) je metoda zabývající se estimací hloubkové mapy dané scény z mnoha snímků s různě nastaveným zaostřením, přičemž pořizování všech snímků probíhá ze stejného místa a snímaná scéna je neměnná. Ke každému bodu v obrázku se snaží najít odpovídající snímek, ve kterém je tento bod právě v maximálním zaostření. Tato metoda většinou potřebuje mít snímky seřazené v obrazovém zásobníku postupně od zaostřeného popředí až po zaostřené pozadí nebo naopak. Pro měření ostrosti plochy snímku se používá množství metod. Některé pracují v prostorové doméně, jiné ve frekvenční doméně. Metoda DFF funguje hlavně na komplexních snímcích s velkou rozmanitostí. U ploch s malou rozmanitostí a nízkou úrovní textury (např. jednobarevný povrch bez hran) tato metoda selhává. [1]

2.2.1 Literární řešení

V této části jsou popsány základní přístupy k metodě kontrolovaného fokusování. Některé přístupy jsou realizované v prostorové doméně, jiné ve frekvenční doméně.

Valencia, Rodriguez-Dagnino


V práci [9] se používá tříúrovňová vlnková transformace aplikovaná na jeden snímek a hloubková mapa je určena ostrostitv obrázku pomocí sbírání několika koeficientů vlnek, které jsou větší než určitý práh. Estimace hloubkové mapy je v této práci založena na měření ostrostitv snímku pomocí vlnkové analýzy a Lipschitzovy estimace výrazných hran. Každý snímek byl reprezentován jako série řádků, což vedlo k horizontálním proužkům v hloubce obrazu. To můžeme vidět na obrázku 2.5, kde vlevo je vstupní snímek a vpravo výstupní hloubková mapa. [9][10]



Obr. 2.5: Příklad estimace hloubkové mapy (Valencia, Rodriguez-Dagnino). [9]

Guo, Zhang

V práci [11] autoři vyřešili problém s horizontálními pásy práce autorů Valencia, Rodriguez-Dagnino a vylepšili konečný výsledek pomocí Lipschitzova exponentu a barevné segmentace. Jejich algoritmus je založen na vlnkové transformaci a detekci ostrostitv hran ve 2D rovině. Tento přístup je vyhovující pro rekonstrukci 3D scény z 2D obrazu. Výsledná hloubková mapa založena na rozostření hran je vidět vlevo na obr. 2.6. Vpravo na obr. 2.6 pak lze vidět hloubkovou mapu po optimalizaci. [11][10]




Obr. 2.6: Hloubková mapa založena na rozostření hran (Ge Guo, Nan Zhang). [11]

Malik, Shim

Autoři práce [12] používají pro získání hloubkové mapy měření ostrosti. To je založeno na optické přenosové funkci implementované ve frekvenční doméně. Následně tento přístup porovnali s klasickým Laplaceovým operátorem pro měření ostrosti a Tenenbaumovým operátorem pro měření ostrosti. V testech se u této metody ukázala větší robustnost vůči šumu v porovnání s ostatními metodami. Optická přenosová funkce ve frekvenční doméně je filtr typu pásmová propust, který zvýrazní vysokofrekvenční složky pro zjištění ostrosti dané oblasti. Konečné měření ostrosti je dáno jako FM_o v malém okně okolo bodu (i, j) . Hodnota v bodě (i, j) je nahrazena sumou vypočtených hodnot všech pixelů v daném okně. Test měření ostrosti touto metodou a její robustnost vůči šumu můžeme vidět na obr. 2.7. [12][10]

$$FM_o = \sum_{x=i-N}^{i+N} \sum_{y=j-N}^{j+N} i_c(x, y) \quad (2.1)$$



Obr. 2.7: Test měření ostrosti (Malik, Shim). [12]


Na obr. 2.8 lze vidět hloubková mapa pro simulovaný kuželový objekt. Obr. 2.8 (c,d) jsou bez přídavného šumu, obr. 2.8 (e,f) jsou s přídavným Gaussovým šumem. SML je suma modifikovaných laplaciánů a nachází se zde pouze pro porovnání robustnosti.

Li, Ngan


Autoři v práci [13] představili neobvyklý přístup k segmentaci objektů založený na modelu matnosti. Tato metoda je navržena pro získání ostrých objektů ze snímků s malou hloubkou ostrosti. Algoritmus založený na této metodě je plně automatický a může být použit pro rozdělení ostrého popředí a rozmazaného pozadí jednotlivých snímků. Autoři v rámci metody implementovali adaptivní nastavování velikosti chyby detekce hranice segmentovaného objektu pro zvýšení přesnosti. Přestože



(a) Frame 50




(d) FM_O




(f) FM_O



(b) Frame 90



(c) SML



(e) SML

Obr. 2.8: Porovnání operátorů pro měření ostrosti na umělém kuželovém objektu (Malik, Shim). [12]


lepších výsledků segmentací objektů může být dosaženo pomocí stávajících metod, segmentace objektů v plně automatizované podobě je v mnoha oblastech počítačového vidění stále velkým problémem. Výsledek automatické segmentace lze vidět na obr. 2.9. [13][10]



Obr. 2.9: Výsledky segmentace (Li, Ngan). [13]

Deng, Jiang


Práce [14] je zaměřena na nový přístup získání hloubkové mapy, a to zejména vnitřních prostor. Největší řešený problém v této práci je získání hloubkové mapy pouze pomocí jednoho snímku. Je zde představen koncept modelu konverze 2D na 3D a také metodologie k určení jednotlivých rovin. Snímek vnitřního prostoru je nejprve rozdělen na popředí a pozadí, poté je pozadí interpretováno jako jedna či dvě horizontální roviny a několik vertikálních rovin. Nakonec je hloubková mapa získána podle klasifikace jednotlivých rovin a geometrických vlastností. Každému pixelu je přiřazena relativní hodnota hloubky podle pozice roviny, ve které se daný pixel nachází. Tento algoritmus pro získání rovin není optimalizován a nachází se zde řada omezení při zpracovávání obecných snímků. Na obr. 2.10 lze vidět příklad estimace hloubkové mapy z 2D snímku vnitřních prostor. [14][10]



Obr. 2.10: Příklad použití metody extrakce hloubkové mapy z 2D snímku (Deng, Jiang). [14]

Autoři v práci [15] představili metodu, která vytváří hloubkovou mapu pouze z jednoho snímku, a to pomocí klasifikace scény. Nejprve provádí klasifikaci scény obrázku do kategorií v závislosti na barevné informaci, ostrosti a kontrastu. Poté na základě této klasifikace vytváří hloubkovou mapu v závislosti na úběžnících a spojnicích. Tato metoda může být použita pro vytváření stereoskopických snímků pro 3D obraz, a to pomocí posunu původního obrázku doleva a doprava na základě jeho hloubky. Tato metoda vykazuje dobré výsledky s určitými omezeními. Například při snímání portrétu musí mít osoba na sobě oblečení světlejší barvy pouze s mírnou texturou. Dále je u této metody omezen počet objektů ve scéně na jeden.

Vývojový diagram této metody pro klasifikaci snímku lze vidět na obr. 2.11. Nejprve je provedena transformace z barevného modelu RGB do HSI. Poté se hledá ve snímku tvář, pokud je nalezena, tak se snímek klasifikuje jako portrét. Pokud nalezena nebyla, detekují se jednotlivé objekty, zem (tráva) a obloha. Pokud snímek obsahuje poměrově velké množství pixelů země a oblohy, obrázek se klasifikuje jako snímek krajiny, jinak se klasifikuje jako obrázek z blízka. [15][10]



Obr. 2.11: Vývojový diagram (Huang, Cheng). [15]



Obr. 2.12: Originální obrázek, hloubková mapa, levý snímek s otevřenou oblastí (Huang, Cheng). [15]




Obr. 2.13: Pravý snímek s otevřenou oblastí (vlevo), výstupní levý snímek (uprostřed), výstupní pravý snímek (vpravo) (Huang, Cheng). [15]



Obr. 2.14: Výsledek sjednocení levého a pravého snímku (Huang, Cheng). [15]

Autoři v práci [16] ukázali praktický přístup k získání hloubkové mapy ze série snímků pořízených z jednoho místa s různým nastavením zaostření. Tento algoritmus vyžaduje pouze Gaussovy filtry a komparátory případně sumační členy, což vede k vysoké efektivitě algoritmu.

Přístup k měření ostrých oblastí v jednotlivých snímcích spočívá nejprve ve výpočtu rozptylové funkce, která u zaostřených pixelů dosahuje výrazně vyšších hodnot než u rozostřených pixelů. Poté se na tuto funkci aplikuje Gaussův filtr a vypočte se rozdíl rozptylové funkce a filtru. Na obr. 2.15 je modrou křivkou znázorněna rozptylová funkce a červenou křivkou aplikovaný Gaussův filtr.



Obr. 2.15: Aplikovaný Gaussův filtr na rozptylovou funkci (Chen, Wu). [16]

Pro zaostřené pixely bude rozdíl větší než pro rozostřené pixely. Tento způsob měření ostrosti popisuje rovnice 2.2.


$$D(x, y) = r(x, y) * (h(x, y) - h(x, y) * G(x, y)) \quad (2.2)$$

kde $r(x, y)$ je plně zaostřený snímek, $h(x, y)$ je odpovídající rozptylová funkce a $G(x, y)$ je Gaussův filtr.

Následně jsou tato data porovnávána v souladu s předpokladem, že první snímek série má ostré pixely v popředí a rozostřené pixely v pozadí, a naopak u posledního snímku. Konečná hloubková mapa je tedy indexová mapa indikující rovinu ostrosti, kde daný pixel leží. Tato metoda se jeví v porovnání s ostatními metodami robustnější, jelikož negeneruje tolik chyb z oblastí s nízkou úrovní textury. Avšak oblasti, které jsou daleko od hran mohou stále generovat chyby. [16][10]



Obr. 2.16: Série snímků s různým zaostřením (Chen, Wu). [16]



Obr. 2.17: Výsledná hloubková mapa (Chen, Wu). [16]


NeuroHive

Moderní způsob estimace hloubkové mapy, který představili autoři v práci [17] je založen na použití strojového učení bez učitele, kde se neuronová síť učí předpovídat cílový snímek z pohledu jiného snímku. Tato metoda je schopná estimovat hloubkovou mapu pouze z jednoho barevného snímku.


Na rozdíl od jiných přístupů, které využívají neuronovou síť zvlášť pro estimaci pozice a pro estimaci hloubky, tato metoda využívá data z enkodéru estimace hloubky pro estimaci pozice. Autoři uvádějí, že takový přístup velmi zlepšuje výsledky estimace pozice a zároveň snižuje počet učících parametrů. Síť pro estimaci hloubky je založena na architektuře enkodér-dekodér, kterou zde tvoří předtrénovaná konvoluční neuronová síť ResNet18. [17]

Autoři implementovali neuronovou síť pomocí knihovny PyTorch a pro trénování byl použit dataset KITTI obsahující okolo 39 000 snímků. Tato metoda se jeví jako

velmi přesná a je otázkou, zda je opravdu potřeba složitých a drahých 3D senzorů pro měření 3D vlastností scény. [17]



Obr. 2.18: Schéma neuronové sítě typu enkodér-dekodér (vlevo) a část pro estimaci pozice (vpravo) (Neurohive). [17]



Obr. 2.19: Estimace hloubky s porovnáním ostatních metod (Neurohive). [17]

2.2.2 Kalibrace kamery

U této metody není kalibrace parametrů kamery kritická. Jelikož nepočítá s modelem kamery, tak jako metoda DFD, lze pro jednotlivé roviny reprezentující výslednou hloubku obrazu indexy přiřazovat relativně. Výsledná hloubková mapa by tak neurčovala absolutní vzdálenost objektu od kamery, resp. jeho dílčích částí, ale pouze vzájemnou polohu.

V případě potřeby absolutních vzdáleností v hloubkové mapě je potřeba parametry kamery kalibrovat. Nejjednodušší přístup je umisťovat objekt do referenčních vzdáleností u_r po určitých krocích, a to ideálně v rámci celého ostřicího rozsahu. Ke každé této vzdálenosti se poté přiřadí odpovídající hodnota zaostření pro maximální ostrost scény. Následně se odstraní neefektivní rozsah zaostření kamery -

vzdálenosti, na které kamera již nemůže zaostřit. Takto získané hodnoty lze aproximovat vhodnou funkcí. Jelikož závislost vzdálenosti na hodnotě zaostření není lineární, je vhodné použít polynomy vyššího řádu.

