VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA STROJNÍHO INŽENÝRSTVÍ
FACULTY OF MECHANICAL ENGINEERING

ÚSTAV MATEMATIKY
INSTITUTE OF MATHEMATICS

MĚŘENÍ PRŮMĚRU EXTRUDOVANÉHO VLÁKNA S VYUŽITÍM NUMERICKÝCH METOD ZPRACOVÁNÍ OBRAZOVÉ INFORMACE

NUMERICAL METHOD OF IMAGE PROCESSING FOR EXTRUDED FIBER DIAMETER MEASUREMENT

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE Bc. Jiří Vostal
AUTHOR

VEDOUCÍ PRÁCE doc. Ing. Pavel Štarha, Ph.D.
SUPERVISOR

BRNO 2018

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ FAKULTA STROJNÍHO INŽENÝRSTVÍ

Zadání diplomové práce

Ústav:	Ústav matematiky
Student:	**Bc. Jiří Vostal**
Studijní program:	Aplikované vědy v inženýrství
Studijní obor:	Matematické inženýrství
Vedoucí práce:	**doc. Ing. Pavel Štarha, Ph.D.**
Akademický rok:	2017/18

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

Měření průměru extrudovaného vlákna s využitím numerických metod zpracování obrazové informace

Stručná charakteristika problematiky úkolu:

V praktických úlohách se často setkáváme s měřením geometrických vlastností sledovaného objektu pomocí různých měřících přístrojů, např. mikrometrů. Alternativou k těmto přístrojům může být analýza snímku sledovaného objektu. Výhodou tohoto postupu je možnost měření více geometrických parametrů objektu v jednom kroku a také možnost uchování zdrojových informací.

Cíle diplomové práce:

1. Popsat numerické metody zpracování obrazu použité pro měření průměru extrudovaného vlákna.
2. Vyvinout aplikační software.
3. Zpracovat naměřené data a ověřit metodu z hlediska opakovatelnosti a reprodukovatelnosti.

Seznam doporučené literatury:

KLÍMA, Miloš, Martin BERNAS, Jiří HOZMAN a Petr DVOŘÁK. Zpracování obrazové informace. Praha: Vydavatelství ČVUT, 1996.

PRATT, William K. Digital Image Processing (Third Edition) PIKS Inside [online]. 3rd ed. New York: Wiley-Interscience, 2001 [cit. 2014-08-07]. ISBN 04-712-2132-5. Dostupné z: http://www.csupomona.edu/~kding/materials/Digital Image Processing - Third Edition - William K.Pratt.pdf

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2017/18

V Brně, dne

L. S.

prof. RNDr. Josef Šlapal, CSc. ředitel ústavu	doc. Ing. Jaroslav Katolický, Ph.D. děkan fakulty

Abstrakt
Tato práce se zabývá problémem měření průměru extrudovaných vláken. Za tímto účelem byl navržen postup využívající numerických metod zpracování obrazové informace. Použité jednotlivé metody jsou popsány v teoretické části. Navržený postup byl zpracován do podoby jednoúčelové aplikace a zhodnocen z hlediska opakovatelnosti a reprodukovatelnosti.

Summary
This work is focused on extruded fiber diameter measurement problem. For this purpose a procedure has been proposed. This procedure makes use of numerical methods for image processing, which are described in theoretical part of work. The proposed procedure has been processed into single-purpose software and in the final part is assessed its repeatability and reproducibility.

Klíčová slova
zpracování obrazu, měření průměru vlákna, pascal, opakovatelnost, reprodukovatelnost.

Keywords
digital image processing, fiber diameter measurement, pascal, repeatability, reproducibility.

VOSTAL, J.*Měření průměru extrudovaného vlákna s využitím numerických metod zpracování obrazové informace.* Brno: Vysoké učení technické v Brně, Fakulta strojního inženýrství, 2018. 51 s. Vedoucí diplomové práce doc. Ing. Pavel Štarha, Ph.D..

Prohlašuji, že jsem pracoval samostatně pod vedením svého vedoucího doc. Ing. Pavla Štarhy, Ph.D. a s použitím zdrojů uvedených v seznamu literatury.

Bc. Jiří Vostal

Obsah

Úvod **3**

1 Fyzický aparát **4**

2 Teoretický základ **6**
2.1 Barva . . . 6
2.2 Metrický prostor a metrika . . . 7
2.3 Obrazová matice . . . 8
2.4 Fourierova transformace . . . 9
2.5 Konvoluce . . . 9
2.6 Lineární filtry . . . 11
2.7 Nelineární filtry . . . 12
2.8 Histogram . . . 12
2.9 Automatická expanze . . . 13
2.10 Segmentace obrazu . . . 14
2.11 Detekce hran . . . 14
2.12 Metoda nejmenších čtverců . . . 15
2.13 Odhad průměru vlákna . . . 17
2.14 Vzdálenost dvou úseček v rovině . . . 18

3 Počítačová implementace **19**
3.1 Základní popis aplikace . . . 19
3.1.1 Prerekvizity . . . 19
3.1.2 Popis uživatelského rozhraní . . . 19
3.2 Algoritmus měření průměru vlákna . . . 22
3.2.1 Převod na stupně šedé . . . 23
3.2.2 Filtr typu dolní propust 1 . . . 23
3.2.3 Gradientní filtr . . . 25
3.2.4 Autoexpanze 1 . . . 26
3.2.5 Filtr typu dolní propust 2 . . . 26
3.2.6 Autoexpanze 2 . . . 28
3.2.7 Prahování . . . 28
3.2.8 Identifikace hran . . . 28
3.2.9 Užití metody nejmenších čtverců . . . 29
3.2.10 Určení vzdálenosti . . . 30
3.3 Nastavení parametrů . . . 31
3.3.1 Optimální hodnoty parametrů LPF1 a LPF2 . . . 31
3.3.2 Optimální prahová hodnota . . . 33

4 Opakovatelnost a reprodukovatelnost **35**
4.1 Opakovatelnost . . . 36
4.2 R&R studie . . . 38

Závěr **42**

Seznam použitých zkratek a symbolů **44**

Seznam příloh **45**

Úvod

Tato práce se zabývá problémem měření průměru extrudovaných vláken. Jedná se o dutá vlákna z čistého polypropylenu. Tato vlákna mají charakter membrány, tzn. mají mikrotrhlinky, které propouští částice do určité velikosti. Používají se pro lékařské účely, například na filtraci krve. Průměr těchto vláken se pohybuje kolem $0,5\,\mathrm{mm}$. Na jejich geometrickou přesnost jsou kladeny vysoké nároky, tím je myšleno především dodržení stanoveného limitu průměru po celé délce. Výstupní kontrola výroby vláken je prováděna metodou, při které se dané vlákno (jehož délka je cca $10\,\mathrm{cm}$) měří na třech různých, náhodně vybraných místech. Měření průměru je požadováno s přesností na mikrometry. V současnosti se zmíněná vlákna měří laserovým mikrometrem. Cílem této práce je navrhnout alternativní způsob měření a ověřit jeho spolehlivost.

Navržený postup využívá numerických metod analýzy obrazu. Analyzuje se snímek vlákna pořízený optickým mikroskopem s vhodně sestaveným osvětlením pozorovaného vlákna tak, aby nedocházelo k odleskům na povrchu vlákna. Výhodou měření pomocí numerických metod zpracování obrazové informace je uchování zdrojových informací a vizuální kontrola nad měřením.

1. Fyzický aparát

Nejdříve si stručně popíšeme náčiní, které budeme používat k pořizování detailních snímků vláken. Náš aparát se skládá z optického mikroskopu, držáku na vlákna, osvětlení a optického snímače. Podrobněji se budeme věnovat pouze osvětlení.

Vlákno promítáme na optický snímač středovým promítáním. Pro zjednodušení je aproximujeme promítáním rovnoběžným. Chyba, které se tím dopustíme, je zanedbatelná. Více viz odstavec 2.13.

Vlákno budeme v tomto odstavci pro jednoduchost považovat za rotační válec, který bude umístěn ve vodorovné poloze pod objektivem mikroskopu. Dále mějme vodorovnou rovinu ϱ, ve které leží osa vlákna. Mikroskop bude zaostřen právě na tuto rovinu. Osvětlit budeme chtít ty části povrchu vlákna, které se s rovinou ϱ protínají. Na obrázku 1.1 jsou červeně zvýrazněny. Právě tyto přímky se na pořízený snímek promítnou jako okraje průmětu vlákna. Naším úkolem bude změřit jejich vzdálenost (která je odhadem průměru vlákna).

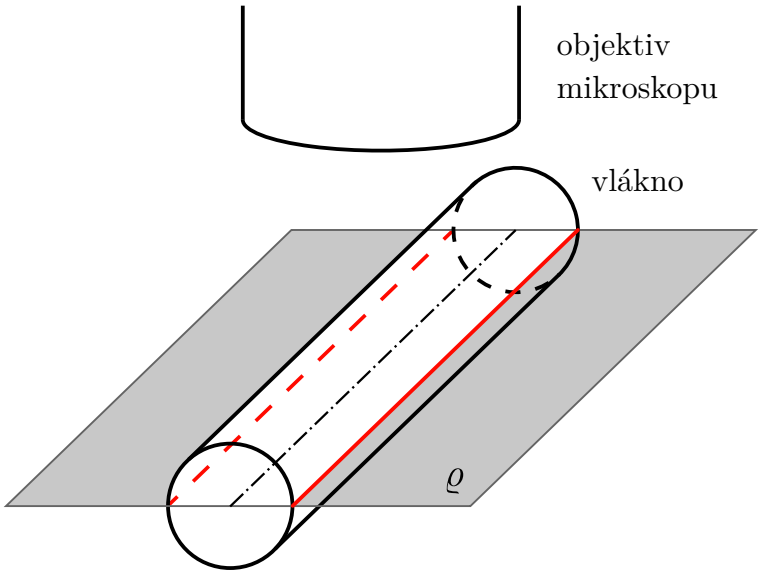

Obrázek 1.1: Vlákno umístěné pod mikroskopem.

Osvětlení seshora ani ze stran není vhodné, protože by to způsobilo nežádoucí odlesky a ty by nám komplikovaly analýzu snímku.

Vlákno tedy osvětlíme pod takovým úhlem, že odlesky od jeho povrchu půjdou mimo objektiv. To můžeme realizovat například pomocí čtyř LED diod umístěných tak, jak ukazují obrázky 1.2 a 1.3.

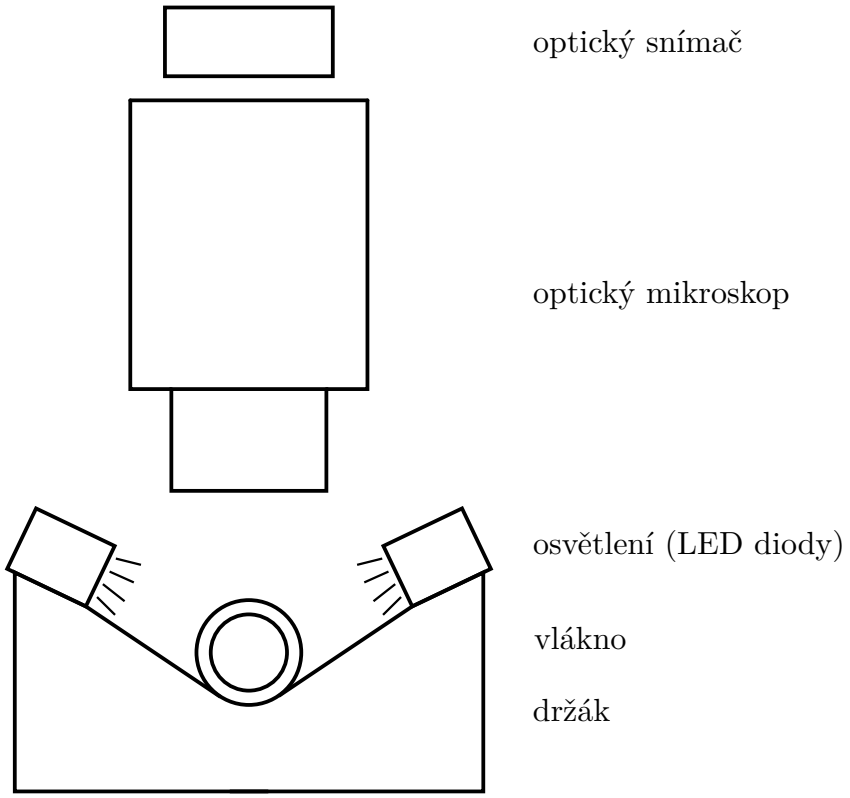

Obrázek 1.2: Schéma celého aparátu.

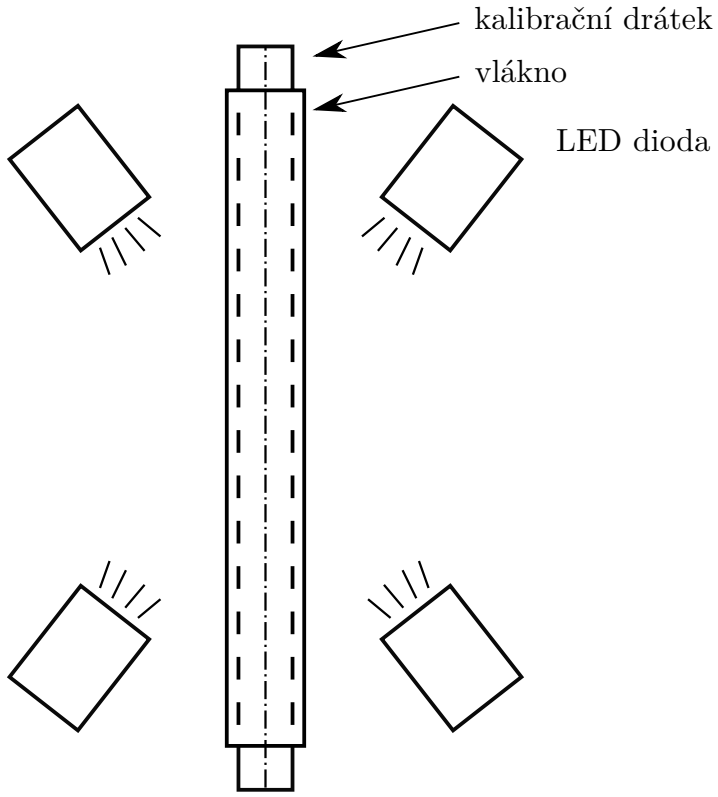

Obrázek 1.3: Půdorys osvětlení vlákna.

2. Teoretický základ

2.1. Barva

Pojem barva objektu můžeme chápat jako elektromagnetické záření odražené daným objektem.

V lidském oku jsou celkem čtyři typy buněk citlivých na světlo. Máme tři typy čípků citlivých na různé vlnové délky. Jedny jsou modrocitlivé, druhé jsou převážně zelenocitlivé a třetí typ je citlivý na vlnové délky odpovídající červenému světlu a trochu i na některé frekvence v modré části spektra. Posledním typem světlocitlivých buněk jsou tyčinky, ty nám zajišťují černobílé vidění v šeru (jsou velmi citlivé na světlo).

Lidské oko dokáže zaznamenat část spektra odpovídající vlnovým délkám přibližně od 400 nm do 700 nm. Viz obrázek 2.1.

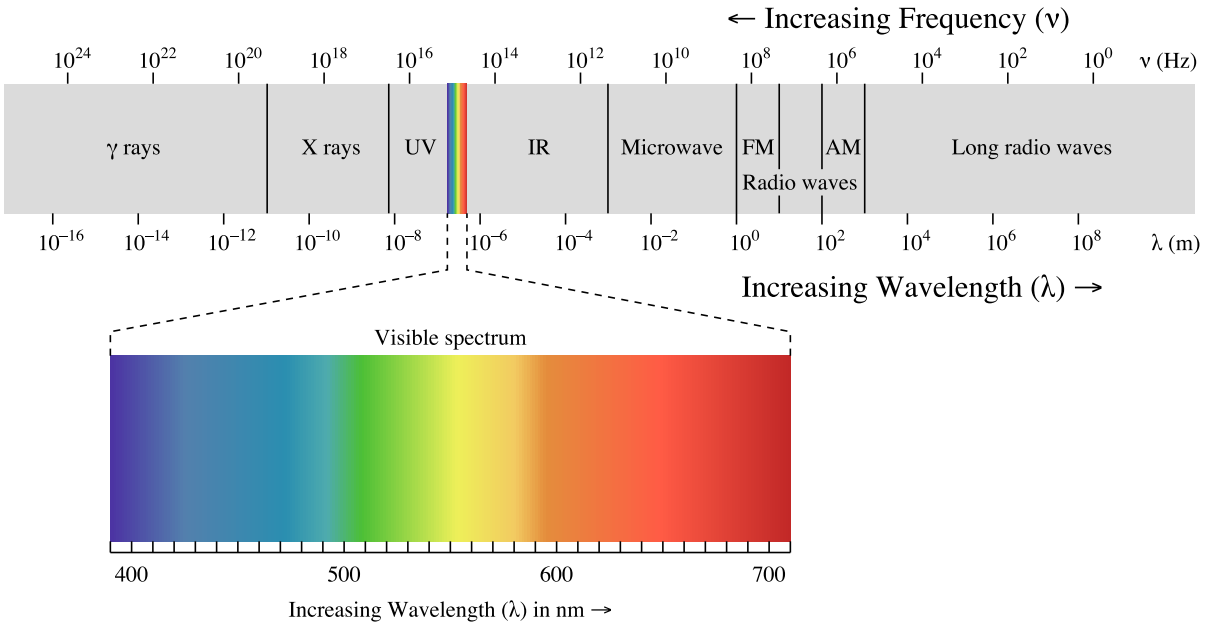

Obrázek 2.1: Znázornění elektromagnetického spektra. Jeho viditelná část je zvýrazněna. Tento obrázek byl převzat z Wikipedie.
Dostupné z: https://en.wikipedia.org/wiki/Light#/media/File:EM_spectrum.svg

Rozlišujeme dvě základní skupiny barevných systémů: aditivní a subtraktivní.

Aditivní model si můžete představit tak, že sedíte v temné místnosti a třemi barevnými reflektory svítíte na zeď. Jeden reflektor svítí červeně, jeden zeleně a jeden modře. Plochu, která není osvětlená, vnímáme jako černou barvu. Průnik dvou základních barev vnímáme jako další barvu a průnik všech tří základních barev vnímáme jako barvu bílou.

Výskyt: světlo, systém RGB

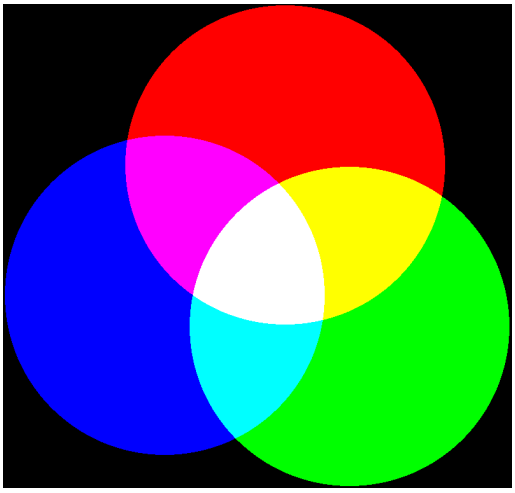

R – red, červená

G – green, zelená

B – blue, modrá

Obrázek 2.2: Ilustrace aditivního systému barev.

Subtraktivní (odčítací) model popisuje princip míchání barev hmotných látek (např. inkoustu nebo temperových barev). Začneme s bílým podkladem. Ten odráží všechny vlnové délky světla, proto ho vnímáme jako bílý. Hmotné barvy filtrují intervaly vlnových délek. Dva základní filtry mají průnik intervalů vlnových délek a ten vnímáme jako další barvu. Průnik všech tří základních filtrů nepropouští žádnou vlnovou délku, což vnímáme jako černou barvu.

Výskyt: inkoust, CMYK systém tiskáren (K - černá)

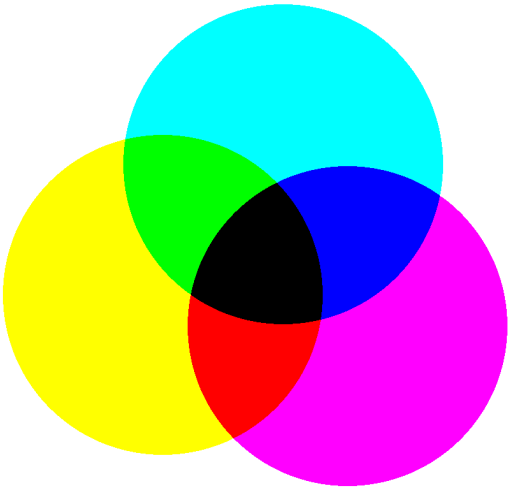

C – cyan, azurová

M – magenta, purpurová

Y – yellow, žlutá

Obrázek 2.3: Ilustrace subtraktivního systému barev.

2.2. Metrický prostor a metrika

Definice 1: Nechť X je libovolná množina a ϱ je zobrazení $\varrho : X \to \langle 0, \infty)$ takové, že pro libovolné $x, y, z \in X$ platí:

$$\begin{array}{lrcl} \text{a)} & \varrho(x,y) & = & 0 \Leftrightarrow x = y \\ \text{b)} & \varrho(x,y) & = & \varrho(y,x) \\ \text{c)} & \varrho(x,z) & \leq & \varrho(x,y) + \varrho(y,z) \end{array}$$

potom dvojici (X,ϱ) nazýváme *metrický prostor* a zobrazení ϱ nazýváme *metrika*.

2.3. Obrazová matice

Pod pojmem digitalizace (v obrazové technice) rozumíme převod spojité dvourozměrné obrazové informace na dvourozměrnou matici obrazových bodů. Obrazové matice mohou mít obecně libovolnou geometrii.

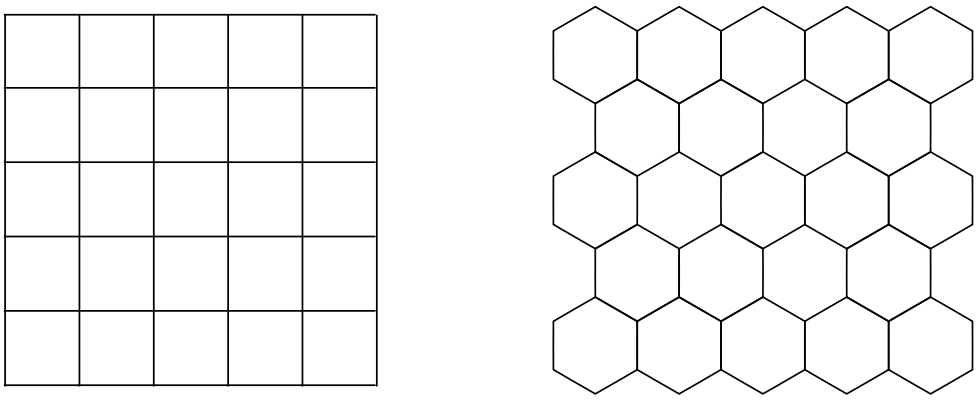

Obrázek 2.4: Pravoúhlá a hexagonální obrazová matice.

Nejčastěji se používá pravoúhlá geometrie. Jednoduše se pak definují funkce pro práci s obrazem. Obraz budeme tedy chápat jako funkci dvou proměnných, jejíž definiční obor i obor hodnot je diskrétní.

Budeme pracovat s obrazy, které používají 8 bitů na každou složku, tzn. 256 úrovní intenzity. Pro systém barev RGB to znamená, že každá ze tří základních složek může nabývat hodnoty od 0 do 255. Máme tedy k dispozici 256^3 různých odstínů barev.

Definice 2 (Okolí pixelu): Nechť $a_{i,j}$ je hodnota pixelu (obrazového bodu) na pozici $[i, j]$ v obrazové matici A. Okolím pixelu $a_{i,j}$ budeme rozumět množinu takových pixelů $a_{k,l}$, pro které platí, že jejich vzdálenost od daného pixelu je menší nebo rovna nějaké předem dané konstantě $\varepsilon > 0$, tj.:

$$\varrho(a_{i,j}, a_{k,l}) \leq \varepsilon,$$

kde ϱ je libovolná metrika. Okolí pixelu $a_{i,j}$ budeme značit $P(a_{i,j})$.

V závislosti na zvolené metrice dostaneme různé tvary okolí. Použijeme-li manhattanskou metriku

$$|i - k| + |j - l| \leq \varepsilon,$$

dostaneme čtvercové okolí a použijeme-li euklidovskou metriku

$$\sqrt{(i - k)^2 + (j - l)^2} \leq \varepsilon,$$

dostaneme okolí ve tvaru digitálního kruhu.

Obecně může mít okolí zcela libovolný tvar, nejčastěji se však používá čtvercové, a to z důvodu jednoduchosti implementace. Volba tvaru okolí záleží na konkrétní řešené úloze.

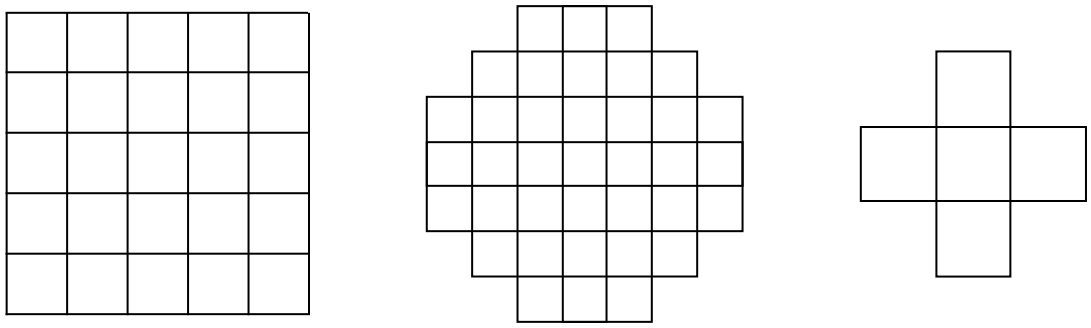

Obrázek 2.5: Různé tvary okolí zpracovávaného obrazového bodu; čtvercové (vlevo), digitální kruh (uprostřed), kříž (vpravo).

2.4. Fourierova transformace

Definice 3: Komplexní funkci $\mathcal{A}$ dvou reálných proměnných ω_x a ω_y nazveme komplexní nebo reálnou *Fourierovou transformací* funkce $A(x, y)$ právě tehdy když

$$\mathcal{A}(\omega_x, \omega_y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} A(x, y) \exp\left(-i(\omega_x x + \omega_y y)\right) \mathrm{d}x\mathrm{d}y \tag{2.1}$$

kde ω_x a ω_y jsou prostorové frekvence a i je imaginární jednotka, tj. $i = \sqrt{-1}$.

Inverzní transformace je tvaru:

$$A(x, y) = \frac{1}{4\pi^2} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \mathcal{A}(\omega_x, \omega_y) \exp\left(i(\omega_x x + \omega_y y)\right) \mathrm{d}\omega_x \mathrm{d}\omega_y$$

Postačující podmínkou pro existenci Fourierovy transformace je absolutní integrovatelnost dané funkce, tj.:

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} |A(x, y)| \mathrm{d}x\mathrm{d}y < \infty$$

V dalším budeme Fourierovu transformaci funkce $A(x, y)$ zapisovat takto:

$$\mathcal{F}(A(x, y)) = \mathcal{A}(\omega_x, \omega_y)$$

nebo pouze

$$\mathcal{F}(A) = \mathcal{A}$$

a inverzní transformaci pak tímto způsobem:

$$\mathcal{F}^{-1}(\mathcal{A}) = A.$$

2.5. Konvoluce

Konvoluce patří k základním nástrojům při práci se signály. Nejdříve si uvedeme základní definici. V této práci budeme operaci konvoluce značit symbolem $\otimes$.

Definice 4: Nechť jsou definovány dvě reálné funkce $C(x)$ a $A(x)$ jedné reálné proměnné. Jejich konvolucí nazveme reálnou funkci definovanou jako integrál:

$$C(x) \otimes A(x) = \int_{-\infty}^{\infty} C(u)A(x-u)\mathrm{d}u.$$

Nyní definujme konvoluci pro funkce dvou reálných proměnných.

Definice 5: Nechť jsou definovány dvě reálné funkce $C(x,y)$ a $A(x,y)$ dvou reálných proměnných. Jejich konvolucí nazveme reálnou funkci dvou proměnných definovanou jako integrál:

$$C(x,y) \otimes A(x,y) = \int_{-\infty}^{\infty}\int_{-\infty}^{\infty} C(u,v)A(x-u,y-v)\mathrm{d}u\mathrm{d}v.$$

Funkce $C(x,y)$ a $A(x,y)$ mohou být například obrazové funkce.