2.2.3 Estimace hloubkové mapy

Tato metoda hledá ve snímku N ploch, ke kterým přiřadí odpovídající hodnotu zaostření, což odpovídá hloubce dané plochy. Je tedy bezpodmínečně nutné měřit ostrost každé plochy snímku a hledat její maximum. [1]

Zarovnání vstupních snímků

Při estimaci hloubkové mapy může být problém, že jednotlivé objekty na všech snímcích nejsou ve stejném místě nebo velikost jednotlivých objektů není na všech snímcích stejná. To může být způsobeno změnou snímacího úhlu nebo vzdálenosti kamery od snímaných objektů, případně fokusováním. Tento problém lze částečně řešit stativem, avšak ten není vždy k dispozici a neřeší deformaci snímku způsobenou fokusováním. Pro větší variabilitu je nutná implementace algoritmu, který transformuje a zarovná všechny snímky ve vstupním zásobníku. Pro transformaci snímků se používají metody z oblasti optického toku (angl. “Optical flow”). [1]

Optický tok je pohyb daného objektu mezi jednotlivými snímky. Tento pohyb je určován relativně ke kameře. Pokud vyjádříme snímek jako intenzitu I , který je funkcí prostoru a času, v tomto případě souřadnice x, y a čas t , dostaneme $I(x, y, t)$. Pohybem pixelu na následujícím snímku o malou změnu $\delta x, \delta y$ za určitou změnu času δt dostaneme intenzitu snímku jako $I(x + \delta x, y + \delta y, t + \delta t)$. Za těchto předpokladů tedy bude platit rovnice: $I(x, y, t) = I(x + \delta x, y + \delta y, t + \delta t)$ [18]. Ilustrace na obr. 2.20.

Pomocí rozvoje do Taylorovy řady dostaneme:


$$I(x + \delta x, y + \delta y, t + \delta t) = I(x, y, t) + \frac{\partial I}{\partial x} \delta x + \frac{\partial I}{\partial y} \delta y + \frac{\partial I}{\partial t} \delta t + \dots \quad (2.3)$$

$$\Rightarrow \frac{\partial I}{\partial x} \delta x + \frac{\partial I}{\partial y} \delta y + \frac{\partial I}{\partial t} \delta t = 0 \quad (2.4)$$

Podělíme δt a dostaneme:

$$\frac{\partial I}{\partial x} u + \frac{\partial I}{\partial y} v + \frac{\partial I}{\partial t} = 0 \quad (2.5)$$

Kde $u = \delta x / \delta t$, $v = \delta y / \delta t$. Tato rovnice má dvě neznámé a nelze jí přímo řešit. Je nutné použít jednu z metod pro estimaci optického toku. Jedny z nejpoužívanějších metod jsou: Lucas-Kanade, Horn-Schunck a Buxton-Buxton. [18]



Obr. 2.20: Znázornění optického toku.

Měření ostrosti


Pro zjištění ostrosti jednotlivých ploch ve snímku je nutné detekovat hrany objektů a jejich intenzitu. Detekce hran je obecně v počítačovém vidění jedna z nejpoužívanějších operací, díky které lze analyzovat a měřit základní vlastnosti objektů jako je plocha, obvod a tvar. Hrany jsou také brány jako jedny z nejdůležitějších informací o sledovaném prostředí pro lidské vnímání. Hranu lze chápat jako hranici mezi objektem a pozadím, případně mezi dvěma překrývajícími se objekty, kde derivace intenzity pixelů dosahuje svých maxim. [19]

Jelikož jsou hrany tvořeny hlavně vyššími frekvencemi, teoreticky je lze detekovat ve frekvenční doméně aplikací hornopropustního filtru nebo v prostorové doméně pomocí konvoluce obrázku s odpovídající maskou. V praxi je používanější přístup detekce hran v prostorové doméně z důvodu menší výpočetní náročnosti a dosahování lepších výsledků. [20]

Pro detekci hran existuje řada operátorů, přičemž každý operátor je vhodný na jiný typ hran. Jedny z nejpoužívanějších jsou: Sobel, Prewitt, Log a Canny. Tvar každého operátoru určuje na jaký typ hran je nejcitlivější. Při detekci hran je problém šum, který se nachází ve snímku. Úkolem detektoru hran je identifikovat velké jasové změny v obrázku.

Mezi nejčastější typy hran patří: skoková hrana, hrana ve tvaru rampy, obdélníková hrana a hrana ve tvaru pily. To je zobrazeno na obr. 2.21. Skoková hrana reprezentuje okamžitý nárůst intenzity a hrana ve tvaru rampy postupný nárůst intenzity. Dále obdélníková hrana znázorňuje okamžitý nárůst a následně okamžitý

pokles intenzity, hrana ve tvaru pily plynulý nárůst a následně plynulý pokles intenzity. [19]



Obr. 2.21: Typy hran. (a) skoková hrana, (b) hrana ve tvaru rampy, (c) obdélníková hrana, (d) hrana ve tvaru pily.


Detektory hran jsou většinou rozděleny na dvě kategorie. První z nich jsou gradientní metody a druhou kategorií jsou Laplaceovy metody. Ke gradientním metodám se řadí Sobelův a Prewitův hranový detektor. Do Laplaceových hranových detektorů se řadí zejména Laplacián gausiánu (Log). Sobelův a Prewitův detektor používá horizontální a vertikální masku, nejčastěji o rozměru 3x3. Výhoda detektorů s maskami o velikosti 3x3 a více spočívá v implicitní filtraci náhodného šumu vstupních dat, a tedy menší senzitivě vůči šumu obsaženého ve snímku oproti prosté diferenci. Přesnost Sobelova a Prewitova detektoru oproti jiným metodám není velká, avšak dostatečná pro řadu aplikací. [19]

-1	0	1	1	2	1
-2	0	2	0	0	0
-1	0	0	-1	-2	-1

Tab. 2.1: Horizontální a vertikální maska.

Hranový detektor typu Log (Laplacián gausiánu) počítá druhou derivaci snímku vyhlazeného určitým filtrem typu dolní propust (Gaussovým filtrem). Vyhlazení vstupních dat je důležité zejména z toho důvodu, že druhá derivace zesiluje náhodný šum obsažený ve vstupním snímku, a to by vedlo k velkým nepřesnostem v detekci


hran. Tato metoda se mimo jiné řadí k detektorům protínající nulu. Protože snímek je tvořen diskrétními hodnotami reprezentující jednotlivé pixely, je nutné najít diskrétní konvoluční matici aproximující druhou derivaci podle definice Laplaceanu. Jak již bylo zmíněno výše, tento filtr aproximující druhou derivaci je velmi náchylný na šum. Je možné konvolvovat Gaussův vyhlazovací filtr s Laplaceovým filtrem, čímž vytvoříme kýžený filtr typu Log, který se posléze konvolvuje se snímkem [21]. Tento detektor lze vidět na obr. 2.22. Na obr. 2.23 je ukázán ilustrativní příklad reakce operátoru LoG na skokovou změnu vstupu a na obr. 2.24 je znázorněno použití operátoru typu LoG na testovacím snímku.



Obr. 2.22: Operátor pro detekci hran typu LoG.

Detektor typu LoG pro 2D s Gaussovou standardní odchylkou σ lze zapsat následujícím matematickým výrazem:

$$LoG(x, y) = -\frac{1}{\pi\sigma^4} \left(1 - \frac{x^2 + y^2}{2\sigma^2} \right) e^{-\frac{x^2 + y^2}{2\sigma^2}} \quad (2.6)$$



Obr. 2.23: Odezva operátoru LoG na skok.



Obr. 2.24: Příklad použití operátoru LoG na testovacím snímku.

Přiřazení hloubkové mapy


Pro přiřazení hloubkové mapy dané scéně je nejprve nutné určit a vybrat ostrou plochu scény pro aktuální zaostření dle přístupu měření ostroty popsanych výše. Poté je potřeba každé této zaostřené vrstvě ve snímku přiřadit index, což může reprezentovat aktuální nastavení zaostření kamery v procentech. Pokud způsob snímání kamery je proveden tak, že první snímek se pořizuje při nastavení zaostření kamery na nejbližší možnou vzdálenost a následně se po krocích kamera zaostřuje směrem na nekonečno, lze jako index ostré vrstvy přímo použít číslo pořadí daného snímku v obrazovém zásobníku. Poté se tyto indexy jednotlivých vrstev složí do jedné matice reprezentující výslednou hloubkovou mapu scény.

Jiný možný způsob k získání hloubkové mapy by mohl být proveden pomocí změny vzdálenosti objektu od kamery. Při každé referenční vzdálenosti je potřeba tuto vzdálenost přesně zaznamenat, pořídít snímek a následně hledat nejostřejší části objektu ve snímku. Díky tomu by mohlo být zaostření objektivu nastaveno na statickou hodnotu.


Sešívání vrstev do jednoho ostrého obrázku

Při slučování jednotlivých vrstev nebo také při šití obrázků dochází k ostrým přechodům. Ty lze redukovat pomocí tzv. alfa míchání, kdy se okraje jednotlivých ploch lineárně míchají (viz obr. 2.25). Ilustraci výsledku optimálního míchání lze vidět na obr. 2.26. Optimální hloubka mísení nastane tehdy, je-li přechod vyhlazený a zároveň neprosvítají jednotlivé vrstvy přes sebe. Vzorec 2.7 je matematický výraz pro alfa míchání levé a pravé plochy nebo obrázku. [22]

$$I_{blend} = \alpha I_{left} + (1 - \alpha) I_{right} \quad (2.7)$$



Obr. 2.25: Znázornění lineárního míchání okrajů obou ploch. [22]




Obr. 2.26: Ukázka alfa míchání. [22]

2.3 Metoda rozfokusování

Anglicky “Depth From Defocus” ve zkratce DFD je metoda zabývající se estimací 3D modelu scény již ze dvou snímků s různě nastaveným zaostřením nebo clonou, přičemž stejně jako u DFF, pořizování všech snímků probíhá ze stejného místa z jedné kamery a snímaná scéna také musí být neměnná. Tato metoda estimuje hloubkovou mapu z relativní rozmazanosti oblastí jednotlivých snímků. Metoda DFF je preferovanější než metoda DFD zejména kvůli jednoduchosti. [1][23]

Metoda rozfokusování tedy určuje vzdálenost mezi viditelným povrchem zkoumaného objektu a čočkou snímací kamery pomocí měření rozmazanosti. Za předpokladu perspektivní projekce reálného bodu do snímku, intenzita daného pixelu (x, y) závisí na vzdálenosti u mezi čočkou kamery a odpovídajícím bodem dané scény. V případě tenké čočky je obrázek formován konvolucí ideální projekce a rozptylové funkce dané jako $g(x, y, \sigma(x, y))$, kde $\sigma(x, y)$ je parametr rozmazanosti daného pixelu (x, y) . Budeme předpokládat, že $\sigma(x, y)$ je konstantní v daném okně, tedy $\sigma(x, y) = \sigma$. Tento předpoklad většinou není realistický, jelikož rozmazanost σ daného pixelu je funkcí lokace odpovídajícího bodu ve scéně. Jednotlivé body objektu nejsou ve stejné vzdálenosti od čočky kamery, a tím pádem míra rozmazanosti ve snímku není konstantní. Bez tohoto předpokladu bychom ovšem čelili matematickému systému, který by byl obtížně řešitelný. To vysvětluje, proč je tento předpoklad ve většině prací zabývajících se tímto tématem implicitně zahrnut. [24]



Obr. 2.27: Zjednodušený model kamery.

Dle čočkové rovnice je množství rozmazanosti ve snímku σ dáno jako:

$$\sigma = k \frac{sD}{2} \left(\frac{1}{f} - \frac{1}{u} - \frac{1}{s} \right) \quad (2.8)$$

Průměr clony D je dán jako podíl ohniskové vzdálenosti f a clonového čísla F

$$D = \frac{f}{F} \quad (2.9)$$

Po dosazení vztahu 2.9 do rovnice 2.8 dostaneme:

$$\sigma = k \frac{sf}{2F} \left(\frac{1}{f} - \frac{1}{u} - \frac{1}{s} \right) \quad (2.10)$$

kde σ je množství rozmazanosti, s je vzdálenost mezi čočkou a snímačem, f je ohnisková vzdálenost, F clonové číslo, u vzdálenost objektu od čočky, k konstanta proporcionality charakteristická pro danou kameru.