Konvoluce má následující vlastnosti:

1.	$C \otimes A = A \otimes C$	komutativita
2.	$k_1C \otimes k_2A = k_1k_2(C \otimes A)$	násobení konstantou
3.	$C \otimes (A_1 + A_2) = C \otimes A_1 + C \otimes A_2$	distributivita vůči sčítání
4.	$C_1 \otimes (C_2 \otimes C_3) = (C_1 \otimes C_2) \otimes C_3$	asociativita

Podrobnější informace o konvoluci můžete nalézt například v publikaci [4] nebo [6].

Věta 1 (Konvoluční teorém): Nechť jsou definovány dvě reálné funkce $C(x,y)$ a $A(x,y)$ dvou reálných proměnných. Pak dvourozměrná Fourierova transformace aplikovaná na konvoluci funkcí C a A se rovná součinu transformací těch funkcí. Tedy:

$$\mathcal{F}(A \otimes C) = \mathcal{F}(A) \cdot \mathcal{F}(C).$$

Po aplikování inverzní Fourierovy transformace dostaneme rovnost ve tvaru:

$$A \otimes C = \mathcal{F}^{-1}(\mathcal{F}(A) \cdot \mathcal{F}(C)).$$

Diskrétní konvoluce

Zavedeme následující označení:
$a_{i,j}$ ... pixely zdrojového obrazu A,
$b_{i,j}$ ... pixely výsledného obrazu B,
$c_{k,l}$ ... prvky jádra konvoluce - matice C.

Máme tedy:

$$B = A \otimes C$$
$$b_{i,j} = \sum_k \sum_l c_{k,l} a_{i+k,j+l} \tag{2.2}$$

$b_{i,j}$ je lineární kombinace prvků v okolí $a_{i,j}$, koeficienty $c_{k,l}$ jsou z konvolučního jádra C. Obvyklým tvarem jádra je čtverec, obecně však může mít zcela libovolný tvar.

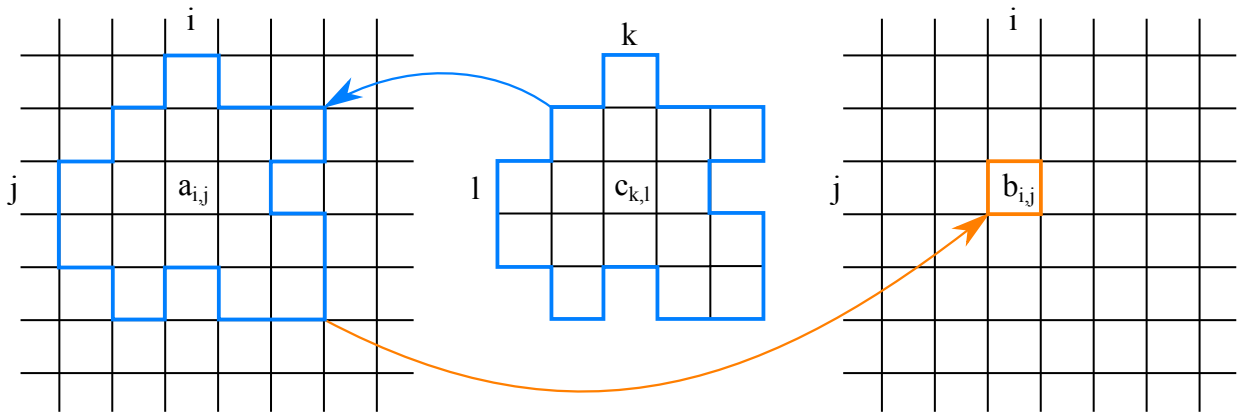

Obrázek 2.6: Znázornění diskrétní konvoluce.

2.6. Lineární filtry

Lineární filtry jsou silný nástroj pro zpracování obrazové informace.

Filtr typu dolní propust (low-pass filter, LPF)

Tento filtr propouští nízké prostorové frekvence, potlačuje tedy aditivní šum, protože ten je reprezentován složkou na nejvyšších prostorových frekvencích.

Nejjednodušší formou tohoto filtru je tzv. klouzavý průměr. Ten však propouští některé vysoké frekvence. Nejvhodnějším konvolučním jádrem pro LPF je gaussovské jádro, tzn. funkční hodnoty jsou odvozeny od Gaussovy funkce dvou proměnných. Její ilustraci můžete vidět na obrázku 2.7.

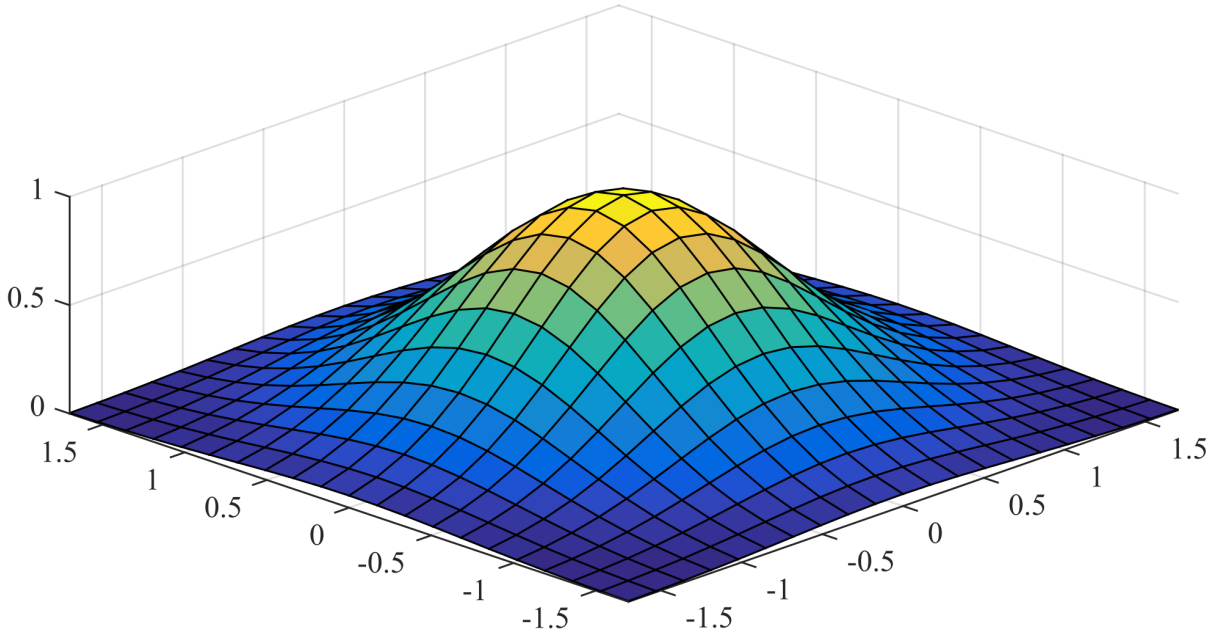

Obrázek 2.7: Toto znázornění dvourozměrné Gaussovy funkce bylo vytvořeno v programu MATLAB.

Filtr typu horní propust (high-pass filter, HPF)

Filtr typu horní propust, jak napovídá jeho název, propouští vysoké a potlačuje nízké prostorové frekvence. Toho je možné využít pro detekci hran v obrazu. Nevýhodou HPF je, že právě na prostorových frekvencích, které propouští, se vyskytuje šum. Přítomnost šumu negativně ovlivňuje kvalitu výsledného obrazu (tj. detekovaných hran).

Doostřovací filtr

Doostřovací filtr zvyšuje úroveň vysokých prostorových frekvencí, to se v obrazu projeví jako zvýraznění hran objektů. Znamená to však, že zesiluje i aditivní šum.

2.7. Nelineární filtry

Nelineární filtry opět pracují s okolím zpracovávaného obrazového bodu. Výsledná hodnota se určí pomocí nelineárních funkcí. Dle zvoleného typu funkce rozlišujeme následující typy filtrů: mediánový filtr, maximum, minimum a další.

Zpracovávaný obrazový bod si označme $a_{i,j}$ a nechť $P(a_{i,j})$ je jeho okolí.

Mediánový filtr

Jako soubor hodnot pro výpočet mediánu vezmeme hodnoty pixelů v $P(a_{i,j})$. Vypočtený medián nahradí daný pixel. Od průměrování se liší zejména tím, že lépe zachovává hrany objektů.

Tento filtr můžeme upravit tím způsobem, že původní hodnotu nahradíme mediánem pouze v případě, kdy se medián bude od původní hodnoty lišit alespoň o nějakou předem zvolenou konstantu.

Využití: filtrace impulsního šumu.

Maximum

V okolí $P(a_{i,j})$ najdeme pixel s maximální hodnotou. Ta nahradí daný pixel.
Efekt: eroze tmavých oblastí, dilatace světlých oblastí.

Minimum

V okolí $P(a_{i,j})$ najdeme pixel s minimální hodnotou. Ta nahradí daný pixel.
Efekt: dilatace tmavých oblastí, eroze světlých oblastí.

2.8. Histogram

Histogram je soustava obdélníků v kartézské souřadné soustavě, jejichž základny jsou třídy a výšky jsou četnosti tříd (absolutní, relativní, kumulativní atd.). Na histogramu lze snadno vidět, jak daný soubor dat využívá svůj dynamický rozsah.

V případě obrazu jsou třídy histogramu přímo jednotlivé úrovně jasu. Pokud máme obraz s více kanály (například systém barev RGB), můžeme histogram sestavit pro každý

barevný kanál zvlášť. Pro histogram celkového jasu se pak používá například aritmetický průměr všech složek.

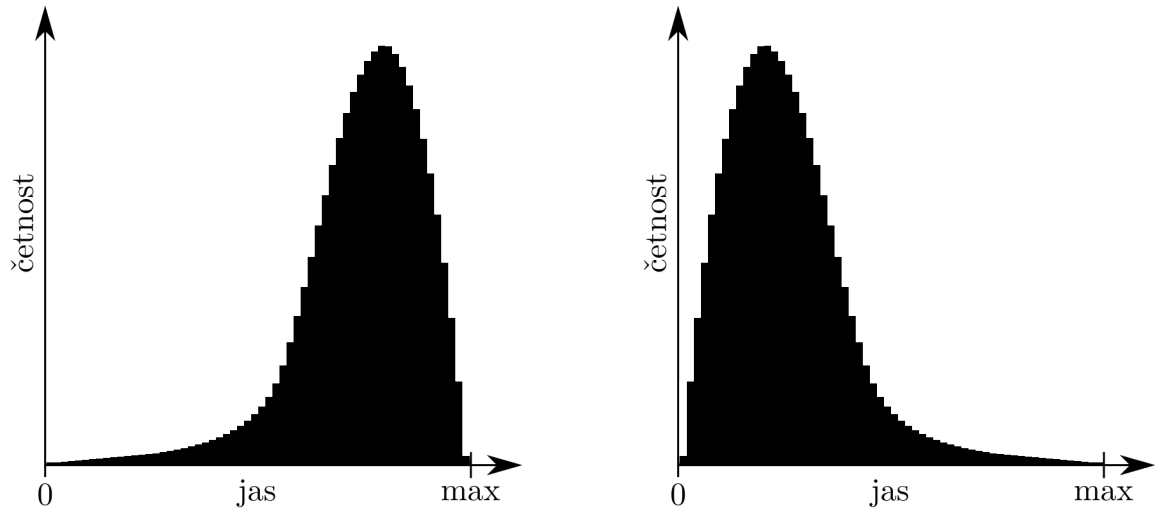

Obrázek 2.8: Histogram převážně světlého obrazu (vlevo) a histogram převážně tmavého obrazu (vpravo).

2.9. Automatická expanze

Stává se, že obrazová data využívají jenom část rozsahu hodnot, kterých mohou nabývat. Autoexpanzí „roztáhneme“ data na celý obor hodnot, pro nejběžnější obrazy (tj. 8bitové) je to rozsah 0–255.

Zavedeme následující označení:
A … původní obrazová matice o rozměrech $m \times n$ pixelů,
B … výsledná obrazová matice o rozměrech $m \times n$ pixelů,
a_{ij} … hodnota pixelu na pozici $[i, j]$ v A,
b_{ij} … hodnota pixelu na pozici $[i, j]$ v B,
$min = min\{a_{ij} \in A;\ i = 1, \ldots, m;\ j = 1, \ldots, n\}$,
$max = max\{a_{ij} \in A;\ i = 1, \ldots, m;\ j = 1, \ldots, n\}$.
MAX … maximální možná hodnota pixelu (pro nejběžnější obrazy je $MAX = 255$).

Automatickou expanzi můžeme realizovat například následující lineární transformací:

$$b_{ij} = \frac{a_{ij} - min}{max - min} \cdot MAX \tag{2.3}$$

Může se však stát, že v obraze bude několik velice světlých nebo velice tmavých pixelů. V takovém případě zůstane část možného rozsahu hodnot téměř nevyužitá. Abychom se tomuto vyhnuli, můžeme určitému počtu pixelů povolit přetečení horní meze nebo podtečení dolní meze. Následně jim přiřadíme mezní hodnotu.

Po automatické expanzi bude výsledný obraz lépe využívat obor hodnot a díky lepšímu kontrastu lidské oko postřehne jemnější detaily.

2.10. Segmentace obrazu

Segmentace obrazu je proces, který vyčleňuje důležité či charakteristické oblasti obrazu s určitou stejnorodostí vzhledem k určité vlastnosti, případně rozděluje obraz na oblasti s určitou stejnorodostí. Tuto stejnorodost není vždy snadné specifikovat.

Prahování

Prahování je jednou z nejdůležitějších a nejpoužívanějších metod segmentace obrazu. V tomto odstavci se budeme věnovat především jednoúrovňovému prahování.

Mějme obraz A s pixely a_{ij}. Nechť je A v odstínech šedé a nechť je reprezentován tmavými objekty na světlém pozadí a to tak, že úrovně šedi obrazových bodů objektů a pozadí tvoří dvě velké skupiny, v histogramu představované dvěma dominantními vrcholy či maximy. Jedním z obvyklých postupů pro vyčlenění objektu z pozadí je zvolení jisté prahové hodnoty - prahu T. Pak jakýkoli obrazový bod, pro který platí $a_{ij} < T$, můžeme nazývat bodem objektu jedné skupiny, jinak ho nazýváme bodem pozadí.

Příklad můžete vidět na obrázku 2.9. Jedná se o ukázku prahování jasu, prahovat však můžeme i barvu nebo nasycení (saturaci).

Obecnějším případem je víceúrovňové prahování, kde se neomezujeme pouze na jednu prahovou hodnotu.