Pro aproximaci rozptylové funkce kamery existuje řada funkcí. Nejčastější varianta je aproximace Gaussovou funkcí (vztah 2.11):


$$g_\sigma = \frac{1}{\pi\sigma^2} e^{-\frac{x^2+y^2}{\sigma^2}} \quad (2.11)$$

2.3.1 Hloubka ostrosti

Hloubka ostrosti je vzdálenost mezi nejbližším a nejvzdálenějším místem, na který dokáže kamera dostatečně zaostřit. Lze ji vypočítat podle ohniskové vzdálenosti, vzdálenosti objektu, kruhu zmatku a velikosti clony. Kruh zmatku zde znamená nedokonalé zaostření světelných paprsků na snímač kamery. Hloubka ostrosti roste kvadraticky s rostoucí vzdáleností objektu od kamery, lineárně s ohniskovou vzdáleností a s kruhem zmatku. Je nepřímo úměrná kvadratické hodnotě ohniskové vzdálenosti. [25]. Výsledná hloubka obrazu je tedy dána vztahem:

$$DOF \approx \frac{2u^2Fc}{f^2} \quad (2.12)$$

kde u je vzdálenost objektu od kamery, F clonové číslo, f ohnisková vzdálenost a c kruh zmatku. Ukázka hloubky ostrosti je vidět na obr. 2.28. Obrázek vlevo je zachycen 50 mm objektivem s nastavením clony na $f/1.4$, kde výsledná hloubka ostrosti je 0.8 cm. Obrázek vpravo byl pořízen stejným objektivem s clonou nastavenou na $f/22$, čemuž odpovídá výsledná hloubka ostrosti 12.4 cm. [25]



Obr. 2.28: Hloubka ostrosti. [25]

2.3.2 Literární řešerše


V této části jsou popsány základní přístupy k metodě rozfokusování. Některé přístupy jsou realizované v prostorové doméně, jiné ve frekvenční doméně. Co je ovšem u všech metod společné je to, že je potřeba přesně znát vnitřní parametry kamery.

Surya, Subbarao


V práci [26] autoři představili přístup určení vzdálenosti objektů ze dvou snímků pomocí konvoluční, resp. dekonvoluční transformace (S transformace) v prostorové doméně. Tato metoda zahrnuje jednoduché lokální operace na dvou snímcích pořízených s různým nastavením průměru clony, resp. clonovým číslem, přičemž oba tyto snímky mohou být rozostřené. U této metody tedy není zapotřebí ostrého snímku.

Ziou, Deschenes

Algoritmus v práci je založen na výpočtu rozdílu rozmazanosti dvou vstupních snímků. Tyto snímky jsou získány pomocí kamery s různým nastavením jejich vnitřních parametrů pro každý snímek. Používá se zde technika lokální dekompozice obrázku pomocí Hermitových polynomů, kdy koeficienty vypočítané pomocí rozmazanějšího snímku jsou funkcí parciálních derivací druhého snímku a rozdílu rozmazanosti. Rozdíl rozmazanosti je tedy výsledkem řešení několika rovnic. Pro řešení v 1D jde o dvě rovnice, ve 2D jde o čtyři rovnice. Dále tento algoritmus nevyužívá žádného modelu obrázku a nevyžaduje iterativní proces výpočtu jako ostatní metody. [24]



Obr. 2.29: Dva vstupní snímky s různým nastavením kamery (Ziou, Deschenes). [24]




Obr. 2.30: Estimace hloubkové mapy metodou DFD (Ziou, Deschenes). [24]

Rajagopalan, Chaudhuri


Autoři Rajagopalan a Chaudhuri [27] představili dvě prostorově variantní metody. V první je obrázek rozdělen do několika menších obrázků. Předpokládá se zde, že míra rozmazanosti je na těchto snímcích konstantní a zároveň se liší na sousedních snímcích. V každém malém obrázku je rozmazanost odhadována minimalizací váhovaného rozdílu hodnot Fourierovy transformace obrázku $I_c(x, y)$ a $I_b(x, y)$. Druhý přístup je založen na Wignerově distribuci, která poskytuje prostorově variantní filtraci. Obě tyto metody mají v porovnání s ostatními metodami dobré výsledky. [27][24]

Výsledky práce ukazují, že první metoda překonala tehdy existující metody estimace hloubkové mapy. Dále se také zjistilo, že druhá metoda je přesnější než první

a také obsahuje informaci o hloubce ve všech dostupných bodech daného snímku oproti první metodě, která je tvořena pouze jednotlivými okny. Na obr. 2.31 lze vidět umělé rozostření testovacího snímku pomocí Gaussova filtru a na obr. 2.32 test obou výše zmíněných metod estimace hloubkové mapy. [27]



Obr. 2.31: Originální obrázek (vlevo), rozostřené obrázky (uprostřed, vpravo) pomocí Gaussova filtru (Rajagopalan, Chaudhuri). [27]



Obr. 2.32: Skutečné hodnoty (vlevo), výsledek první (uprostřed) a druhé (vpravo) metody estimace hloubkové mapy (Rajagopalan, Chaudhuri). [27]

2.3.3 Kalibrace kamery

Všechny metody DFD potřebují precizní kalibraci vnitřních parametrů kamery. Většina DFD metod používá dobře známé techniky kalibrace parametrů kamery, které reprezentují optickou soustavu kamery jako malou díрку, jíž prochází světelné paprsky. Ve skutečnosti se však jedná o složitou soustavu tenkých čoček, jejichž vzájemná poloha se navíc mění například se změnou zoomu případně zaostření. Tyto skutečnosti značně stěžují získání vnitřních parametrů kamery. Řešením je tedy používat již přesně kalibrované laboratorní kamery se známými vnitřními parametry nebo parametry běžně dostupných kamer estimovat. V této části je popsán přístup estimace. [28]

Existují dva základní přístupy estimace vnitřních parametrů kamery, kdy každý vyžaduje zachycení dvou snímků s různým nastavením některých vnitřních parametrů. Prvním z nich je estimace parametrů změnou vzdálenosti objektu od kamery a druhým estimace parametrů změnou clonového čísla.

Estimace parametrů změnou vzdálenosti objektu od kamery

První přístup vyžaduje pořízení rozmazaného snímku g_1 v referenční vzdálenosti u_r a následně pořízení ostrého snímku g_2 změnou vzdálenosti objektu od kamery. Následně je nutné takto získané snímky zarovnat a přizpůsobit jejich velikost aby se vzájemně přesně překrývaly. Rovnici 2.10 vyjádříme pro i -tý snímek a pro referenční vzdálenost u_r jako

$$\sigma_i = k \frac{s_2 f_i}{2F_i} \left(\frac{1}{f_i} - \frac{1}{u_r} - \frac{1}{s_i} \right) \quad (2.13)$$

Dále je nutné implementovat S-transformaci publikovanou v práci [26] autory G.Surya a M.Subbarao, kde je obrázek vyjádřen polynomy třetího stupně. Tyto polynomy mohou být nahrazeny sérií dolnoproustních filtrů. Vztah mezi obrázky g_1 a g_2 je poté vyjádřen jako

$$\sigma_1^2 - \sigma_2^2 = 4 \frac{g_1 - g_2}{\nabla^2 g} \triangleq G \quad (2.14)$$

kde ∇^2 je Laplaceův operátor, celý čitatel lze vyjádřit jako

$$\nabla^2 g = \frac{\nabla^2 g_1 + \nabla^2 g_2}{2} \quad (2.15)$$

Z rovnice 2.13 získáme

$$\sigma_1 = \alpha \sigma_2 + \beta \quad (2.16)$$

U obou snímků je tedy parametr ohniskové vzdálenosti f neměnný, clonové číslo F je rovněž neměnné, mění se zde pouze vzdálenost s a také u . Tedy $f_1 = f_2 = f$, $F_1 = F_2$, $s_1 \neq s_2$ a tedy $\alpha = 1$. Po vyjádření β dostaneme

$$\beta = \frac{k f s_2}{2F} \left(\frac{1}{f} - \frac{1}{s_1} \right) - \frac{k f s_2}{2F} \left(\frac{1}{f} - \frac{1}{s_2} \right) \quad (2.17)$$

Z rovnic 2.16 a 2.14 dostaneme

$$\sigma_2 = \frac{G - \beta^2}{2\beta} \quad (2.18)$$

Jelikož je g_2 zaostřený snímek, je množství rozmazanosti $\sigma_2 = 0$, a tedy z rovnice 2.18 získáme

$$\beta = \pm\sqrt{G} \quad (2.19)$$

Pokud je měřena referenční vzdálenost u_r , vzdálenost s_2 může být určena z rovnice 2.10. Parametry f a F mohou být vyčteny přímo z kamery [28].

Estimace parametrů změnou clonového čísla

Druhý přístup estimace parametrů kamery je založen na principu změny clonového čísla při stejné vzdálenosti objektu od kamery, na rozdíl od výše zmíněné metody, která pro estimaci parametrů vyžaduje změnu vzdálenosti objektu. Postup u této estimace je dán následovně: nejprve je nutné pořídit první snímek s libovolným nastavením parametrů kamery a následně pořídit druhý snímek se změněnou clonou. Při pořizování obou snímků uvažujeme stejnou referenční vzdálenost daného objektu u_r od kamery, stejnou ohniskovou vzdálenost a také stejné nastavení zaostření. Díky minimálnímu vlivu nastavení clony na velikost případně posunutí snímků zde odpadá nutnost jejich normalizace. U obou snímků je tedy ohnisková vzdálenost f neměnná, vzdálenost s je rovněž neměnná, dochází pouze ke změně clonového čísla F . Můžeme tedy psát $f_1 = f_2 = f$, $s_1 = s_2 = s$, $F_1 \neq F_2$, a proto rovnice 2.10 bude vypadat pro i -tý snímek následovně:

$$\sigma_i = k \frac{sf}{2F_i} \left(\frac{1}{f} - \frac{1}{u_r} - \frac{1}{s} \right) \quad (2.20)$$

vztah mezi množstvím rozmazanosti σ_1 a σ_2 je

$$\sigma_1 = \alpha \sigma_2 \quad (2.21)$$

číslo α je dáno jako podíl clonového čísla F_1 a F_2

$$\alpha = \frac{F_1}{F_2} \quad (2.22)$$

z rovnic 2.14 a 2.22 můžeme psát:

$$\sigma_2 = \pm \sqrt{\frac{G}{\alpha^2 - 1}} \quad (2.23)$$

Znaménko σ_2 lze určit následovně: nejprve přizpůsobíme ohniskovou vzdálenost kamery ve směru zaostření na daný objekt. Pokud je tato ohnisková vzdálenost menší nebo rovna původní ohniskové vzdálenosti, σ_2 je pozitivní, jinak negativní. [28]

Pokud uvažujeme známou referenční vzdálenost objektu u_r , ohniskovou vzdálenost f , clonové číslo F_i a množství rozmazanosti σ_i , lze z rovnice 2.20 psát:

$$s_i = \frac{\left(\frac{2F_i\sigma_i}{kf} + 1\right)}{\left(\frac{1}{f} - \frac{1}{u_r}\right)} \quad (2.24)$$

2.3.4 Měření vzdálenosti

Jak výše zmíněné postupy napovídají, parametry kamery lze estimovat několika způsoby. Jednou z hlavních nevýhod prvního přístupu estimace parametrů kamery je nutnost jednoho plně ostrého snímku. Druhou hlavní nevýhodou je nutnost normalizace obou snímků, tj. úprava velikosti, posunutí a rotace snímků způsobená změnou vzdálenosti objektu od kamery a s tím spojeným nechtěným posunutím objektu vůči optické ose. Tyto skutečnosti značně stěžují samotnou realizaci estimace parametrů z důvodu potřeby dodatečných algoritmů a v neposlední řadě také zhoršují přesnost estimace [28]. Z výše uvedených důvodů je tato část práce zaměřena pouze na měření vzdálenosti pomocí změny clony.

Měření vzdálenosti objektu změnou clony

Po úspěšné kalibraci kamery a s tím spojeným získáním všech parametrů je možné přejít k samotnému měření vzdálenosti objektu. Předpokládá se zde, že ohnisková vzdálenost f , vzdálenost s a zaostření jsou stejné, jako při kalibraci. Nejprve je potřeba opět pořídit dva různě rozmazané snímky g_1 a g_2 ze stejného místa snímání. Rozdíl rozmazanosti je možné docílit změnou clonového čísla F [28]. Poté je potřeba vypočítat rozdíl rozmazanosti snímků G z rovnice 2.14. Rozmazanost σ se následně určí z rovnice 2.20, 2.21 a 2.23. Poté lze z rovnice 2.20 vyjádřit vzdálenost u :

$$u = \frac{ks_i f_i}{ks_i - kf_i - 2F_i \sigma_i} \quad (2.25)$$

2.4 Technika mikro-rozfokusování obrazu

Tato metoda slouží pro měření refrakčního indexu (dále jen RI) materiálů a je založená na principu clony se třemi dírkami, která je připojena k mikroskopickému optickému systému. RI je jeden z optických vlastností kapalin, který může být použit pro zjištění různých biologických a chemických vlastností. Velkými výhodami senzorů měřících RI je jejich citlivost a absence popisovacích metod. [29]


2.4.1 Vznik metody

Obecná technika rozfokusování obrazu již byla použita v řadě výzkumů zabývajících se 3D sledováním částic a 3D měřením toku kapaliny. Tato technika byla rozšířena do oblasti mikro průtokových aplikací a vznikla tak právě technika mikro rozfokusování obrazu, kterou představili autoři S.Y.Yoon a S.Yang ve své práci [29]. Zatímco předchozí práce využívaly přímé porovnání separace obrazu, autoři této práce navrhli metodu, která využívá rychlost změny separace obrazu. Výhoda této metody spočívá ve využití v širším spektru aplikací zejména z důvodu její necitlivosti na nejistoty ve zkoumaném prostředí jako je pracovní vzdálenost, tloušťka vzorku a podkladový materiál. [29]

2.4.2 Princip metody

Klíčovým optickým prvkem techniky mikro rozfokusování obrazu je clona se třemi dírkami, která je přímo přidělána za čočky objektivu a rozděluje optické paprsky do třech různých optických cest. Jak je vidět na obr. 2.33, pokud není měřený bod zaostřen, promítnou se na zobrazovací rovině tři samostatné oddělené body díky rozdělení optických cest clonou. Průměr kroužku D , který vznikne proložením těchto promítnutých bodů je závislý na vzdálenosti vzorku, jeho tloušťce, vzdálenosti dírek ve cloně a na RI materiálu vzorku. S výjimkou RI vzorku jsou všechny tyto zmíněné parametry dobře známé, tím pádem průměr kroužku D je přímo funkcí RI. Pro měření RI je nutné provést kalibraci pomocí několika různých RI a průměrů D . Vztah mezi změnou průměru kroužku a změnou RI vzorku lze tedy vyjádřit jako $\delta D/\delta z$ a je téměř konstantní z důvodu lineárního vztahu mezi vzdáleností z a D a také nezávislosti na tloušťce vzorku. [29]. Na obr. 2.34 je znázorněn vliv dvou různých refrakčních indexů (n_1, n_2) na velikost kroužku D .