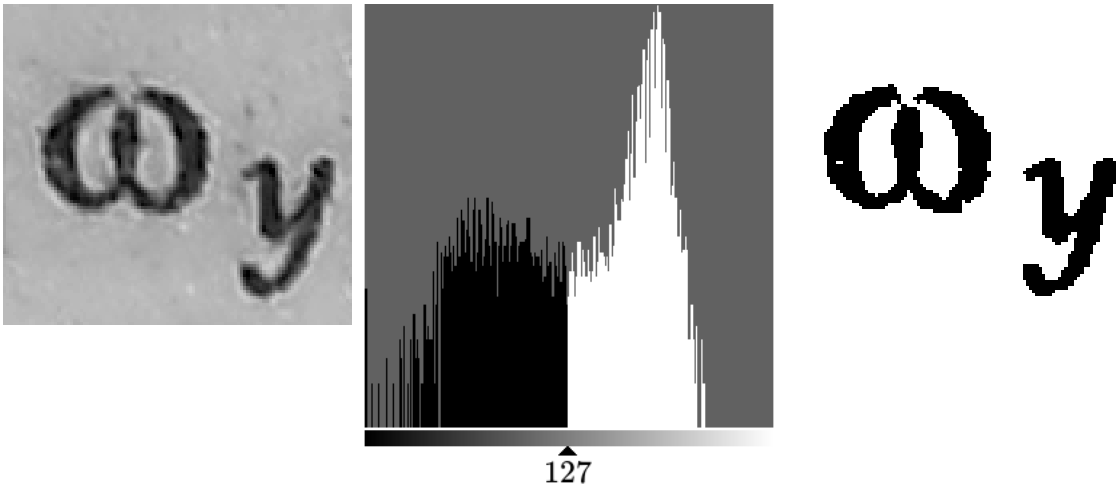

Obrázek 2.9: Znázornění prahování. Původní obrázek je vlevo. Uprostřed je histogram původního obrázku. Jeho svislá osa je pro lepší názornost logaritmická. Černá část histogramu znázorňuje pixely, které budou černé. Bílá část histogramu znázorňuje pixely, které budou bílé. Vpravo je výsledný obrázek.

2.11. Detekce hran

Podmínkou pro úspěšnou detekci hranice objektu je výrazná hranice objektu, tj. skoková změna hodnoty pixelu.

Detekce hran pomocí filtru typu horní propust

Použitelné pouze na obrazu s velmi nízkým obsahem aditivního šumu.

Příklady konvolučních jader, pomocí kterých můžeme tento typ filtru realizovat:

$$\begin{pmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{pmatrix}, \begin{pmatrix} 1 & 0 & 1 \\ 0 & -4 & 0 \\ 1 & 0 & 1 \end{pmatrix}$$

Gradientní filtr

Gradient, který známe z analýzy spojitých funkcí, nahradíme normou z vektoru diferencí:

$$b_{i,j} = \|(a_{i+1,j} - a_{i,j}, a_{i,j+1} - a_{i,j})\|,$$

kde $a_{i,j}$ jsou pixely původního obrazu A a $b_{i,j}$ jsou pixely výsledného obrazu B.

Dále v této práci budeme používat normu vycházející z euklidovské:

$$b_{i,j} := \frac{1}{\sqrt{2}}\sqrt{(a_{i+1,j} - a_{i,j})^2 + (a_{i,j+1} - a_{i,j})^2} \tag{2.4}$$

Konstanta $\frac{1}{\sqrt{2}}$ je tam proto, abychom výsledek transformovali zpět na interval, ze kterého jsou hodnoty $a_{i,j}$. Pokud $a_{i,j} \in \langle 0, 255 \rangle$, pak i výsledek $b_{i,j} \in \langle 0, 255 \rangle$.

Výsledný obraz B bude tmavý tam, kde měl původní obraz A téměř konstantní plochy. Hranice budou světlé. Gradientní filtr je na aditivní šum méně citlivý než metoda s filtrem typu horní propust.

2.12. Metoda nejmenších čtverců

Tento odstavec byl z velké čísti převzat ze skript [3], str. 54–56.

Metoda nejmenších čtverců (dále jen MNČ) označuje postup pro přibližné řešení přeurčených soustav rovnic. Princip této metody je založen na minimalizaci kvadrátů[1] reziduí. Rezidua jsou rozdíly mezi pozorováními a modelem:

$$r = \sum_{i=1}^{m} r_i = \sum_{i=1}^{m} (y_i - model_i),$$

kde m je počet pozorování, $model_i$ je hodnota zvoleného modelu v i-tém čase, y_i je hodnota naměřená v i-tém čase.

Model volíme v podobě lineární kombinace n bázových funkcí (přičemž $n \leq m$):

$$\begin{aligned} model &= a_1\varphi_1(t) + a_2\varphi_2(t) + \cdots + a_n\varphi_n(t) \\ model_i &= a_1\varphi_1(t_i) + a_2\varphi_2(t_i) + \cdots + a_n\varphi_n(t_i) = \sum_{j=1}^{n} a_j\varphi_j(t_i) \end{aligned}$$

a_j jsou hledané parametry modelu.

Návrhová matice $\mathbf{X}$ modelu:

$$\mathbf{X} = \begin{pmatrix} \varphi_1(t_1) & \varphi_2(t_1) & \cdots & \varphi_n(t_1) \\ \varphi_1(t_2) & \varphi_2(t_2) & \cdots & \varphi_n(t_2) \\ \vdots & \vdots & & \vdots \\ \varphi_1(t_m) & \varphi_2(t_m) & \cdots & \varphi_n(t_m) \end{pmatrix}$$

[1] Odtud pochází výraz „nejmenší čtverce“.

Budeme tedy řešit úlohu:

$$\begin{aligned} \|\mathbf{r}\|^2 &:= \sum_{i=1}^{m} (r_i)^2 \to \min \\ &\equiv \sum_{i=1}^{m} (y_i - model_i)^2 \to \min \\ &\equiv \sum_{i=1}^{m} \left(y_i - \sum_{j=1}^{n} a_j \varphi_j(t_i) \right)^2 \to \min . \end{aligned} \tag{2.5}$$

Řešení této minimalizační úlohy musí splňovat nutnou podmínku pro extrém, tj. derivace podle každé proměnné se musí rovnat nule. Proměnné jsou v našem případě hledané parametry. Podmínka pro extrém bude tedy ve tvaru soustavy n rovnic o n neznámých:

$$\frac{\partial \|\mathbf{r}\|^2}{\partial a_k} = \frac{\partial}{\partial a_k} \sum_{i=1}^{m} \left(y_i - \sum_{j=1}^{n} a_j \varphi_j(t_i) \right)^2 = 0, \qquad k = 1, 2, \ldots, n.$$

Zderivováním dostaneme:

$$2 \sum_{i=1}^{m} \left(y_i - \sum_{j=1}^{n} a_j \varphi_j(t_i) \right) (-\varphi_k(t_i)) = 0, \qquad k = 1, 2, \ldots, n.$$

Upravíme:

$$\sum_{j=1}^{n} \left(\sum_{i=1}^{m} \varphi_k(t_i) \varphi_j(t_i) \right) a_j = \sum_{i=1}^{m} y_i \varphi_k(t_i), \qquad k = 1, 2, \ldots, n.$$

Rozepsaný tvar:

$$\begin{pmatrix} \sum_{i=1}^{m} \varphi_1(t_i)\varphi_1(t_i) & \sum_{i=1}^{m} \varphi_1(t_i)\varphi_2(t_i) & \cdots & \sum_{i=1}^{m} \varphi_1(t_i)\varphi_n(t_i) \\ \sum_{i=1}^{m} \varphi_2(t_i)\varphi_1(t_i) & \sum_{i=1}^{m} \varphi_2(t_i)\varphi_2(t_i) & \cdots & \sum_{i=1}^{m} \varphi_2(t_i)\varphi_n(t_i) \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{i=1}^{m} \varphi_n(t_i)\varphi_1(t_i) & \sum_{i=1}^{m} \varphi_n(t_i)\varphi_2(t_i) & \cdots & \sum_{i=1}^{m} \varphi_n(t_i)\varphi_n(t_i) \end{pmatrix} \cdot \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^{m} y_i \varphi_1(t_i) \\ \sum_{i=1}^{m} y_i \varphi_2(t_i) \\ \vdots \\ \sum_{i=1}^{m} y_i \varphi_n(t_i) \end{pmatrix}$$

Maticově možno zapsat jako:

$$\mathbf{X}^T \mathbf{X} \mathbf{a} = \mathbf{X}^T \mathbf{y} \tag{2.6}$$

Soustavě 2.6 se obecně říká *normální soustava rovnic.*
Jsou-li sloupce matice $\mathbf{X}$ lineárně nezávislé, pak je matice $\mathbf{X}^T\mathbf{X}$ pozitivně definitní a řešení normální soustavy 2.6 je jediným řešením úlohy 2.5.

MNČ budeme využívat pro prokládání dat křivkami, v našem případě to budou přímky, tj. polynomy prvního stupně.

Prokládání dat přímkou

Řekněme, že jsme provedli m pozorování. Máme tedy hodnoty

$$y_i = y(x_i), \quad i = 1,\ 2,\ \cdots,\ m,$$

kde y je funkce, pomocí které chceme aproximovat, a x_i jsou navzájem různé hodnoty proměnné x (například čas). Z obecné rovnice přímky $y = a + bx$ sestavíme dvě bázové funkce $\varphi_1(x) = x^0 = 1,\ \varphi_2(x) = x^1$. Soustava rovnic pro neznámé a a b je potom tvaru:

$$\begin{pmatrix} \sum_{i=1}^{m} 1 \cdot 1 & \sum_{i=1}^{m} 1 \cdot x_i \\ \sum_{i=1}^{m} x_i \cdot 1 & \sum_{i=1}^{m} x_i \cdot x_i \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^{m} 1 \cdot y_i \\ \sum_{i=1}^{m} x_i \cdot y_i \end{pmatrix}. \tag{2.7}$$

Odtud dostaneme koeficienty a, b hledané přímky $y = a + bx$.

Hledané koeficienty můžeme explicitně vyjádřit například následujícím způsobem:

$$\begin{aligned} b &= \frac{m \cdot \sum_{i=1}^{m} x_i \cdot y_i - \sum_{i=1}^{m} x_i \cdot \sum_{i=1}^{m} y_i}{m \cdot \sum_{i=1}^{m} x_i^2 - \left(\sum_{i=1}^{m} x_i\right)^2}, \\ a &= \frac{\sum_{i=1}^{m} y_i - b \cdot \sum_{i=1}^{m} x_i}{m}. \end{aligned} \tag{2.8}$$

2.13. Odhad průměru vlákna

V případě naší optické soustavy se jedná o středové promítání, ale vzhledem k celkové geometrii systému, průměru vlákna a zornému úhlu objektivu lze středové promítání aproximovat rovnoběžným. Chyba, které se touto aproximací dopustíme, se při dané geometrii pohybuje řádově v setinách mikrometru. Naším cílem je měřit s přesností na mikrometry, takže tuto chybu můžeme zanedbat.

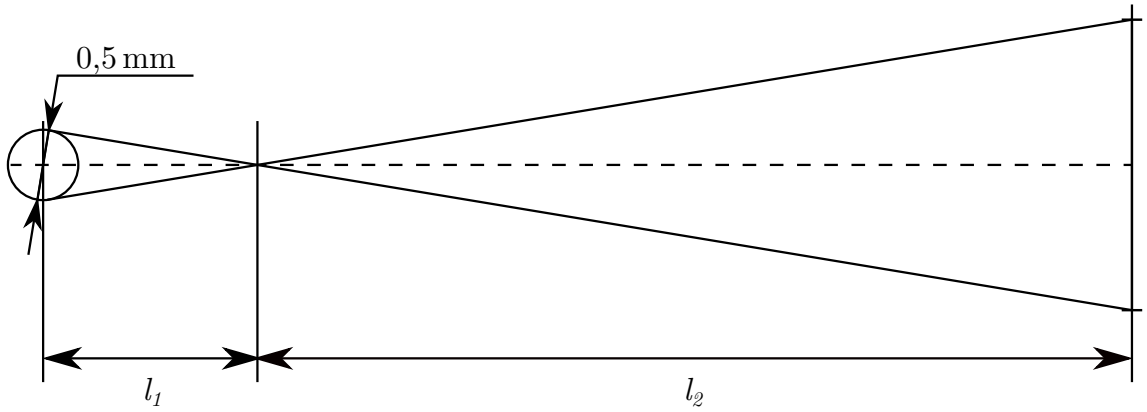

Obrázek 2.10: Zjednodušený model středového promítání při použití mikroskopického objektivu se zvětšením 4×. Při pracovní vzdálenosti $l_2 = 160\,\mathrm{mm}$ nám vyšlo $l_1 = 40\,\mathrm{mm}$. Vlákno je oproti ostatním okótovaným vzdálenostem zvětšeno 27×.

2.14. Vzdálenost dvou úseček v rovině

V praxi se dvě rovnoběžné úsečky nemusí zobrazit jako rovnoběžné. To se může stát například u středového promítání. Jiným důvodem pro nerovnoběžnost pozorovaných úseček mohou být nedokonalé geometrické vlastnosti analyzovaného objektu. Vlákna, jejichž průměr budeme měřit, obecně nemají konstantní průměr. Často jsou lokálně mírně kuželovitá.

Při měření průměru vlákna se tedy zaměříme na určení „průměrné vzdálenosti“ úseček, které se nám na snímku vlákna jeví jako hrany vlákna. Zmíněné úsečky si pracovně označíme jako $\overline{p}$ a $\overline{q}$. Budeme přitom předpokládat, že jsou souměrné podle osy úhlu, který svírají nebo k tomu mají velice blízko.

Vzdálenost dvou úseček budeme v této práci určovat podle následujícího postupu:

1. Máme úsečky $\overline{p}$ a $\overline{q}$, které mohou a nemusí být rovnoběžné.
   Dále mějme normované vektory $\overrightarrow{u}$ a $\overrightarrow{v}$ tak, že $\overrightarrow{u} \perp \overline{p}$ a $\overrightarrow{v} \perp \overline{q}$.
2. Vektor $\overrightarrow{w}$ získáme jako součet vektorů $\overrightarrow{u}$ a $\overrightarrow{v}$.
3. Střed úsečky $\overline{p}$ označíme jako bod A.
4. Bodem A proložíme přímku r ve směru vektoru $\overrightarrow{w}$.
5. Průsečík přímky r a úsečky $\overline{q}$ označíme jako bod B.
6. Vzdálenost bodů A a B budeme považovat za vzdálenost úseček $\overline{p}$ a $\overline{q}$.