Na obr. 2.35 je znázorněn zjednodušený model optického systému pro metodu mikro rozfokusování obrazu aplikovanou na vzorky s hodnotami RI n_1 a n_2 . Souhrnné hodnoty RI pro podklad, čočky a vzduch lze považovat rovno RI, n_e , což vede ke stejnému úhlu θ_e . Jak lze vidět na obr. 2.35 trasa optických paprsků stejná pro oba průměry kroužku $D_1 = D_2$ je použita pro vyjádření optické korelace RI. [29]



Obr. 2.33: Princip mikro-rozfoksování obrazu (Yoon, Yang). [29]

Optické paprsky z bodu z_1 pro n_1 a z_2 pro n_2 se lámou pod úhlem θ_e a vytvoří tak dvě identické trojice bodů ($D_1 = D_2$) na zobrazovací rovině. Výsledkem lineární závislosti mezi průměrem kroužku D a vzdálenosti bodu z , lze vypočítat D jako $D = (\partial D / \partial z)(z - z_0)$. Pro stejné průměry kroužků $D_1 = D_2$ lze psát:

$$\left(\frac{\partial D}{\partial z} \right) (z_1 - z_0) = \left(\frac{\partial D}{\partial z} \right)_2 (z_2 - z_0) \quad (2.26)$$

Podle Snellova zákona pro šíření paprsků prostředím platí pro model na obr. 2.35

$$n_e \sin(\theta_e) = n_1 \sin(\theta_1) = n_2 \sin(\theta_2) \quad (2.27)$$

Vztah mezi z_1 a z_2 lze určit z cest paprsků a rovnice 2.27:

$$\frac{(z_1 - z_0)}{(z_2 - z_0)} = \frac{\tan(\theta_2)}{\tan(\theta_1)} = \frac{n_1 \cos(\theta_1)}{n_2 \cos(\theta_2)} \quad (2.28)$$

Zaostřený obrázek



Rozostřený obrázek



D_0

Δz

n_1

n_2

$(n_1 < n_2)$




D_1

D_2



$$(\Delta D / \Delta z)_1 > (\Delta D / \Delta z)_2$$

Obr. 2.34: Efekt různých refrakčních indexů na kroužek (Yoon, Yang). [29]



Obr. 2.35: Optický model mikro-rozfokusování obrazu (Yoon, Yang). [29]

Lze předpokládat, že hodnota zlomku $\cos(\theta_1)/\cos(\theta_2) \sim 1.0$ protože $\cos(\theta)$ se moc nemění kvůli velmi malému úhlu θ . Z rovnice 2.26 a 2.28 poté vyplývá:

$$\frac{(\partial D/\partial z)_2}{(\partial D/\partial z)_1} = \frac{(z_1 - z_0)}{(z_2 - z_0)} \cong \frac{n_1}{n_2} \quad (2.29)$$

Rovnici 2.29 lze zapsat následovně:

$$n_1(\partial D/\partial z)_1 = n_2(\partial D/\partial z)_2 = C \quad (2.30)$$


kde C je konstanta, kterou lze získat pomocí kalibrace RI– $(\partial D/\partial z)$. Nakonec se RI vyjádří jako funkce $(\partial D/\partial z)$:

$$n = f(\partial D/\partial z) = \frac{C}{(\partial D/\partial z)} \quad (2.31)$$

[29]

2.4.3 Výsledky práce autorů S.Y.Yoon a S.Yang


Autoři v experimentu umístili nad zkoumané vzorky s různým RI skleněnou tabulku s chromovou vrstvou a pomocí leptání vytvořili matici průhledných bodů od sebe navzájem vzdálených $50 \mu\text{m}$ a každý o průměru $3 \mu\text{m}$. Tabulka je vidět principiálně na obr. 2.36.



Obr. 2.36: Skleněná tabulka s chromovou vrstvou a dírkami (Yoon, Yang). [29]

Paprsky světla z halogenové lampy prochází přes dírky v této tabulce, dále přes zkoumaný vzorek, objektiv, clonu se třemi dírkami, zrcadlo, čočku a nakonec vstupují do kamery. Se vzorkem pohybuje v ose z řízený piezo můstek.

Ze série snímků v obr. 2.37 lze vidět závislost průměru pomyslného kroužku D na RI a ose z . S rostoucí osou z roste průměr kroužku dle vztahu $(\Delta D/\Delta z)$ a zároveň s rostoucím RI průměr kroužku klesá. Tato metoda byla testována na několika vzorcích, kdy každý měl certifikovanou hodnotu RI. Testy prokázaly velkou přesnost této metody, a to řádově 10^{-4} RIU (pixel/ μm) mezi certifikovanou a naměřenou hodnotou. Tato metoda je tedy použitelná pro jednoduché měření hodnot RI tekutých a gelových vzorků. [29]



Obr. 2.37: Změna kroužku v závislosti na RI a změně osy z (Yoon, Yang). [29]


2.4.4 Návrh možného použití metody pro měření vzdálenosti

Tato metoda by se dala také použít pro samotné měření vzdálenosti. Světlo by nejprve vstupovalo do objektivu, poté přes clonu se třemi dírkami a dopadalo by na objekt, ke kterému je potřeba měřit vzdálenost. Zaostření těchto paprsků na nekonečno by způsobilo stejnou velikosti pomyslného kroužku mezi jednotlivými světelnými body bez závislosti na vzdálenosti objektu. Pokud by se namířila kamera na objekt osvětlený těmito body, bylo by možné z průměru kroužku určit vzdálenost objektu. Principiální návrh měřicí sestavy je na obr. 2.38.

Z výsledných snímků by se nejprve musely segmentovat světelné body a následně měřit jejich vzájemnou polohu. Segmentace by bylo možné provést například tak, že

by se našla maximální jasová hodnota ve snímku, od které by se následně odečetl definovaný práh. Pokud by jasová hodnota jednotlivých pixelů byla větší než tento rozdíl, zaznamenala by se logická jednička, jinak nula. Tím by vznikla maska, definující nejjasnější oblasti ve snímku. Následně by se mohla na tuto masku aplikovat shluková analýza (například K-means) a hledaly by se tři shlukové oblasti. Výsledkem by byla přesná poloha středu každého světelného bodu ve snímku. Pokud by byl objekt ve větší vzdálenosti, pomyslný kroužek by byl menší a naopak. Pokud by poloha jednotlivých středů byla mimo omezující prahy, vyhodnotila by se situace jako chybová.

Při tomto návrhu se uvažuje libovolný úhel mezi zdrojem světla a kamerou. V případě přesně definovaného úhlu by bylo vhodné použít přístup aktivní triangulace.



Obr. 2.38: Principiální návrh měření vzdálenosti.

3 Průzkum trhu nabízených snímačů

Komerčně se z fokusovacích technik využívají hlavně konfokální snímače a konfokální mikroskopy. V průmyslu se používají konfokální snímače zejména pro přesné měření vzdáleností nebo tloušťky transparentních materiálů a je možné je umístit přímo na výrobní linky. Konfokální mikroskopy nacházejí uplatnění nejvíce v oblasti vědních oborů, které se zabývají zkoumáním 3D vlastností buněk nebo velmi malých částic. [30][31]

3.1 Konfokální snímače

Jedna z největších firem zabývajících se výrobou a vývojem konfokálních chromatických snímačů je Micro-Epsilon. Jedná se o středně velkou firmu, která již přes 50 let vede v oblasti měřicí techniky s vysokou přesností. [30]

Další firma zabývající se výrobou konfokálních snímačů je Keyence, která se obecně věnuje měřícím systémům, laserovým popisovačům, mikroskopům a počítačovému vidění. Firma byla založena roku 1974 a nyní má přes 250 000 zákazníků ve 110 zemích po celém světě. [32]

3.1.1 Firma Micro-Epsilon

Snímače firmy Micro-Epsilon se používají v laboratořích, výrobních podnicích, případně jsou montovány přímo do sériových výrobků. Tato firma vyrábí nejen snímače pro měření vzdálenosti a polohy, ale také například snímače pro měření teploty, rychlosti, snímače pro měření tloušťky barvy a snímače barev. Dále vyrábí kontroléry pro zpracování signálů ze snímačů. [30]


Vlastnosti a použití konfokálních snímačů

Jednou z hlavních výhod použití konfokálních snímačů vzdálenosti od firmy Micro-Epsilon je jejich vysoké rozlišení a vzorkovací frekvence, a to prakticky na všech typech povrchu. Snímače mají malý měřicí bod, díky čemuž mohou být zkoumány velmi malé předměty. Úzký optický kužel snímače navíc umožňuje měřit i velmi strmé plochy (až do 48° náklonu). Firma nabízí jak axiální, tak radiální provedení snímačů, což poskytuje možnost zkoumání geometrických vlastností objektů uvnitř otvorů nebo těžko přístupných míst. Dalším možným použitím snímačů je měření tloušťky transparentních materiálů, jako je například sklo, kdy za použití jednoho snímače je tloušťka měřena s přesností na jeden mikrometr. Mimo jiné lze těmito snímači detekovat i zakřivení čoček brýlí a objektivů (obr. 3.1 vlevo) a také měřit mezery bezpečnostních skel (obr. 3.1 vpravo). Měřicí rozsah se u těchto snímačů

pohybuje od 300 μm do 30 mm, a to až do frekvence měření 70 kHz. Snímače také dokáží měřit až šest úrovní najednou. Základní parametry jednotlivých skupin snímačů jsou uvedeny v tab. 3.1. [30]

Parametry/ Model	Průměr senzoru [mm]	Měřicí rozsah [mm]	Rozlišení [nm]
ISF2402	4	0.4-3.5	16-100
ISF2403	8	0.4-10.0	16-250
ISF2404	12	2.0	40
ISF2405	27-64	0.3-30.0	4-300
ISF2406	20-27	2.5-10.0	24-60
ISF2407	12-54	0.1-3.0	10-20

Tab. 3.1: Parametry konfokálních snímačů firmy Micro-Epsilon.



Obr. 3.1: Příklady použití konfokálních snímačů firmy Micro-Epsilon. [30]

Konfokální kontroléry

Firma Micro-Epsilon dále nabízí ke konfokálním snímačům konfokální kontroléry. Nejrychlejší kontrolér typu confocalIDT IFC2471HS (obr. 3.2) dosahuje vzorkovací frekvence až 70 kHz bez nutnosti použití externího zdroje světla. Kontrolér je považován za jeden z nejrychlejších na světě a je kompatibilní se všemi konfokálními snímači série IFS. Kontrolér se vyrábí ve dvou základních provedeních, a to IFC2471LED,

který slouží pouze pro měření vzdálenosti a poté typ IFC2471MP LED, pomocí kterého lze měřit tloušťku transparentních materiálů. Tyto kontroléry je možné konfigurovat pomocí Ethernetového připojení přes webové rozhraní, ve kterém je možné vybírat z databáze přednastavených měřených materiálů. [33]



Obr. 3.2: Kontrolér od firmy Micro-Epsilon. [33]

3.1.2 Firma Keyence

Konfokální snímače od firmy Keyence jsou také velmi přesné a lze je použít pro měření vzdáleností jakýchkoliv povrchů. Jejich použití je vhodné například pro měření tloušťky tenkých plastových folií, křemíkových desek, skla, příp. pro měření odchylky rotačních součástí. Stejně jako u snímačů firmy Micro-Epsilon, v těle snímače se nachází pouze soubor optických čoček pro rozklad světla a tudíž snímače nejsou náchylné na teplo, elektrický šum případně jiné negativní vlivy okolí. Díky tomu, že mají snímače průměr pouze 8 mm, je možné je použít ve velmi malých prostorech. Firma rovněž vyrábí vlastní konfokální kontroléry s jednoduchým softwarem pro uživatele poskytující nastavení snímání, vizualizaci, ukládání a export naměřených dat. Dále firma vyrábí kromě standardních konfokálních snímačů (řada CL-P) také kvadrturní snímače, které umožňují přesné měření i nerovných povrchů (řada CL-L). Základní parametry snímačů jsou v tabulce 3.2. [34]

Parametry/ Model	Referenční vzdálenost [mm]	Měřicí rozsah [mm]	Rozlišení [μm]
CL-L007	7	1.5	0.25
CL-L015	15	1.3	0.25
CL-L030	30	3.7	0.25
CL-L070	70	10	0.25

Tab. 3.2: Parametry konfokálních snímačů firmy Keyence.