Jako důsledek těchto kroků má vektor $\overrightarrow{s} \perp r$ stejný směr jako osa úhlu, který svírají úsečky $\overline{p}$ a $\overline{q}$. Celý postup je ilustrován na obrázku 2.11.

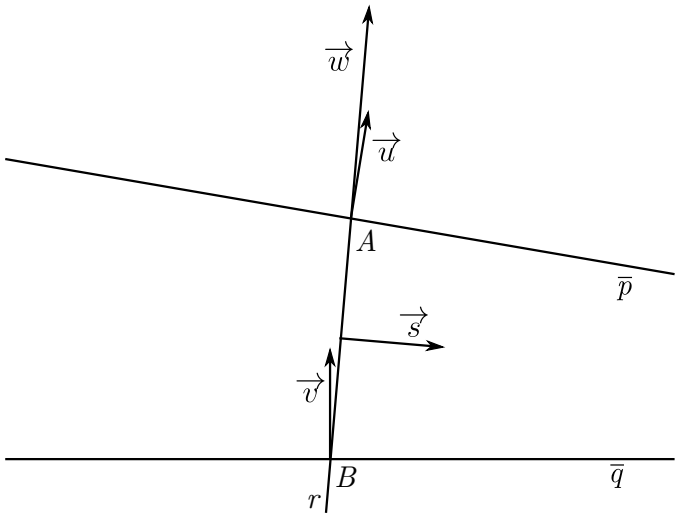

Obrázek 2.11: Nerovnoběžné úsečky.

3. Počítačová implementace

Pro tvorbu softwaru by použit jazyk pascal a vývojové prostředí Lazarus. Lazarus existuje ve verzi pro linux i pro Windows. Zvolil jsem verzi pro Windows zejména proto, že je to nejrozšířenější operační systém.

Tato kapitola je členěna na tři části. První část má za úkol seznámit uživatele s rozhraním programu. Ve druhé části jsou podrobně popsány jednotlivé kroky algoritmu. Třetí část se zabývá problémem nejlepšího nastavení parametrů.

3.1. Základní popis aplikace

3.1.1. Prerekvizity

Nutné podmínky úspěšného zpracování snímku

- Snímky ve formátu BMP (Windows bitmap)
- Výška snímku: 100 až 1600 pixelů
- Šířka snímku: 100 až 1600 pixelů
- Horní „hrana“ vlákna musí procházet mezi středem horního okraje obrazu a středem obrazu
- Dolní „hrana“ vlákna musí procházet mezi středem dolního okraje obrazu a středem obrazu

Soubor MEMO.ini

Ve stejné složce jako soubor .exe se nachází soubor MEMO.ini. Jsou v něm uloženy hodnoty parametrů. Program se při spuštění pokusí ty hodnoty načíst. Nezdaří-li se to (například proto, že soubor MEMO.ini není přítomen), program použije vestavěné výchozí hodnoty.

Při ukončení programu se aktuální hodnoty parametrů (včetně adresářové cesty) uloží do souboru MEMO.ini. Pokud soubor neexistuje, automaticky se vytvoří.

3.1.2. Popis uživatelského rozhraní

Hlavní okno

Hlavní okno programu můžete vidět na obrázku 3.1. Jednotlivé komponenty jsou očíslovány. V následující části budou podrobně popsány jejich funkce.

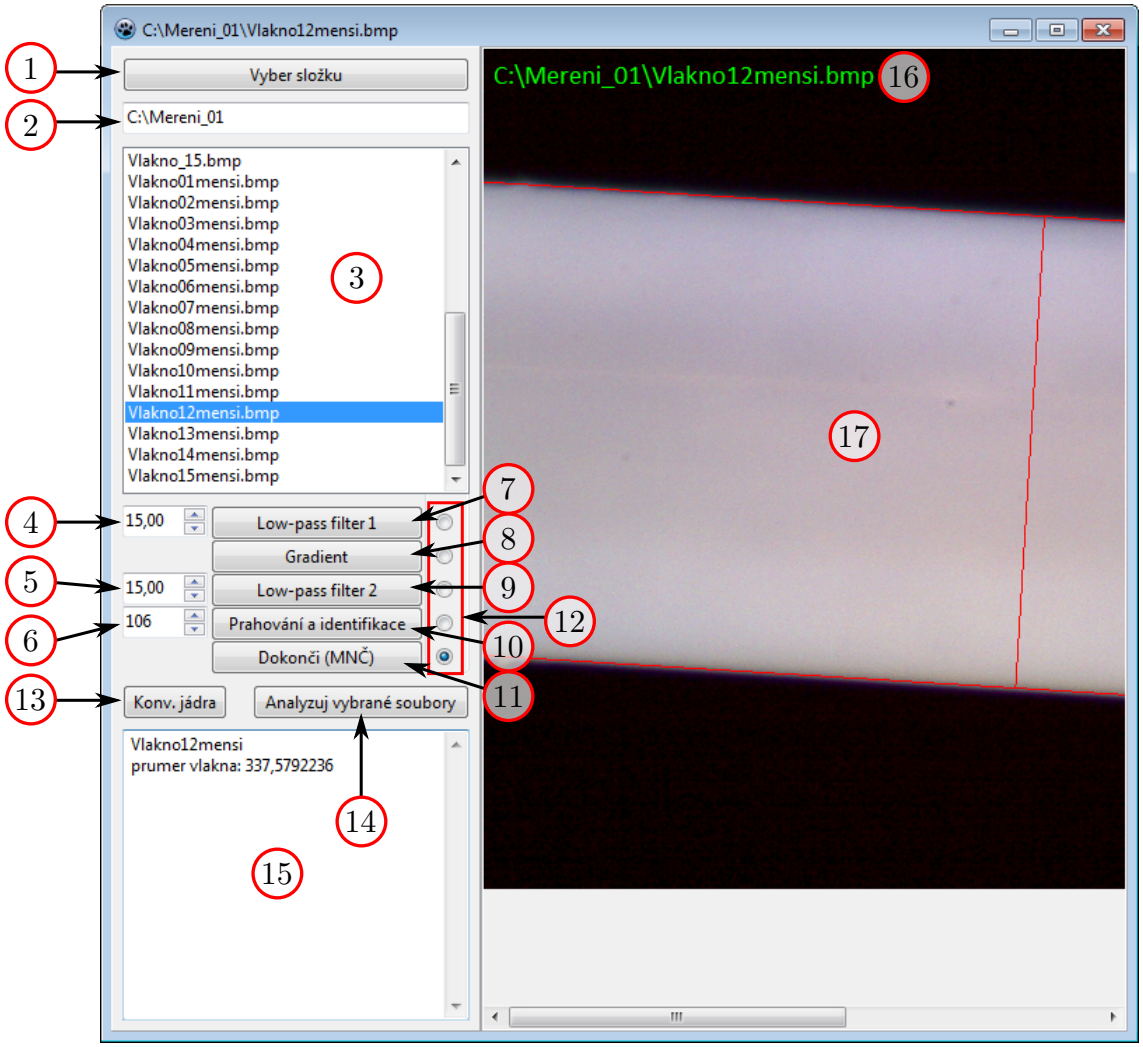

Obrázek 3.1: Hlavní okno programu s očíslovanými komponentami.

1) Zobrazí okno pro výběr složky. Vyberte složku, ve které máte uloženy snímky k analýze.

2) Řádek zobrazující název vybrané složky včetně celé cesty k ní. Nelze editovat.

3) Seznam všech souborů typu BMP, které se nachází ve vybrané složce. Slouží pro výběr konkrétních snímků k analýze. Pomocí kláves Ctrl nebo Shift je možné vybrat více snímků. Mnohonásobný výběr lze provést i stiskem a tažením myši.

4) Zde se nastavuje parametr pro první filtr typu dolní propust. Ovlivňuje míru rozmazání. Čím vyšší hodnota, tím větší rozmazání. Doporučená hodnota je 15.

5) Zde se nastavuje parametr pro druhý filtr typu dolní propust. Ovlivňuje míru rozmazání. Čím vyšší hodnota, tím větší rozmazání. Doporučená hodnota je 15.

6) Nastavení hodnoty prahu. Přípustné hodnoty jsou celá čísla z intervalu $\langle 0, 255 \rangle$. Doporučená hodnota je 106.

Poznámka: Hodnoty v komponentách 4, 5 a 6 lze pohodlně měnit kolečkem myši. Kurzor myši však musí být v oblasti s čísly, ne na „šipečkách“ v pravé části komponenty.

7) Se snímkem, který je označen v seznamu, bude proveden první krok algoritmu. Jedná se o převod na stupně šedi a filtr typu dolní propust. Výsledek se zobrazí vpravo. Je-li v seznamu označen více než jeden snímek, nestane se nic.

8) Na výsledek předchozího kroku algoritmu aplikuje gradientní filtr následovaný automatickou expanzí. Výsledek se zobrazí vpravo.

9) S výsledkem předchozího kroku algoritmu provede třetí krok. Nejdříve bude aplikován filtr typu dolní propust, poté automatická expanze. Výsledek se zobrazí vpravo.

10) S výsledkem předchozího kroku algoritmu provede nejdříve prahování, pak identifikaci objektu horní hrany a dolní hrany. Výsledek se zobrazí vpravo.

11) S výsledkem předchozího kroku algoritmu provede závěrečnou operaci, tj. identifikovanými hranami se proloží přímky pomocí MNČ a spočítá se jejich vzdálenost (což je hledaný průměr vlákna). V textové oblasti (komponenta č. 15) se zobrazí výsledky či chybová hlášení. Vpravo se zobrazí původní snímek s červeně vyznačenými „hranami“ a úsečkou, na které byl naměřen průměr.

Poznámka: Opakovaným klikáním na kterékoli z tlačítek 7 až 11 se změny nebudou kumulovat, ale opakovat.

12) Přepíná, který mezivýsledek je zobrazen v pravé části okna.

13) Zobrazí okno s náhledem a možností nastavení konvolučních jader, viz obrázek 3.2.

14) Na vybraných snímcích provede celý algoritmus s aktuálními hodnotami parametrů. V textové oblasti (komponenta č. 15) se zobrazí výsledky či chybová hlášení. Vpravo se zobrazí výsledek posledního kroku na snímku, který byl analyzován jako poslední.

15) Výpis výsledků a chybových hlášení. Naměřený průměr je udáván v pixelech. Obsahem je text, který lze označit (i přepsat) a zkopírovat do schránky za účelem dalšího použití.

16) Název právě zobrazeného snímku včetně celé jeho adresářové cesty. Pokud bylo v seznamu souborů právě vybráno více snímků, zobrazuje počet vybraných snímků.

17) Plocha pro zobrazení snímků.

Okno konvolučních jader

Změnou parametrů vlevo se příslušné jádro automaticky přepočítá.

Stiskem na tlačítko OK se uloží aktuální hodnoty parametrů a toto okno se zavře. Když bude okno zavřeno pomocí křížku v pravém horním rohu okna, provedené změny se neuloží.

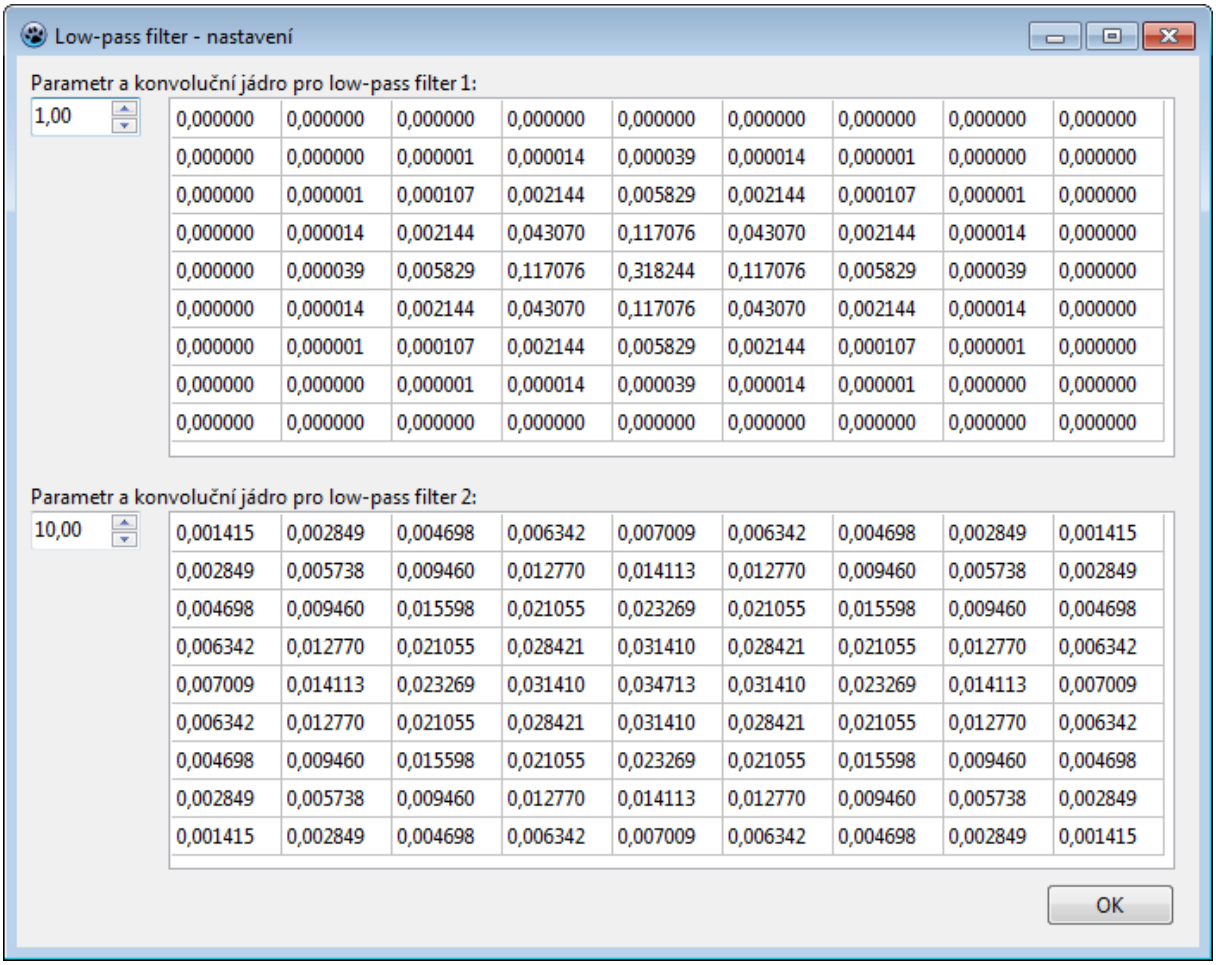

Obrázek 3.2: Okno pro náhled a nastavení konvolučních jader. Editovat je možné pouze parametry vlevo.

3.2. Algoritmus měření průměru vlákna

Celkový proces měření průměru vlákna lze rozdělit do následujících deseti kroků:

1. převod na stupně šedé
2. filtr typu dolní propust 1
3. gradientní filtr
4. autoexpanze 1
5. filtr typu dolní propust 2
6. autoexpanze 2
7. prahování
8. identifikace hran
9. metoda nejmenších čtverců

10. určení vzdálenosti

Následuje podrobný popis jednotlivých kroků tohoto algoritmu. Pro tvorbu histogramů v této kapitole byl použit GNU Image Manipulation Program (GIMP).

3.2.1. Převod na stupně šedé

Snímek získaný z kamery má tři barevné složky (kanály) – RGB. My však budeme pracovat pouze se zelenou složkou. Červená a modrá složka má v našem případě horší obrazové vlastnosti. Jde především o barevnou vadu optické soustavy. Různé vlnové délky světla se při přechodu do jiného optického prostředí lámou pod různými úhly. Důsledkem toho je, že na rozhraní bílého objektu a tmavého pozadí vzniká fialový nádech. Fialová je směsí červené a modré. To znamená, že hrany objektu v červené a modré složce nejsou ostré. Použitím pouze zelené složky tedy potlačíme vliv barevné vady objektivu a získáme výraznější přechod mezi světlým vláknem a tmavým pozadím.

Navíc, počet pixelů, které snímají intenzitu zelené barvy je 50 % (červených je 25 % a modrých také 25 %). Z tohoto důvodu máme v zelené složce dvojnásobné množství informací než ve složce červené nebo modré.

Zůstane nám tedy jeden kanál, který budeme chápat jako obraz ve stupních šedé.

Výsledek této operace můžete vidět na obrázku 3.3.

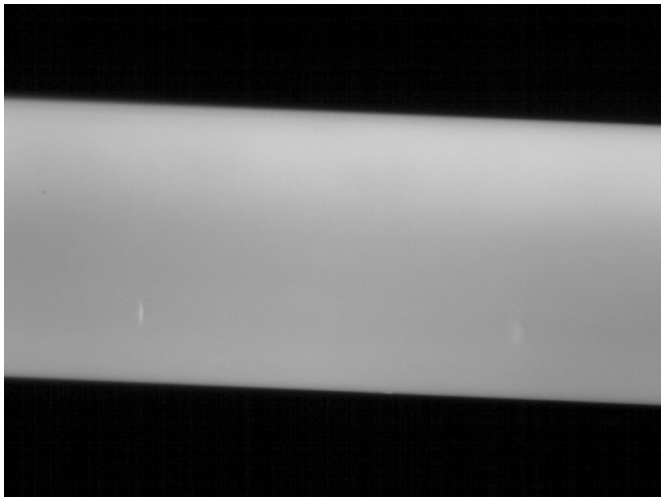

Obrázek 3.3: Výsledek převodu na stupně šedé.

3.2.2. Filtr typu dolní propust 1

Vzhledem tomu, že gradientní filtr je citlivý na aditivní šum, je vhodné ho potlačit filtrem typu dolní propust. K tomu využijeme diskrétní konvoluci. Při tvorbě konvolučního jádra vycházíme z dvourozměrné Gaussovy funkce, tj.:

$$f(x, y) = \exp\left(-\frac{x^2 + y^2}{c}\right),$$

kde $c > 0$ je volitelná konstanta, v odstavci 3.3. ji budeme značit jako LPF1 (příp. LPF2 v případě filtru typu dolní propust 2).

Volba konstanty c má přímý vliv na tvar Gaussovy funkce. Se změnou tvaru Gaussovy funkce se změní i úroveň potlačení vysokých prostorových frekvencí. Vizuálně se to projevuje rozostřením obrazu. Čím vyšší hodnota konstanty c, tím více bude obraz rozostřen.

Mějme tabulku C (můžeme ji považovat i za matici), která nám bude představovat konvoluční jádro. Nechť jsou její řádky i sloupce číslovány od $-n$ do n. Zvolíme konstantu $c > 0$ a tabulku vyplníme podle následujícího předpisu:

$$C(i,j) = \frac{1}{s} \cdot \exp\left(-\frac{i^2+j^2}{c}\right), \text{ kde } s = \sum_{k=-n}^{n} \sum_{l=-n}^{n} \exp\left(-\frac{k^2+l^2}{c}\right).$$

Můžeme si všimnout, že díky koeficientu s bude součet všech prvků v tabulce roven jedné.

Tabulka 1: Jádro konvoluce pro $c = 15$.

$j \backslash i$	-4	-3	-2	-1	0	1	2	3	4
-4	0,0031	0,0049	0,0069	0,0084	0,0090	0,0084	0,0069	0,0049	0,0031
-3	0,0049	0,0079	0,0110	0,0134	0,0143	0,0134	0,0110	0,0079	0,0049
-2	0,0069	0,0110	0,0153	0,0187	0,0200	0,0187	0,0153	0,0110	0,0069
-1	0,0084	0,0134	0,0187	0,0228	0,0244	0,0228	0,0187	0,0134	0,0084
0	0,0090	0,0143	0,0200	0,0244	0,0261	0,0244	0,0200	0,0143	0,0090
-1	0,0084	0,0134	0,0187	0,0228	0,0244	0,0228	0,0187	0,0134	0,0084
-2	0,0069	0,0110	0,0153	0,0187	0,0200	0,0187	0,0153	0,0110	0,0069
-3	0,0049	0,0079	0,0110	0,0134	0,0143	0,0134	0,0110	0,0079	0,0049
-4	0,0031	0,0049	0,0069	0,0084	0,0090	0,0084	0,0069	0,0049	0,0031

Dále už zbývá jen provést diskrétní konvoluci, budeme se tedy řídit vzorcem 2.2.

V následující části kódu je matice `orig` zelenou složkou původního obrazu. Výstupem je matice `LPF1_result`.

```
// počátek přípravy jádra konvoluce - matice "core"
sum := 0;
for i:=-4 to 4 do
    for j:=-4 to 4 do begin
        core[i, j] := exp((-i*i - j*j)/FSpEd_LPF1.Value);
        sum := sum + core[i, j];
    end;
// ještě je třeba znormovat
for i:=-4 to 4 do
    for j:=-4 to 4 do
        core[i, j] := core[i, j]/sum;
// jádro připraveno
for j:=4 to (Image1.Picture.Bitmap.Height - 5) do
    for i:=4 to (Image1.Picture.Bitmap.Width - 5) do begin
        VGr:=0;
        for l:=-4 to 4 do
            for k:=-4 to 4 do begin
                VGr := VGr + core[k, l]*orig[i + k, j + l];
            end;
        LPF1_result[i, j] := VGr;
    end;
```

Výsledek této operace je na obrázku 3.4. Možná si všimnete, že se vlevo a vpravo nachází černý okraj, který tam předtím nebyl. Ve skutečnosti je i nahoře a dole. Je to důsledek toho, že konvoluci s naším jádrem neaplikujeme na krajní pixely. V krajních bodech totiž dochází k okrajovému efektu. Tyto krajní pixely dodefinujeme hodnotou nula. V dalším zpracování tento černý okraj snímku ničemu nevadí (kromě toho, že si budeme muset dát pozor na meze cyklů u gradientního filtru, viz následující odstavec).

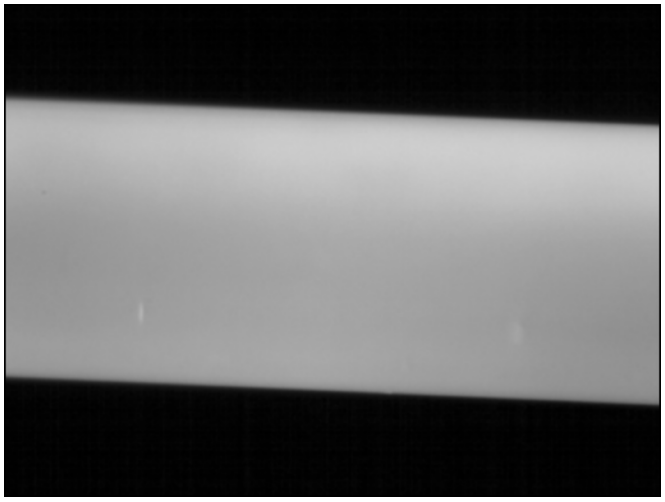

Obrázek 3.4: Výsledek prvního filtru typu dolní propust.

3.2.3. Gradientní filtr

Účelem této operace je nalezení hran.
Použijeme normu definovanou vztahem 2.4:

$$grad_{i,j} := \sqrt{(A_{i+1,j} - A_{i,j})^2 + (A_{i,j+1} - A_{i,j})^2} \cdot \frac{1}{\sqrt{2}},$$

kde A je vstupní obrazová matice a $grad$ je výstupní obrazová matice.

V pascalu realizujeme takto:

```
for j:=4 to (Image1.Picture.Bitmap.Height - 6) do
    for i:=4 to (Image1.Picture.Bitmap.Width - 6) do
    begin
        Grad := Sqrt(Sqr(LPF1_result[i+1,j] - LPF1_result[i,j])
                + Sqr(LPF1_result[i,j+1] - LPF1_result[i,j]))/Sqrt(2);
        grad_result[i,j] := Grad;
    end;
```

Meze cyklů zohledňují černý okraj snímku, jinak by nám vlevo a vpravo vznikly nežádoucí svislé hrany.

Výsledek této operace (obrázek 3.5) jsme pro lepší viditelnost převedli na negativ a přidali jsme černý rámeček.

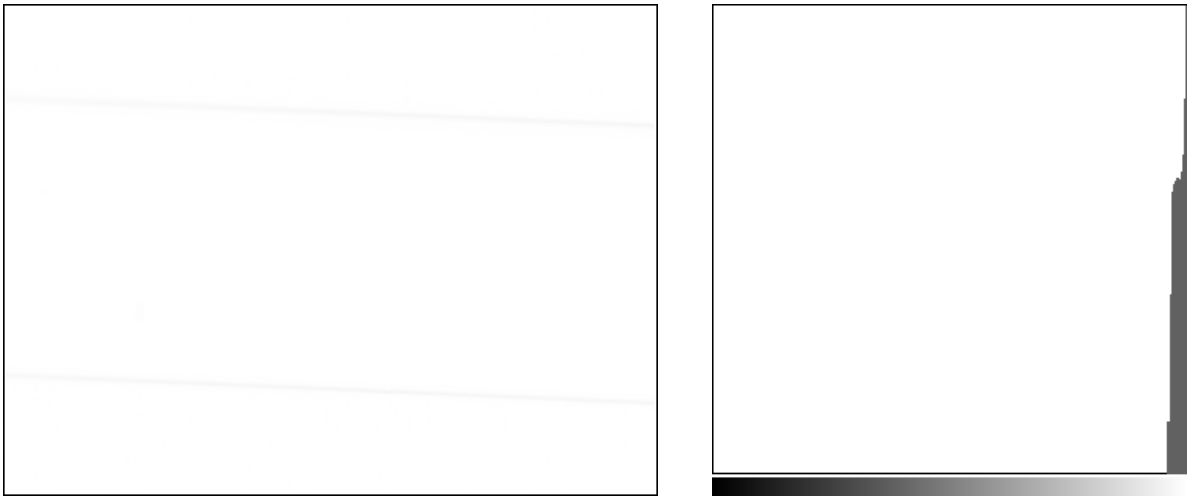

Obrázek 3.5: Negativ výsledku gradientní metody (vlevo) a jeho histogram (vpravo). Svislá osa histogramu je pro lepší názornost logaritmická.

3.2.4. Autoexpanze 1

Účelem této automatické expanze je pouze vizualizace výsledku gradientní metody. Výsledek gradientu využívá pouze malou část možného rozsahu hodnot, a to tak malou, že je na pozadí sotva něco vidět.

I když je tento krok z pohledu algoritmu jako celku zbytečný, vstupem do dalšího kroku bude výsledek této autoexpanze.

Poznámka: Data si od počátku algoritmu uchováváme v reálné proměnné.

Realizace automatické expanze v jazyce pascal:

```
min := 255;
max := 0;
for j:=4 to (Image1.Picture.Bitmap.Height - 5) do
    for i:=4 to (Image1.Picture.Bitmap.Width - 5) do
    begin
        if max <= grad_result[i, j] then max := grad_result[i, j];
        if min >= grad_result[i, j] then min := grad_result[i, j];
    end;
// minimum i maximum nalezeno, matice grad_result zatím nezměněna
for j:=4 to (Image1.Picture.Bitmap.Height - 5) do
    for i:=4 to (Image1.Picture.Bitmap.Width - 5) do
        grad_result[i, j] := (grad_result[i, j] - min)/(max - min)*255;
```

Výsledek této operace jsme pro lepší viditelnost převedli na negativ a přidali jsme černý rámeček. Viz obrázek 3.6.

3.2.5. Filtr typu dolní propust 2

Tímto filtrem potlačíme šum, který nám vznikl použitím gradientní metody. Postup je stejný jako v odstavci 3.2.2.

Výsledek této operace jsme pro lepší viditelnost převedli na negativ a přidali jsme černý rámeček. Viz obrázek 3.7.

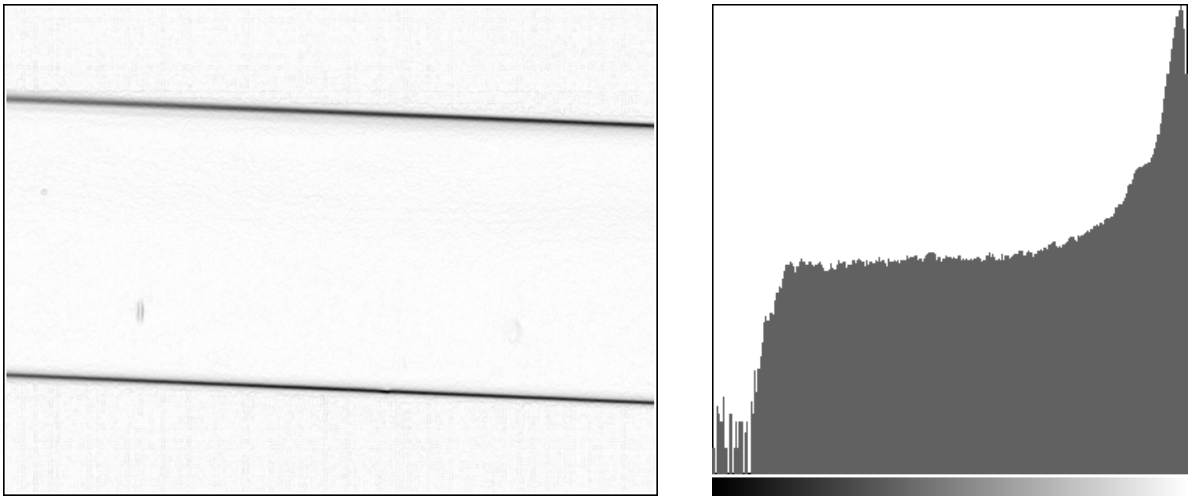

Obrázek 3.6: Negativ výsledku první autoexpanze (vlevo) a jeho histogram (vpravo). Svislá osa histogramu je pro lepší názornost logaritmická.