3.2 Konfokální mikroskopy

3.2.1 Firma Zeiss

Jednou z firem vyrábějící konfokální mikroskopy je německá firma Zeiss, která čítá kolem 32 000 zaměstnanců v téměř 50 zemích. Firma působí v optickém a optoelektronickém průmyslu, zejména v odvětví výroby, měření kvality a technologií v medicíně. Vyrábí různé druhy mikroskopů, brýlové čočky, kamerové čočky a dalekohledy.


Jejich nejnovějším modelem konfokálního mikroskopu je ZEISS LSM 980 with Airyscan 2, který nachází uplatnění v neurovědě, výzkumu rakoviny a dalších disciplínách zkoumající živé organizmy. Firma slibuje nadstandardní rozlišení mikroskopu s možností pozorování velkých ploch s velmi krátkou dobou měření. Dále k mikroskopům poskytuje množství softwaru pro optimalizaci práce, podporu efektivity a nakládání s daty [31]. Tento model lze vidět na obr. 3.3.




Obr. 3.3: Konfokální mikroskop firmy Zeiss. [31]

Metoda Airyscan 2 používá detektor oblastí se 32 soustředně poskládanými detekčními elementy. To umožňuje měřit víc bodů najednou. Samotná konfokální dírka

zůstává otevřená a nezadržuje tak světlo, díky čemuž je zachyceno více fotonů. To produkuje při záznamu znatelně lepší výsledky [31]. Princip této metody lze vidět na obr. 3.4. Ukázkový snímek neuronu myšího mozku je znázorněn na obr. 3.5.



Obr. 3.4: Princip metody Airyscan. [31]




Obr. 3.5: Myší mozek pod konfokálním mikroskopem. [31]

3.2.2 Firma BioTek

BioTek má již 50 letou historii v oblasti zobrazovacích a mikroskopických systémů, čteček mikrodestiček, dávkovače mikrodestiček a mnoho dalšího.

Jejich nejnovějším modelem konfokálního mikroskopu je Cytation C10 Confocal Imaging Reader, který kombinuje automatický digitální konfokální a širokoúhlý mikroskop s konvenční čtečkou mikrodestiček. Konfokální rotační disk v tomto zařízení poskytuje vynikající rozlišení a optické možnosti dělení při použití na širokou škálu vzorků. Výrobce používá kvalitní CMOS snímací kameru, objektiv od firmy Olympus a osvětlení pomocí laseru [35]. Unikátní architektura konfokálního mikroskopu je ukázána na obr. 3.6.




Obr. 3.6: Unikátní architektura konfokálního mikroskopu BioTek. [35]

4 Experimentální ověření

V této části práce je popsáno experimentální pracoviště, praktická implementace metod DFF a DFD. Na závěr této části jsou ukázány výsledky implementovaných metod.


4.1 Experimentální pracoviště, vývojové prostředí

Pracoviště bylo tvořeno kamerou, objektivem, podstavcem pro kameru, počítačem, dodatečným osvětlením. Dále byla použita redukce mezi kamerou a objektivem, která obsahuje modul Canon EF a také byl použit 5 V zdroj pro napájení objektivu a modulu Canon EF. Pro komunikaci počítače s modulem Canon EF byl použit převodník USB/RS232. Schéma sestavy lze vidět na obr. 4.1. Algoritmy metody kontrolované fokusování a metody rozfokusování jsou zpracovány v prostředí Matlab.




Obr. 4.1: Náskres experimentálního pracoviště.

Pro záznam snímků byla použita barevná průmyslová kamera typu Imaging Source DFK21AU04. Kamera má rozlišení 640x480 px, rychlost snímání 60 fps, komunikace i napájení je přes USB port. Přes redukci je ke kameře přimontován nastavitelný objektiv typu Tamron 177D AF 28-80 mm F/3.5-5.6 Aspherical. Tento objektiv umožňuje elektronicky nastavovat zaostření a velikost clony. Ohnisková vzdálenost se však musí nastavovat ručně. Ta byla pro zjednodušení vypracování těchto metod nastavena staticky na hodnotu 28 mm, tedy s nejmenším možným



Obr. 4.2: Ukázka způsobu focení kalibračního objektu.

přiblížením. Pro řízení tohoto objektivu je zde použit modul Canon EF 1.0 umožňující řízení objektivů Canon pomocí sériové linky RS-232 nebo TTL-232, který je přes převodník připojen do USB portu počítače. Modul je vložen do redukce mezi kamerovým závitem C mount a závitem Canon. To samozřejmě vede ke zvětšení vzdálenosti mezi samotným snímačem kamery a objektivem, což značně způsobí zkrácení a přiblížení celého ostřicího rozsahu. Není tedy možné vůbec zaostřit na nekonečno a snímané objekty musí být podstatně menší. Modul Canon EF lze vidět na obr. 4.3.



Obr. 4.3: Modul Cannon EF.


4.1.1 Komunikace s modulem Canon EF

I přes výše zmíněnou velkou nevýhodu, výhoda v použití této sestavy je, že je možné pohodlně přímo z prostředí Matlab přesně ovládat nastavení clony, zaostření a také pořizovat snímky. Základní funkce z prostředí Matlab potřebné pro komunikaci s modulem Canon EF 1.0 po sériové lince jsou popsány v tabulce 4.1.

Funkce	Popis
<code>serial()</code>	vytvoření objektu asociovaného s COM portem
<code>fopen()</code>	otevření objektu pro komunikaci
<code>fprintf()</code>	zápis řetězce na sériovou linku
<code>fclose()</code>	uzavření komunikace s objektem

Tab. 4.1: Základní funkce pro komunikaci s modulem Canon EF.

Při komunikaci s modulem Canon EF je každý příkaz zabalen do start znaku, ID zařízení, stop znaku a kontrolního součtu viz obr. 4.4



Obr. 4.4: Formát řetězce pro ovládání objektivu po sériové lince.

Popis jednotlivých částí tohoto řetězce je uveden v tabulce 4.2. Samotný příkaz **COMMAND** je složen ze třech písmen a ze čtyř číslic. Písmena na začátku určují, jaká periferie se bude ovládat. Číslice reprezentují nastavovanou hodnotu v hexadecimálním zápisu. Při realizaci této práce byly využity dva základní příkazy, a to **lfp** ("lenses focus percentage") a **lap** ("lenses aperture percentage"). První z uvedených příkazů slouží pro procentuální zaostření z rozsahu. Druhý příkaz slouží pro procentuální nastavení clony z rozsahu.

START	Start znak: 0x02
ID	ID zařízení: 0x00-0x7F
COMMAND	Samotný příkaz pro jednotlivé úkony (např. lfp0200)
STOP	Stop znak: 0x03
CRC	Kontrolní součet

Tab. 4.2: Řetězec pro komunikaci s modulem Canon EF.

4.1.2 Komunikace s kamerou

Kamera je připojena pomocí USB portu do počítače. Prostředí Matlab umožňuje přímou komunikaci s kamerou pomocí Image Acquisition Toolboxu. Samotné nastavení kamery lze vidět na výpisu 4.1. Nejprve je nutné zavolat příkaz `imaqreset`, který způsobí odpojení a smazání všech připojených akvizčních zařízení. Další příkaz `videoinput()` slouží k nastavení propojení mezi prostředím Matlab a samotnou kamerou, kde první parametr označuje jaký ovladač se použije pro komunikaci se zařízením. V tomto případě jde o obecný ovladač operačního systému pro video rozhraní `winvideo`. Druhý parametr v tomto příkazu je ID zařízení. Tím se vytvoří objekt, zde pojmenovaný `kam`, u kterého je možné nastavovat další parametry. Dále je přiřazena parametru `ReturnedColorSpace` hodnota `grayscale`, což znamená, že výstupní video bude v šedotónové škále. Snímání v šedotónové škále je zde zvoleno z několika důvodů. Prvním z nich je, že popisované metody v této práci nevyžadují pro estimaci hloubky scény barevný snímek. Dalším důvodem je menší paměťová náročnost při pořizování většího množství snímků a také vyšší rychlost zpracování dat. Barevné snímky by se uplatnily pouze pro potřebu barevného výsledného all-in-focus snímku, nicméně pro estimaci hloubkové mapy je stejně nejprve potřeba převést vstupní snímky do šedotónové škály. Pomocí následujícího příkazu `triggerconfig()` je nastaveno spuštění snímání v manuálním režimu. Poslední tři řádky z výpisu slouží pro manuální nastavení expozice, což je například u metody DFD mnohdy velmi kritické z důvodu změny nastavení clony.

Výpis 4.1: Nastavení komunikace s kamerou v prostředí Matlab

```
1 imaqreset;
2 pause(2);
3 kam = videoinput('winvideo',1);
4 kam.ReturnedColorSpace = 'grayscale';
5 triggerconfig(kam,'manual');
6 param = getselectedsource(kam);
7 param.ExposureMode = 'manual';
8 param.Exposure = -4;
```

4.2 Kontrolované fokusování


V této části je popsána problematika automatického pořizování snímků, kalibrace kamery a samotná estimace hloubkové mapy, kde jsou popsány dílčí kroky metody.

4.2.1 Kalibrace kamery

U této metody je kalibrace kamery rozdělena na dvě systematické části, a to automatizované pořízení snímků a samotný výpočet kalibrace. Byla zde snaha o vytvoření univerzálního algoritmu pro automatizované pořízení snímků, který bude sloužit jak pro pořízení snímků potřebných pro kalibraci, tak pro snímky, na kterých se provádí estimace hloubkové mapy.

Automatizované pořízení snímků pro kalibraci kamery


Tato metoda vyžaduje diametrálně odlišný způsob pořizování kalibračních snímků a výpočet kalibrace kamery oproti metodě rozfokusování. V této části je zejména popsáno automatické nastavování kamery s objektivem, pořizování a ukládání kalibračních snímků. Vývojový diagram lze vidět na obr. 4.5.



Obr. 4.5: Vývojový diagram automatizovaného pořizování snímků.

Nejprve je dle výpisu 4.1 nastavena komunikace a zapnut náhled kamery, který usnadňuje nastavení jednotlivých parametrů. Poté je zobrazeno okno pro zadání vstupních parametrů viz obr. 4.6. První parametr slouží k nastavení počtu kalibračních vzdáleností. Pomocí druhého parametru se nastaví první kalibrační vzdálenost

od kamery. Další určuje vzdálenost posunutí mezi jednotlivými měřeními. Následně se nastaví krok fokusování a nakonec se zadá název výstupního souboru.



Parameters setup

Number of measurements:
10

Start measurement distance [cm]:
10

Measurement step distance [cm]:
2.5


Focus step [%]:
1

Output filename:
CalibrationMat

OK Cancel

Obr. 4.6: Nastavení vstupních parametrů pro zachycení snímků

Po zadání všech parametrů skript spustí záznam kamery, otevře komunikaci s objektem po sériové lince a nastaví zaostření na nulu. Poté se začne v každé referenční vzdálenosti se záznamem kalibračních snímků v celém ostřicím rozsahu. Pokud parametr kroku fokusování je nastaven na 1 %, provede se v dané vzdálenosti záznam sta snímků. Před záznamem každé série se objeví okno (obr. 4.7), které informuje o nastavení kalibračního objektu do dané referenční vzdálenosti. Po kliknutí na tlačítko **Continue** dojde ke spuštění záznamu série snímků, tlačítko **Cancel** zruší záznam.



Object distance adjust

? Please set the object distance to: 10 cm


Continue Cancel

Obr. 4.7: Informativní okno pro nastavení vzdálenosti kalibračního objektu.

Při samotném nastavování zaostření kamery byla napsaná jednoduchá funkce sloužící pro přepočtení vstupních procent na hexadecimální číslo. Z něj se vytvoří řetězec, který se přímo posílá na sériovou linku. Tuto funkci lze vidět ve výpisu 4.2.

Před ukončením programu se ještě uzavře port sériové linky a zastaví se kamera. Pokud záznam všech měření proběhl úspěšně, jsou hodnoty parametrů a všechny snímky strukturálně uloženy do souboru pro další zpracování.

Jako kalibrační objekt byl použit vytištěný černý kříž s dostatečným počtem hran na bílém papíře, který byl v každé kalibrační vzdálenosti umístěn kolmo ke kameře. Ukázku kalibračního kříže lze vidět na obr. 4.8.



Obr. 4.8: Ukázka kalibračního kříže.

Výpis 4.2: Přepočítání procent a zápis na sériovou linku.

```


1 function setFocus(aSerial, aPercentage)
2     value = min(aPercentage, 100);
3     value = max(value, 0);
4     value = uint16(value*0.01*1024);
5     value = dec2hex(value,4);
6     fprintf(aSerial, '\002xlfps\003x', value);
7 end

```

Kalibrace kamery

Pokud jsou nachystána kalibrační data pomocí výše zmíněného postupu, je možné přistoupit k samotnému výpočtu kalibrace. Vývojový diagram výpočtu kalibrace kamery pro metodu DFF lze vidět na obr. 4.9.

Nejprve je tedy nutné načíst parametry a kalibrační snímky ze souboru. Poté je potřeba pro každou referenční vzdálenost určit nejostřejší snímek. Získáme tak ke každému indexu zaostření odpovídající vzdálenost. Pro měření ostrosti je zde



Obr. 4.9: Vývojový diagram výpočtu kalibrace kamery.


použit filtr typu Laplacián gausiánu se vhodně nastaveným práhováním. Tento filtr vykazoval ze série pokusů s ostatními filtry nejlepší výsledky. Závislost procentuálního zaostření s odpovídající ostroostí na vzdálenosti lze vidět v tab. 4.3.

Z těchto dat je následně nutné odstranit oblasti, které jsou mimo ostřicí rozsah kamery. Pokud by se tyto oblasti započítaly do aktivního rozsahu, negativně by se ovlivnila aproximace odpovídajících hodnot. Pro odstranění těchto oblastí byl použit jednoduchý algoritmus založený na myšlence, že s rostoucí vzdáleností také musí růst index zaostření kamery. Takto odfiltrované hodnoty jsou zvýrazněné v tabulce 4.3. Lze si všimnout, že algoritmus není zcela efektivní, jelikož neodfiltroval například i snímky pro vzdálenost 12.5 cm. Pro výslednou aproximaci je to ovšem zanedbatelné. Jiným možným přístupem je spočítat průměr množství ostroosti ve vybraných ostrých snímcích a snímky s nižšími hodnotami zanedbat.

Vzdálenost [cm]	Zaostření [%]	Ostrost [-]
10.0	15	0.12
12.5	1	1.47
15.0	3	16.88
17.5	26	18.23
20.0	56	17.49
22.5	68	17.70
25.0	94	15.64
27.5	98	15.51
30.0	99	9.75
32.5	97	5.76
35.0	100	2.44

Tab. 4.3: Závislost zaostření s odpovídající ostroostí na vzdálenosti.


Výsledné odfiltrované hodnoty jsou aproximovány pomocí funkcí `polyfit()` a `polyval()`, a to polynomem druhého řádu. Tyto hodnoty s aproximací lze vidět na grafu na obr. 4.10.



Obr. 4.10: Závislost procentuálního zaostření na vzdálenosti.

4.2.2 Estimace hloubkové mapy

V této části jsou popsány dílčí kroky pro estimaci hloubkové mapy. Při zpracování jsem vycházel z práce autorů Y.Chen, Y.Wu [16] a z algoritmu publikovaného na fóru [36]. Orientační vývojový diagram lze vidět na obr. 4.11.




Obr. 4.11: Vývojový diagram metody DFF.

Příprava obrazového zásobníku

U této metody estimace hloubkové mapy se počítá s tím, že obrazový zásobník bude obsahovat snímky s různým nastavením zaostření kamery, přičemž první snímek bude zaostřen na popředí a poslední snímek zaostřen na pozadí. Při volbě počtu vstupních snímků se musí brát mimo jiné v potaz rozmanitost sledovaného objektu a také potřebné rozlišení hloubkové mapy. V tomto případě je v obrazovém zásobníku sto snímků. Bez kalibrace kamery jsou výsledné hodnoty hloubkové mapy relativní v závislosti na krocích zaostření mezi jednotlivými snímky. Pro zjištění absolutních

hodnot 3D vlastností scény je potřeba provést kalibraci této metody a kamery viz výše. Na obr. 4.12 můžeme vidět dva snímky z obrazového zásobníku, který je pro ověření této metody použit. Snímek vlevo je zaostřen na popředí a snímek vpravo na pozadí.



Obr. 4.12: Ukázka prvního (vlevo) a posledního snímku (vpravo) obrazového zásobníku.

Zarovnání snímků

V Matlabu lze použít vestavěné funkce pro zarovnávání a transformaci snímků. Je možné použít například funkci `imregtform`, která odhaduje geometrickou transformaci daného transformovaného snímku podle referenčního snímku. Do této funkce vstupují tedy dva snímky. Referenční snímek je většinou neměnný a zpravidla to bývá první snímek obrazového zásobníku. Oba snímky vstupují do této funkce v šedotónové škále. Výstupem funkce je struktura nesoucí informaci o transformaci snímku. Poté lze na transformovaný RGB snímek nebo snímek v šedotónové škále tuto transformaci aplikovat. Pro zlepšení vlastností transformace lze ještě upravit další parametry jako například počet iterací nebo minimální krok atd. Výsledek automatického zarovnání na dvou názorných testovacích snímcích pořízených ze dvou různých pozorovacích úhlů lze vidět na obr. 4.13, kde vlevo jsou dva nezarovnané snímky a vpravo zarovnané.



Obr. 4.13: Příklad zarovnání dvou vstupních snímků.



Jasová úprava snímků

Jako další část předzpracování obrazu je jasová úprava jednotlivých snímků podle referenčního snímku, kterým je v tomto případě první snímek v obrazovém zásobníku. Princip je takový, že se nejprve převedou všechny snímky z obrazového zásobníku do šedotónové škály a poté se vypočítá rozdíl průměru jasových hodnot referenčního a aktuálního snímku. Tento rozdíl se nakonec přičte k jasové hodnotě každého pixelu snímku z obrazového zásobníku.



Měření ostrosti

Po sérii pokusů detekcí hran různými operátory jsem zjistil, že nejlepších výsledků v této aplikaci dosahuje operátor typu Log. Masku nejen toho operátoru lze v Matlabu vytvořit jednoduše pomocí vestavěné funkce `fspecial`. Následně jsem pro filtraci snímků převedených do šedotónové škály použil funkci `imfilter` se dvěma vstupními parametry. Prvním z nich je zpracováváný snímek a druhým je maska operátoru. To vede k vytváření obrázků s informací o ostrosti hran jednotlivých snímků, což lze vidět na obr. 4.14 vlevo. Tyto obrázky jsou následně dilatovány pomocí vestavěné funkce `imdilate`. Dilatace se u těchto typů úloh používá zejména z důvodu „roztážení“ hran do blízkého okolí, které hrany neobsahuje. Počítá se tedy s tím, že blízké okolí hran má stejnou hloubku jako hrany samotné. Tím samozřejmě může dojít k poškození samotných hranic objektů ve snímku. Ukázka detekce

hran prvního snímku z obrazového zásobníku zaostřeného na popředí po dilataci je na obr. 4.14 vpravo. Na obr. 4.15 je poté ukázka detekce hran posledního snímku z obrazového zásobníku zaostřeného na pozadí.



Obr. 4.14: Detekce hran při zaostřeném snímku na popředí, vlevo bez dilatace, vpravo s dilatací.



Obr. 4.15: Detekce hran při zaostřeném snímku na pozadí, vlevo bez dilatace, vpravo s dilatací.


Přiřazení hloubkové mapy

Základní algoritmus pro přiřazení hloubkové mapy je vidět ve výpisu 4.3. Před samotným vytvořením hloubkové mapy je nejprve nutné vytvořit matici prahů pro detekci hran, zde je tato matice pojmenovaná `logResponse` a má stejnou velikost jako snímky v obrazovém zásobníku (`imgStackGray`). Pro každý element matice prahů lze připočíst parametr `logthreshold`, který při zvýšení způsobí, že se budou hledat významnější hrany. Dále se ve for cyklu porovnávají jednotlivé snímky obrazového zásobníku po hranové detekci (`imgEdges`). Tím vznikne indexová mapa nesoucí informaci o tom, které oblasti jsou u daného snímku právě zaostřené (řádek č.5). V dalším kroku (řádek č.6) se do matice prahů v definovaných místech dle indexové mapy uloží přímo hodnota z hranové detekce. To slouží k tomu, aby v se následujícím kroku hledaly pouze významnější hrany než v předchozím kroku. Zároveň se počítá s tím, že první snímek v obrazovém zásobníku bude zaostřen na popředí. Na konci for cyklu (řádek č.7) se již přiřadí do matice reprezentující hloubku daný index for cyklu v místech definovaných indexovou mapou.


Výpis 4.3: Přiřazení hloubkové mapy.

```
1 logthreshold = 0
2 logResponse = zeros(size(imgStackGray{1})) + logthreshold;
3 depthMap = ones(size(imgStackGray{1}));
4 for i = 1:length(imgStackGray)
5     index = imgEdges{i} > logResponse;
6     logResponse(index) = imgEdges{i}(index);
7     depthMap(index) = i;
8 end
```

V případě zkalibrované kamery lze vytvořit odpovídající hloubkovou škálu. Vzniklá hloubková mapa s hloubkovou škálou lze vidět na obr. 4.16. Následně se takto získaná mapa vyhladí Gaussovým filtrem a vznikne tak konečná hloubková mapa viz obr. 4.17.



Obr. 4.16: Estimace hloubkové mapy bez vyhlazení.




Obr. 4.17: Estimace hloubkové mapy s vyhlazením.

Skládání vrstev do jednoho ostrého snímku

Nejprve se použije hloubková mapa pro každý snímek v obrazovém zásobníku jako index dané vrstvy. Tyto jednotlivé vrstvy se uloží do výsledné matice reprezentu-


jící ostrý obrázek. Problém při vytváření ostrého obrázku jsou přechody mezi jednotlivými vrstvami. Tento nedostatek lze potlačit alfa mícháním, které je popsáno v teoretické části. Je zde použita aplikace výrazu 2.7 pomocí indexů reprezentující zaostřené vrstvy. Konečný výsledek sešití ostrých vrstev a po aplikaci alfa míchání lze vidět na obr. 4.18



Obr. 4.18: Sešití jednotlivých ostrých vrstev.

Segmentace hloubkové mapy

Segmentace výsledné hloubkové mapy je možné provést pomocí výše popsaného ostrého snímku. Nejjednodušší metoda je využít kontrastního rozdílu mezi pozadím a zkoumaným objektem. V tomto případě jde o černé čáry a symboly na bílém papíře, tudíž je možné tuto metodu aplikovat. Pro odfiltrování bílého pozadí se nejprve zjistí maximální hodnota jasu pixelů celého snímku, od které se následně odečte definované číslo. Výsledná hodnota reprezentuje práh pro segmentaci, pomocí kterého se určuje, zda daný pixel je součástí objektu nebo se jedná o pozadí a má být odfiltrován. Tím vznikne maska, která se násobí s původní hloubkovou mapou. Výslednou hloubkovou mapu po segmentaci lze vidět na obr. 4.19.



Obr. 4.19: Hloubková mapa po segmentaci.


4.3 Metoda rozfokusování

Na začátku této části je popsána problematika kalibrace kamery. Ta je rozdělená na dvě důležité části, a to na automatizované pořízení snímku a výpočet kalibrace kamery. Je tedy možné tyto dvě části systematicky rozdělit pro větší variabilitu řešení samotné kalibrace. Díky první části získáme všechny známé parametry kamery a také dva rozfokusované snímky. Vše je následně kompaktně uloženo do struktury, kterou lze později načítat algoritmy pro estimaci parametrů. Na konci této části je popsána estimace vzdálenosti objektů od kamery. Popsaná kalibrace kamery a měření vzdálenosti vychází z práce autorů D.Zion, F.Deschenes [24] a G.Surya, M.Subbarao [26].

4.3.1 Automatizované pořízení snímků

Jedna z nejdůležitějších věcí potřebná pro správnou kalibraci kamery a následnou estimaci samotné hloubkové mapy je správně pořídit rozfokusované snímky a také další známé parametry kamery. V této části je zejména popsáno automatické nastavování kamery a objektivu a samotné pořizování snímků. Vývojový diagram lze vidět na obr. 4.20.