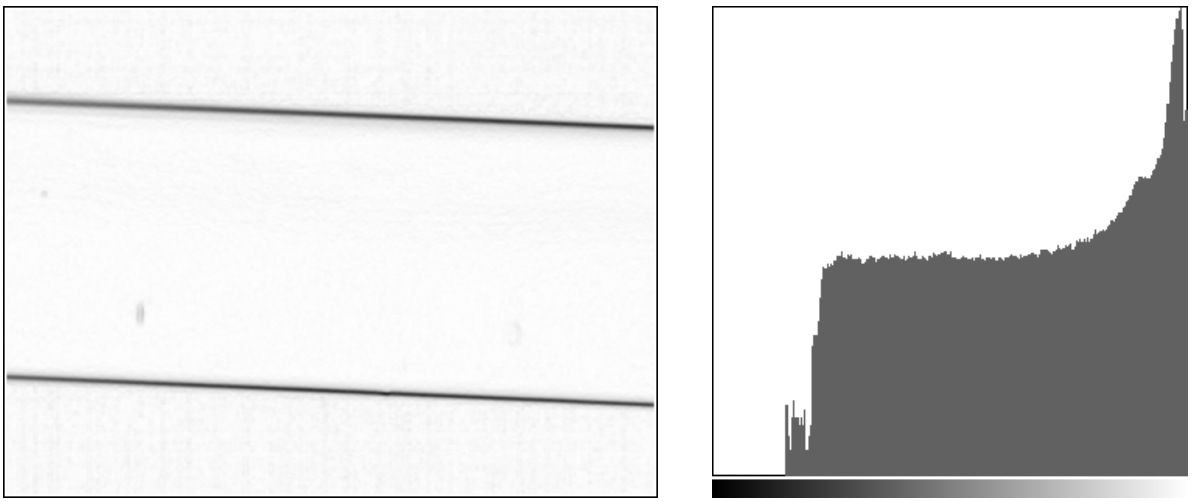

Obrázek 3.7: Negativ výsledku druhého filtru typu dolní propust (vlevo) a jeho histogram (vpravo). Svislá osa histogramu je pro lepší názornost logaritmická.

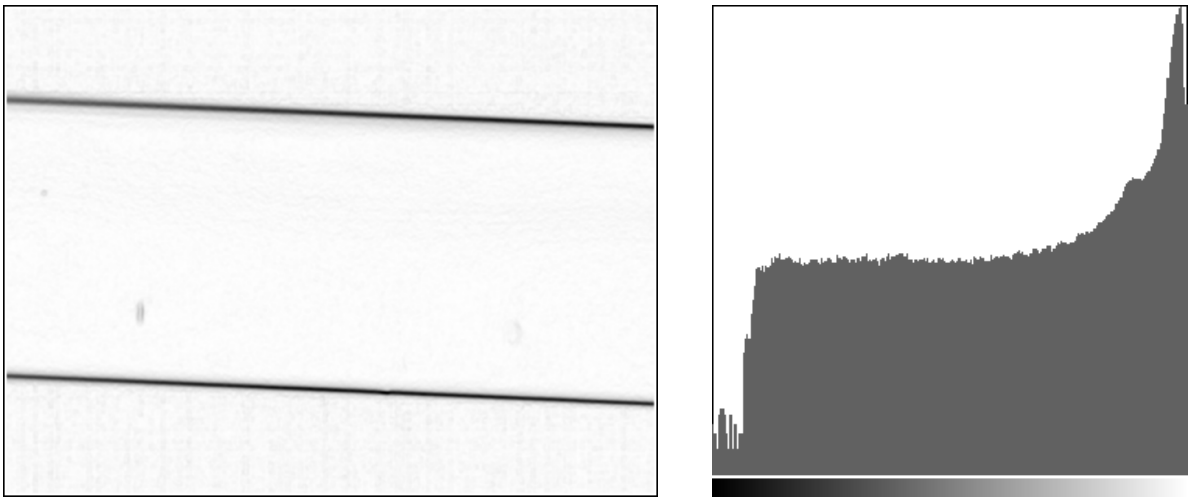

Obrázek 3.8: Negativ výsledku druhé autoexpanze (vlevo) a jeho histogram (vpravo). Svislá osa histogramu je pro lepší názornost logaritmická.

3.2.6. Autoexpanze 2

Data normalizujeme na rozsah 0–255, takže se nám bude mnohem lépe nastavovat hodnota prahu. Možná budeme schopni určit jednu hodnotu prahu pro všechny snímky.

Výsledek této operace jsme pro lepší viditelnost převedli na negativ a přidali jsme černý rámeček. Viz obrázek 3.8.

3.2.7. Prahování

Při vhodně zvolené prahové hodnotě provedeme segmentaci obrazu, kterým je v této chvíli poupravený výsledek gradientní metody. Všechny pixely s hodnotou nižší než práh označíme jako pozadí, pixely s hodnotou vyšší (nebo rovnou) označíme jako objekt. V našem případě to provedeme tak, že jim nastavíme nulovou hodnotu (černý). Ostatním pixelům nastavíme hodnotu 255 (bílý).

Výsledek této operace jsme pro lepší viditelnost převedli na negativ a přidali jsme černý rámeček. Viz obrázek 3.9.

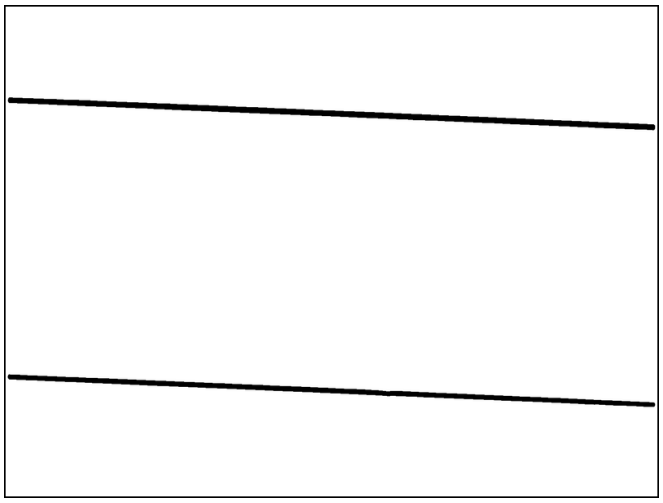

Obrázek 3.9: Negativ výsledku prahování - obsahuje pouze dvě barvy.

3.2.8. Identifikace hran

Horní hranu identifikujeme tak, že si zvolíme výchozí bod ve středu horní strany obrazu a postupujeme směrem ke středu obrazu. Až narazíme na pixel, který nepatří pozadí, ale objektu, identifikujeme objekt horní hrany. Pokud bude mít nalezený objekt počet pixelů menší než předem zvolená hranice, algoritmus ukončíme. Kritická hranice je implicitně nastavena na 50 pixelů.

Analogicky budeme hledat i dolní hranu.

Ilustraci tohoto postupu můžete vidět na obrázku 3.10. Jedná se však o vlákno, se kterým jsme v tomto textu dosud nepracovali. Je zde použito pouze pro demonstraci rozpadu horní hrany vlákna při prahování.

Na obrázku 3.11 jsou identifikovány hrany vlákna, se kterým jsme pracovali dosud a se kterým budeme pracovat i nadále.

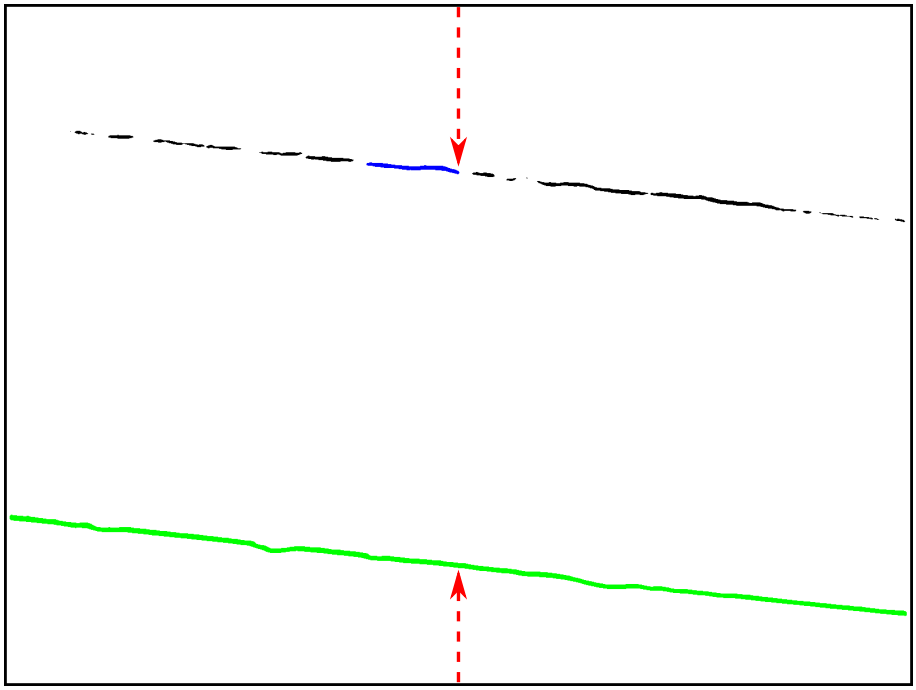

Obrázek 3.10: Výsledek identifikace hran. Pro účel tisku byla černá a bílá barva invertována.

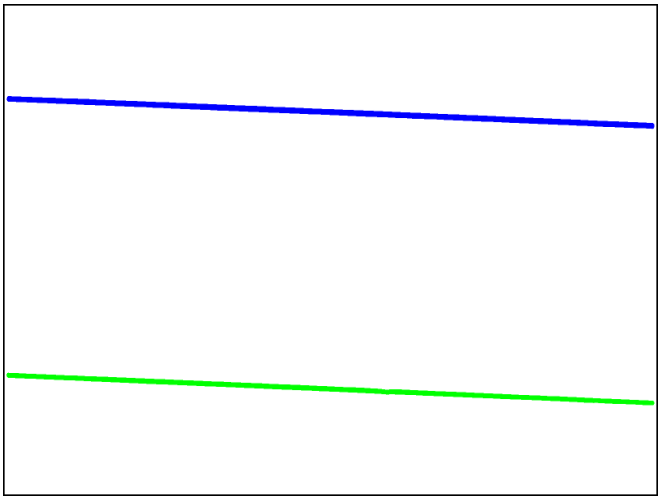

Obrázek 3.11: Výsledek identifikace hran. Pro účel tisku bylo černé pozadí nahrazeno bílým.

3.2.9. Užití metody nejmenších čtverců

Na objekt hrany se můžeme dívat jako na množinu bodů - pixelů. Vyhledáme všechny modré pixely v obraze a zaznamenáme si jejich souřadnice $[x_i, y_i]$. Dále postupujeme podle rovnice 2.8.

```
nn := k;    //počet pixelů náležejících horní hraně
sumX := 0; sumX2 := 0; sumXY := 0; sumY := 0;
for i:=0 to (nn - 1) do begin
    sumX := sumX + ListX[i];
    sumX2 := sumX2 + ListX[i]*ListX[i];
    sumXY := sumXY + ListX[i]*ListY[i];
    sumY := sumY + ListY[i];
end;
k1 := (nn*sumXY - sumX*sumY)/(nn*sumX2 - sumX*sumX);
q1 := (sumY - k1*sumX)/nn;
```

Analogicky proložíme přímku i množinou zelených pixelů.

3.2.10. Určení vzdálenosti

Směrnice přímek získaných z MNČ se sice většinou liší až na zhruba třetím desetinném místě, ale přímky rovnoběžné nejsou. Budeme tedy postupovat podle odstavce 2.14. Výsledek je na obrázku 3.12.