Nejprve je dle výpisu 4.1 nastavena komunikace a zapnut náhled kamery, který usnadňuje nastavení jednotlivých parametrů. Poté je zobrazeno okno pro určení způ-



Obr. 4.20: Vývojový diagram automatizovaného pořizování snímků.


sobu snímání viz 4.21. Na výběr je ze dvou možností, a to **Normal** a **Calibration**. Pomocí prvního režimu lze pořídit dva rozfokusované snímky pro následný výpočet vzdálenosti. Předpokládá se zde, že je kamera již zkalibrována. Pomocí druhého režimu lze pořídit dva snímky určené pro kalibraci kamery. Rozdíl mezi oběma režimy je ten, že kalibrační režim ukládá všechny známé parametry kamery včetně zadané referenční vzdálenosti objektu a ukládá je do jiného souboru než normální režim. Dále je možné u kalibračního režimu zvolit způsob jednoho zaostřeného snímku, což některé metody pro výpočet kalibrace vyžadují. Pro získání zaostřeného snímku je nejprve s počátečním nastavením clony pořízen soubor snímků s různě nastaveným zaostřením, ze kterého je vybrán nejostřejší snímek a jemu odpovídající zaostření. Poté se pořídí první referenční snímek, následně se změní nastavení clony a pořídí se druhý referenční snímek.

Pro ukázkou byl umístěn objekt do vzdálenosti 22 cm od kamery a byly pořízeny dva referenční snímky viz 4.22. Na levém obrázku lze vidět snímek pořízený s maximálně uzavřenou clonou, což pro objektiv Tamron 177D AF odpovídá číslu clony $f/22$. Na pravém obrázku pak lze vidět snímek s maximálně otevřenou clonou, zde



Obr. 4.21: Dialogové okno pro určení způsobu snímání.

odpovídající číslu $f/3.5$.



Obr. 4.22: Ukázka prvního a druhého referenčního snímku.

4.3.2 Kalibrace kamery

Pro kalibraci kamery byla použita metoda estimace parametrů změnou clonového čísla. Tato metoda je popsána v teoretické části, kde byly rovněž diskutovány její výhody.

Pro získání dvou rozfokusovaných snímků umístíme objekt do referenční vzdálenosti u_r a spustíme algoritmus popsany výše v režimu kalibrace. Následně se tato data použijí pro estimaci parametrů kamery, a to tak, že se nejprve pomocí vzorce 2.14 spočítá rozdíl rozmazanosti G obou snímků. Pro vytvoření potřebného Laplaceova operátoru existuje v prostředí Matlab funkce `fspecial('laplacian')`, typ operátoru je zadán parametrem. Pro konvoluci snímků s operátorem je použita funkce `imfilter()`, kde jako první parametr se zadá kýžený snímek a jako druhý parametr se zadá operátor. Následně se dle vzorce 2.22 spočítá ze známých clonových čísel F_1 a F_2 hodnota α , která se použije pro výpočet množství rozmazanosti σ_2 podle vztahu 2.23. Množství rozmazanosti σ_1 lze vypočítat dle vztahu 2.21.

Tyto parametry se posléze dosadí do vzorce 2.24, čímž získáme vzdálenosti s_1 a s_2 . V tomto případě budou tyto vzdálenosti stejné, je tedy možné výpočet zjednodušit a počítat pouze jednu vzdálenost, a to s_2 . Parametr se nakonec uloží do souboru pro následnou estimaci vzdálenosti.

Pro ukázkové snímky z obrázku 4.22 a referenční objekt ležící ve vzdálenosti 22 cm od kamery vyšla kalibrační vzdálenost $s = 24.5mm$.

4.3.3 Měření vzdálenosti

Po úspěšné kalibraci kamery je možné přejít k estimaci vzdáleností objektů od kamery. Stejně jako u výpočtu kalibrace kamery se nejprve pořídí dva různě rozfokované snímky a vypočítá se jejich rozdíl G . Následně se rovněž vypočítá poměr clonových čísel α a z toho množství rozmazanosti σ . Nakonec se podle vzorce 2.25 spočítá kýžená vzdálenost objektu.

Pro určení hloubky jednotlivých částí scény je možné jednoduše vstupní snímky rozdělit na menší obrázky a výslednou vzdálenost tak počítat pro každý obrázek. Avšak v této práci z důvodu použité aparatury a jejím nevýhodám popsaným na začátku praktické části nelze určovat hloubku jednotlivých částí scény. Tedy z důvodu velmi zkráceného ostřicího rozsahu kamery a s tím spojenou nemožností ostření na větší objekty. To způsobí velmi malý vzorek dat pro každý jednotlivý obrázek a výsledná mapa tak nepodává relevantní informace. Z toho důvodu je nutné použít pro měření vzdálenosti pokud možno co největší vzorek dat, v tomto případě celý snímek.


4.4 Výsledky implementovaných metod

V této části práce jsou ukázány a diskutovány výsledky metody kontrolovaného fokusování a metody rozfoksování, jejichž implementace byla popsána v teoretické i praktické části.

4.4.1 Kontrolované fokusování

Pro ověření funkčnosti metody jsem umístil do ostřicího rozsahu soustavy dva referenční objekty s vhodnou úrovní textury, v tomto případě se jedná o zadní strany hracích karet postavených kolmo na podložku. První karta byla postavená ve vzdálenosti 20 cm od objektivu kamery a druhá ve vzdálenosti 25 cm. Následně jsem automaticky pořídil sto snímků, kdy byl postupně první snímek zaostřený na popředí a poslední snímek na pozadí (obr. 4.23 vlevo a vpravo). Poté jsem spustil algoritmus estimace hloubkové mapy popisovaný v teoretické i praktické části. Ten

vygeneroval ostrý snímek (obr. 4.24) a k tomu hloubkovou mapu, kterou lze vidět na obr. 4.25.




Obr. 4.23: První a poslední snímek zadních stran karet.



Obr. 4.24: Sešitý ostrý snímek karet.


Průměr indexů bodů zadní karty (pravá část obrázku 4.25) vyšel 72.7, což dle kalibrace odpovídá hloubce 25.2 cm a průměr indexů bodů přední karty (levá část obrázku 4.25) vyšel 37. To odpovídá dle kalibrace hodnotě 19.9 cm. Z těchto zjištěných hodnot je zřejmé, že hloubková mapa je velmi přesná.




Obr. 4.25: Hloubka scény s kartami ve formátu HSV.

Další testovací objekty


V této části jsou ukázány estimace hloubkových map dalších testovacích objektů.




Obr. 4.26: Hloubková mapa maticek a šroubků.



Obr. 4.27: Hloubková mapa klíče.



Obr. 4.28: Hloubková mapa malého úchytu.



Obr. 4.29: Hloubková mapa stroužku česneku.

4.4.2 Metoda rozfokusování

Pro ověření této metody jsem nejprve zkalibroval kameru dle popsaného postupu v teoretické i praktické části. Jako kalibrační objekt jsem opět použil zadní strany hracích karet. V tomto případě byla potřeba pouze jedna karta umístěná v referenční vzdálenosti. Po úspěšné kalibraci kamery, jak jsem již psal výše, byl vypočten parametr s o hodnotě 24.5 mm. Následně jsem umisťoval kartu do různých vzdáleností od kamery a pomocí výše zmíněného algoritmu pořizoval vždy dva různě rozfokusované snímky, kdy nastavení parametrů kamery pro estimaci vzdálenosti bylo identické s nastavením parametrů při kalibraci. Výstupem algoritmu byly estimované vzdálenosti u , které jsou spolu se skutečnými vzdálenostmi u_r souhrnně sepsány níže v tabulce č. 4.4. Jak lze vidět ze třetího sloupce, absolutní chyba estimace vzdálenosti se pohybuje od 0.2 cm do 1.3 cm, což odpovídá relativní chybě v rozmezí od 1.1 % do 13.0 %.

u_r [cm]	u [cm]	δ [cm]	δ_r [%]
10.0	11.3	1.3	13.0
12.0	11.5	0.5	4.2
14.0	12.8	1.2	8.6
16.0	15.2	0.8	5.0
18.0	17.8	0.2	1.1
20.0	21.2	1.2	6.0

Tab. 4.4: Výsledné hodnoty estimace vzdáleností pomocí DFD.

Závěr

Na začátku této práce jsem objasnil základní metody optického měření vzdáleností a 3D vlastností scény. Dále jsem vysvětlil tři základní typy fokusovacích metod pro rekonstrukci 3D vlastností objektů, a to metodu konfokální mikroskopie, kontrolované fokusování (DFF) a metodu rozfokusování (DFD). Následně jsem popsal metodu mikro-rozfokusování obrazu, která slouží ke stanovení chemických vlastností transparentních materiálů pomocí měření jejich fyzikálních vlastností, a to zejména měřením refrakčního indexu.

U metody konfokální mikroskopie jsem popsal princip pomalého rastrujícího konfokálního mikroskopu, rychlého konfokálního mikroskopu založeného na metodě Nipkowova disku a na akusticko-optickém deflektoru. Nejrychlejší metodou snímání je mikroskop s Nipkowovým diskem díky množství dírek, přes které je pozorovaný objekt osvětlen. S tím spojená nevýhoda je, že kvůli malé frakci světla procházející přes tento kotouč mohou být výsledné signály velmi slabé.

Dále jsem u metody DFF popsal základní princip a diskutoval jsem řadu prací zabývajících se touto tematikou s ukázkou jejich výsledků. Některé přístupy jsou založené na segmentaci objektů ve scéně, příp. na určitém modelu prostředí, jiné se segmentací objektů vůbec nepracují, ale pracují pouze s informacemi pořízenými při snímání. Také byla u této metody teoreticky objasněna kalibrace kamery. Následně jsem navrhl teoretický postup pro estimaci hloubkové mapy pomocí této metody a také jsem popsal elementární náležitosti pro sešití ostrého snímku.

U metody DFD jsem rovněž popsal základní princip s ukázkou několika prací a s popisem jejich přístupů. Poté jsem matematicky popsal měření vzdálenosti a dva přístupy kalibrace kamery s diskuzí jejich vlastností.

K technice mikro-rozfokusování obrazu jsem popsal vznik této metody, její princip a ukázel jsem praktické výsledky práce zabývajících se tímto tématem. Následně jsem vymyslel a sepsal návrh postupu pro optické měření vzdálenosti vycházející z principu této metody.

V druhé části této práce jsem pro experimentální ověření vybral metodu DFF a metodu DFD. Ověření metody konfokální mikroskopie by bylo velmi obtížné z důvodu drahého a těžko dostupného vybavení. Pro tyto dvě metody jsem připravil a nasnímal několik experimentálních objektů, kdy pro každý objekt je vytvořený obrazový zásobník obsahující snímky vždy s různým nastavením zostření. Obrazový zásobník je specifický pro obě metody. U metody DFF odpovídá počet vstupních snímků přímo rozlišení výsledné hloubkové mapy. Řádově je vhodné pracovat s obrazovým zásobníkem v rozmezí od 10 do 100 snímků, avšak reálná velikost zásobníku není nijak omezena. Metoda DFD vyžaduje vždy pouze dva snímky a parametry kamery, kdy některé z nich je potřeba získat kalibrací. Ta je u této metody kri-

tická. Kalibrace u metody DFF není nutná, je potřeba pouze pro určení absolutních vzdáleností hloubky jednotlivých částí zkoumané scény.

Pro experimentální ověření metod jsem použil běžnou průmyslovou kameru s elektronicky nastavitelným objektivem pomocí sériového rozhraní přímo z prostředí Matlab. Tuto aparaturu jsem představil na začátku praktické části práce, kde byly rovněž diskutovány její výhody a nevýhody.

Pro metodu DFF jsem popsal algoritmus automatizovaného pořizování snímků pro kalibraci kamery a pro běžné snímání. Tyto dva přístupy se liší v tom, že při pořizování snímků pro kalibraci kamery potřebujeme znát i přesnou referenční vzdálenost kalibračního objektu od kamery a další parametry, kdežto při běžném snímání tyto informace přirozeně nepotřebujeme. Dále jsem pro tuto metodu popsal výpočet kalibrace kamery. V části estimace hloubkové mapy jsem popsal přípravu obrazového zásobníku zahrnující zarovnání vstupních snímků pomocí optického toku a jasovou korekci. Dále byl objasněn způsob detekce hran a měření ostrosti jednotlivých částí snímků a také bylo vysvětleno, jak jsem vytvářel hloubkovou mapu scény. Poté byl prezentován způsob šití zaostřených vrstev, tvorba ostrého snímku a s tím spojené míchání zaostřených vrstev. Nakonec jsem uvedl možnost segmentace hloubkové mapy dle reálného objektu, kdy se informace o hloubce zobrazí pouze pro daný zkoumaný objekt.

Pro metodu DFD jsem opět popsal algoritmus pro automatizované pořizování snímků jak pro kalibraci kamery, tak pro běžné snímání. Zde je opět pro režim kalibrace typické ukládání i dalších parametrů o kameře a snímané scéně. Dále jsem popsal praktický způsob výpočtu kalibrace kamery, který je detailně popsán v teoretické části práce a objasnil jsem samotné měření vzdálenosti. Poté jsem objasnil způsob vytvoření hloubkové mapy pomocí této metody a s tím spojené problémy, které způsobují velkou komplikaci pro vytvoření relevantní hloubkové mapy.

Není možné použít jeden algoritmus pořizování snímků pro obě metody z důvodu diametrálně rozdílných principů. Přesto jsem se snažil o vytvoření maximálně univerzálních algoritmů, které umožňují u obou metod pořizování snímků ve dvou režimech, a to v režimu kalibrace a v režimu běžného snímání. Výpočet kalibrace kamery je zahrnut v algoritmech pro estimaci hloubky. Pokud se nenajdou již vypočtená kalibrační data, algoritmus se pokusí z dostupných dat kalibraci vypočítat. Pokud nejsou ani tato data k dispozici, u metody DFF se provede estimace hloubkové mapy bez přiřazené hloubkové mapy a výpočet metody DFD se neprovede vůbec.

V poslední části práce jsem popsal a ukázal výsledky metod na reálných snímcích. Ukázal jsem, že estimace hloubkové mapy je u metody DFF poměrně přesná a použitelná pro estimaci absolutní hloubkové mapy scény. Pro hloubkovou mapu jsem použil formát HSV z důvodu lepší čitelnosti hloubkové škály. Pro metodu DFD jsem

sestavil tabulku (tab. 4.4) naměřených hodnot v porovnání se skutečnými hodnotami. Jak lze vidět, relativní chyba metody se pro danou scénu pohybuje v rozmezí od 1.1 % do 13.0 %. Přesnost u této metody je podstatně nižší než u metody DFF. To může být způsobeno aditivní chybou vzniklou nedokonalou kalibrací kamery, příp. zaokrouhlováním. Hlavní výhodou metody DFD je velmi jednoduchý a rychlý výpočet a rychlá kalibrace oproti metodě DFF. Čas, po který trvá pořízení snímků u metody DFD je podstatně menší než u metody DFF. Velkou výhodou metody DFF je fakt, že může pracovat i bez kalibrace a je podstatně robustnější oproti metodě DFD. Pro praktické využití metod v praxi hodnotím metodu DFF jako optimální volbu. Při dnešních rychlých ostřících mechanismech lze dobu, po kterou se pořizují snímky podstatně zkrátit.

Při snímání objektů metodami DFF a DFD je potřeba brát v potaz řadu omezujících podmínek. Nejzákladnější z nich je, že měřený objekt nebo scéna musí obsahovat dostatečnou úroveň textury, jelikož obě metody pracují s měřením ostrosti. Dalším omezujícím faktorem je nutnost vhodného rovnoměrného osvětlení a také správné nastavení expoziční doby kamery. Metoda DFD je velmi náchylná na změnu struktury měřeného objektu, změnu parametrů kamery a také na změnu okolního osvětlení zejména mezi kalibrací a samotnou estimací vzdálenosti. Také je nutné u obou metod vždy najít správný rozsah měření, který závisí na ohniskové vzdálenosti, zaostření a nastavení clony.

Fokusovací metody nejsou příliš přesné, ale pro svou funkci nepotřebují přídavné snímače ani zdroje světla. Díky tomu je lze aplikovat všude, kde je k dispozici říditelné ostření. Například při implementaci do mobilního telefonu lze jednoduše během pár sekund rekonstruovat hloubku scény, příp. sešít all-in-focus snímek. Navíc lze díky jednomu objektivu snímat i velmi malé předměty, které by například s pasivní triangulací nebylo možné vůbec nasnímat.

Literatura

- [1] Bing-Zhong Jing and D. S. Yeung. Recovering depth from images using adaptive depth from focus. In *2012 International Conference on Machine Learning and Cybernetics*, volume 3, pages 1205–1211, 2012. doi:10.1109/ICMLC.2012.6359527.
- [2] 3d scanning. URL: https://en.wikipedia.org/wiki/3D_scanning.
- [3] Bernd Jahne, Horst Haussecker, and Peter Geissler. *Handbook of Computer Vision and Applications: Volume 1: From Images to Features*. Academic Press, Inc., USA, 1999.
- [4] Time of flight. URL: https://en.wikipedia.org/wiki/Time_of_flight.
- [5] D. Semwogerere and E. R. Weeks. Confocal microscopy. In *Encyclopedia of Biomaterials and Biomedical Engineering*, pages 1–10, 2005. doi:10.1081/E-EBBE-120024153.
- [6] D. K. Toomre, M. F. Langhorst, and M. W. Davidson. Introduction to spinning disk confocal microscopy. [online]. URL: <http://zeiss-campus.magnet.fsu.edu/articles/spinningdisk/introduction.html>.
- [7] R. Paschotta. Acousto-optic deflectors. *Encyclopedia of Laser Physics and Technology*, 2008, 2008.
- [8] Chromatic confocal technology. URL: <https://www.polytec.com/us/surface-metrology/technology/chromatic-confocal-technology>.
- [9] Sergio Aguirre Valencia and Ramon M. Rodriguez-Dagnino. Synthesizing stereo 3D views from focus cues in monoscopic 2D images. In Andrew J. Woods, John O. Merritt, Stephen A. Benton, and Mark T. Bolas, editors, *Stereoscopic Displays and Virtual Reality Systems X*, volume 5006, pages 377 – 388. International Society for Optics and Photonics, SPIE, 2003. doi:10.1117/12.474113.
- [10] J. B. Kulkarni and C. M. Sheelarani. Generation of depth map based on depth from focus: A survey. In *2015 International Conference on Computing Communication Control and Automation*, pages 716–720, 2015. doi:10.1109/ICCUBE.2015.146.
- [11] Ge Guo, Nan Zhang, Longshe Huo, and Wen Gao. 2d to 3d conversion based on edge defocus and segmentation. In *2008 IEEE International Conference on*

- Acoustics, Speech and Signal Processing*, pages 2181–2184, 2008. doi:10.1109/ICASSP.2008.4518076.
- [12] A. S. Malik, S. Shim, and T. Choi. Depth map estimation using a robust focus measure. In *2007 IEEE International Conference on Image Processing*, volume 6, pages VI – 564–VI – 567, 2007. doi:10.1109/ICIP.2007.4379647.
 - [13] H. Li and K. N. Ngan. Unsupervised segmentation of defocused video based on matting model. In *2006 International Conference on Image Processing*, pages 1825–1828, 2006. doi:10.1109/ICIP.2006.312601.
 - [14] X. Deng, X. Jiang, Q. Liu, and W. Wang. Automatic depth map estimation of monocular indoor environments. In *2008 International Conference on Multi-Media and Information Technology*, pages 646–649, 2008. doi:10.1109/MMIT.2008.14.
 - [15] Y. Huang, F. Cheng, and Y. Liang. Creating depth map from 2d scene classification. In *2008 3rd International Conference on Innovative Computing Information and Control*, pages 69–69, 2008. doi:10.1109/ICICIC.2008.205.
 - [16] Y. Chen, Yi-Chin Wu, Chih-Hung Liu, Wei-Chih Sun, and Y. Chen. Depth map generation based on depth from focus. In *2010 International Conference on Electronic Devices, Systems and Applications*, pages 59–63, 2010. doi:10.1109/ICEDSA.2010.5503103.
 - [17] Depth estimation using encoder-decoder networks and self-supervised learning. URL: <https://blog.goodaudience.com/depth-estimation-using-encoder-decoder-networks-and-self-supervised-learning-fd97>
 - [18] Chuan en Lin. Introduction to motion estimation with optical flow. [online]. URL: <https://nanonets.com/blog/optical-flow/>.
 - [19] A. Sharma, M. D. Ansari, and R. Kumar. A comparative study of edge detectors in digital image processing. In *2017 4th International Conference on Signal Processing, Computing and Control (ISPCC)*, pages 246–250, 2017. doi:10.1109/ISPCC.2017.8269683.
 - [20] Edge detectors. URL: <https://homepages.inf.ed.ac.uk/rbf/HIPR2/edgdetct.htm>.
 - [21] R. Fisher, S. Perkins, A. Walker, and E. Wolfart. Laplacian/laplacian of gaussian. [online]. URL: <https://homepages.inf.ed.ac.uk/rbf/HIPR2/log.htm>.


- [22] Kavita Bala. Computer vision. URL: http://www.cs.cornell.edu/courses/cs4670/2016sp/lectures/lec21_panoramas_web.pdf.
- [23] Y. Xiong and S. A. Shafer. Depth from focusing and defocusing. In *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pages 68–73, 1993. doi:10.1109/CVPR.1993.340977.
- [24] Djemel Ziou and Francois Deschenes. Depth from defocus estimation in spatial domain. *Computer Vision and Image Understanding*, 81(2):143 – 165, 2001. URL: <http://www.sciencedirect.com/science/article/pii/S1077314200908993>, doi:<https://doi.org/10.1006/cviu.2000.0899>.
- [25] Depth of field. URL: https://en.wikipedia.org/wiki/Depth_of_field.
- [26] G. Surya and M. Subbarao. Depth from defocus by changing camera aperture: a spatial domain approach. In *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pages 61–67, 1993. doi:10.1109/CVPR.1993.340978.
- [27] A.N. Rajagopalan and S. Chaudhuri. Space-variant approaches to recovery of depth from defocused images. *Computer Vision and Image Understanding*, 68(3):309 – 329, 1997. URL: <http://www.sciencedirect.com/science/article/pii/S1077314297905348>, doi:<https://doi.org/10.1006/cviu.1997.0534>.
- [28] Q. Zhang and Y. Gong. A novel technique of image-based camera calibration in depth-from-defocus. In *2008 First International Conference on Intelligent Networks and Intelligent Systems*, pages 483–486, 2008. doi:10.1109/ICINIS.2008.95.
- [29] S. Yang S. Y. Yoon and J. Hyun. Simple refractometry using optical path separation via multiple pinholes. *Micro and Nano Systems Letters*, 5, 2017. URL: <https://mns1-journal.springeropen.com/articles/10.1186/s40486-017-0043-0>, doi:<https://doi.org/10.1186/s40486-017-0043-0>.
- [30] Konfokální snímače vzdálenosti, polohy a tloušťky pro transparentní materiály. URL: <https://www.micro-epsilon.cz/displacement-position-sensors/confocal-sensor/>.
- [31] Zeiss lsm 980 with airyscan 2. URL: <https://www.zeiss.com/microscopy/int/products/confocal-microscopes/confocal-microscope-with-multiplex-mode-lsm-980-airyscan-2.html#downloads>.

- [32] Corporate overview. URL: <https://www.keyence.com/about-us/corporate/>.
- [33] Kontrolér s integrovaným zdrojem světla vzorkovací frekvencí až do 70kHz. URL: https://www.micro-epsilon.cz/displacement-position-sensors/confocal-sensor/controller_IFC2471HS/.
- [34] Cl-3000 series confocal displacement sensor. URL: https://www.keyence.com/mykeyence/?ptn=001&ad_local=lpindexprcl-3000.
- [35] Cytation c10. URL: <https://www.biotek.com/products/cell-imaging-microscopy-confocal-imaging-reader/cytation-c10/#1>.
- [36] alm865. Focus stacking and 3d effect, 2014. URL: <https://www.magiclantern.fm/forum/index.php?topic=11886.0>.


Seznam symbolů, veličin a zkratek

DFF	Metoda kontrolovaného fokusování – Depth From Focus
DFD	Metoda rozfokusování – Depth From Defocus
RI	Refrakční index
1D	Jednorozměrný prostor
2D	Dvourozměrný prostor
3D	Trojrozměrný prostor
CCD	Typ senzoru kamery – Charge-coupled device
RGB	Barevný model
HSI	Barevný model
LoG	Hranový detektor – Laplacian of Gaussian
USB	Sériová sběrnice – Universal Serial Bus


A Výsledky estimované hloubkové mapy




Obr. A.1: Hloubková mapa maticek a škoubků.



Obr. A.2: Hloubková mapa klíče.



Obr. A.3: Hloubková mapa malého úchytu.



Obr. A.4: Hloubková mapa stroužku česneku.

B Obsah přiloženého CD

Na přiloženém CD jsou zdrojové kódy metod DFD a DFF. U každé metody jsou přiloženy i testovací data. Software byl testován ve verzi Matlab R2020a.

/	kořenový adresář přiloženého CD
├── Text	
│ ├── diplomova_prace-Jan_Machacek.pdf	Diplomová práce
├── DFD	metoda DFD
│ ├── measuring.....	naměřená a kalibrační data
│ ├── DFD_estimator.m.....	estimace vzdálenosti
│ ├── DFD_imageTaker.m.....	pořizování snímků
├── DFF.....	metoda DFF
│ ├── calibData.....	kalibrační data
│ ├── imgStack.....	nasnímané vzorky
│ ├── DFF_estimator.....	estimace hloubkové mapy
│ ├── DFF_imageTaker.....	pořizování snímků