Náš software nám udá průměr vlákna v pixelech. Přepočet na mikrometry záleží na konkrétním aparátu, kterým byl daný snímek pořízen. Jednoduchým měřením jsme zjistili, že v případě naší optické soustavy se délka jednoho milimetru zobrazí na délku

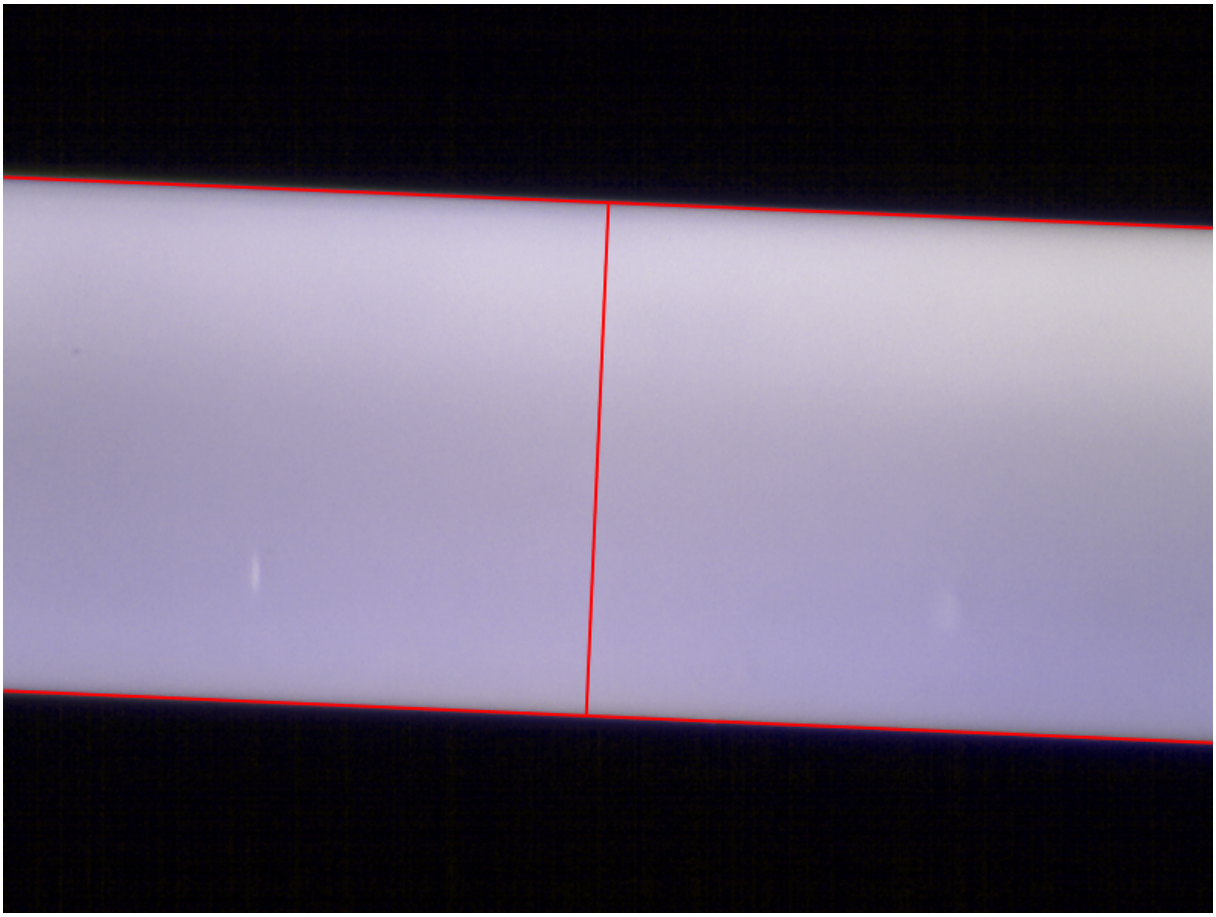

Obrázek 3.12: Původní snímek s červeně vyznačenými hranami a úsečkou, na které byl naměřen průměr.

1346 pixelů. V následujících kapitolách budeme všechny naměřené průměry vláken transformovat tímto převodním poměrem.

3.3. Nastavení parametrů

Software sice máme, ale nevíme, jaké je nejlepší nastavení parametrů, tj. při jakých hodnotách parametrů máme největší šanci na úspěšné měření. Parametry máme celkem tři. Jedním je práh, dalšími dvěma jsou konstanty ve vzorcích pro první a druhý filtr typu dolní propust.

Provedeme tedy experiment. Vezmeme určitý počet různých snímků vláken a všechny zpracujeme pro různá nastavení parametrů LPF1, LPF2 a práh. Ze získaných dat se další analýzou pokusíme určit optimální nastavení parametrů.

Experiment provedeme na deseti snímcích. Budeme uvažovat následující hodnoty parametrů:

Tabulka 2: Parametry

parametr	rozsah hodnot	krok	počet různých hodnot
LPF1	1 až 20	1	20
LPF2	1 až 20	1	20
práh	46 až 226	12	16

Obdržíme tedy $10 \times 20 \times 20 \times 16 = 64000$ měření, která v následujících dvou odstavcích zanalyzujeme.

3.3.1. Optimální hodnoty parametrů LPF1 a LPF2

Na datech, která jsme obdrželi budeme nejdříve sledovat úspěšnost měření jako závislost na hodnotách LPF1 a LPF2. Měření bývají neúspěšná když je práh příliš vysoký nebo když jsou hodnoty LPF1 a LPF2 příliš malé (v obraze zůstane příliš šumu).

Data zpracujeme v programu Minitab 17. Použijeme metodu binární regrese pro různé nastavení parametrů LPF1 a LPF2.

Následují výsledky v podobě konturových diagramů (pro pátý snímek se nepovedlo sestavit příslušný binární model).

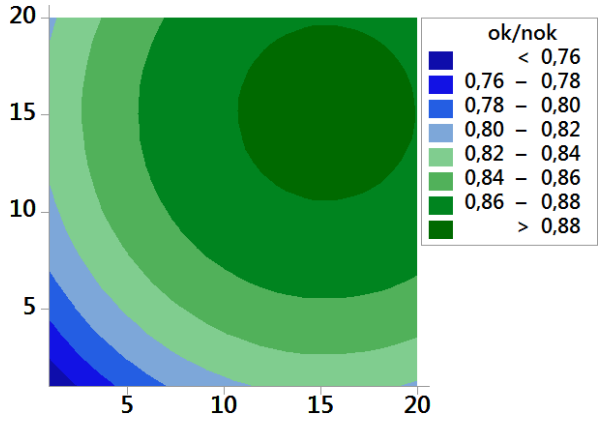

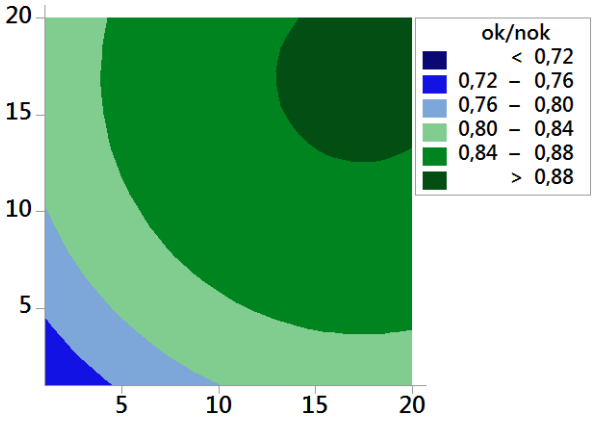

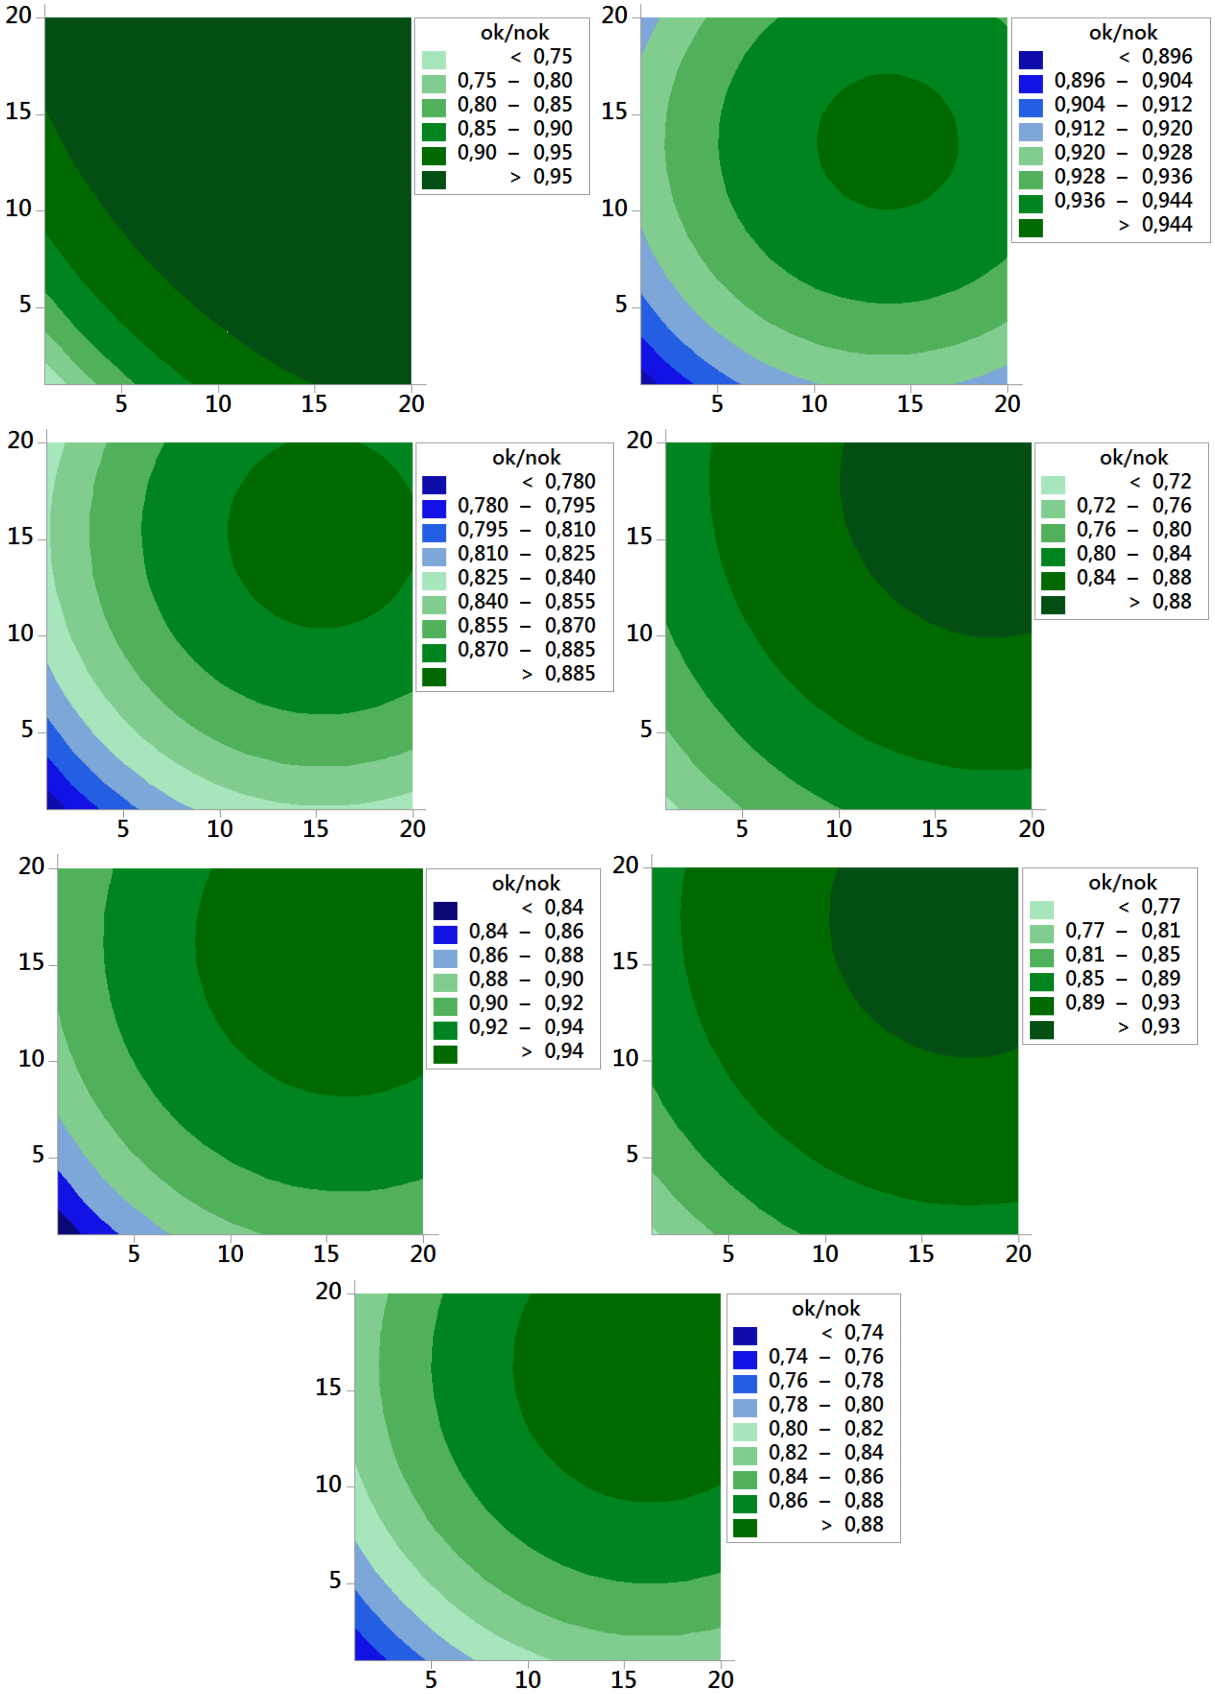

Tyto diagramy byly vytvořeny v programu Minitab 17. Na vodorovné ose je vždy parametr LPF1, na ose svislé parametr LPF2. Tmavě zelené oblasti mají největší hustotu úspěšných měření.

Z grafů můžeme vyvodit tři závěry:

a) Grafy jsou téměř symetrické podle osy kvadrantu. V dalším tedy můžeme oběma filtrům typu dolní propust nastavit stejné hodnoty parametrů. (Počet parametrů jsme zredukovali ze tří na dva.)

b) Od hodnoty cca 18 až 20 se počet úspěšných měření začíná snižovat. Je to způsobeno tím, že se náš lineární filtr začíná příliš blížit klouzavému průměru. Klouzavý průměr propouští některé vysoké obrazové frekvence.

c) Největší úspěšnost identifikace hran nastává pro hodnoty cca 12 až 18. Střed intervalu $\langle 12, 18 \rangle$ je číslo 15. **Za optimální hodnotu pro konstanty LPF1 a LPF2 tedy zvolíme číslo 15**.

3.3.2. Optimální prahová hodnota

Předchozích 64000 měření zredukujeme na 3200 tím, že využijeme výsledek předchozího odstavce, tj. položíme LPF1 = LPF2 (dále jen LPF). Data znázorníme v programu Minitab pomocí bodových diagramů (scatterplot), které můžete nalézt v příloze A. Znázornili jsme pouze úspěšná měření, protože neúspěšná nemají přiřazenou hodnotu průměru.

Hledáme, pro jakou prahovou hodnotu je variabilita v závislosti na změně parametru LPF minimální. Pro každý z deseti snímků a každou prahovou hodnotu spočteme směrodatnou odchylku naměřených průměrů.

Tabulka 3: Směrodatné odchylky

práh\č.	1	2	3	4	5	6	7	8	9	10
46	0,168	0,202	0,247	0,193	0,354	0,232	0,133	0,300	0,155	0,233
58	0,068	0,135	0,185	0,127	0,322	0,207	0,095	0,197	0,075	0,143
70	0,054	0,074	0,109	0,078	0,239	0,125	0,058	0,115	0,059	0,079
82	0,022	0,048	0,074	**0,059**	0,158	0,069	0,052	0,074	0,077	0,068
94	0,029	0,039	**0,063**	0,064	0,092	0,047	**0,052**	0,076	0,075	0,092
106	**0,019**	**0,036**	0,066	0,080	0,072	**0,039**	0,070	0,067	**0,053**	0,067
118	0,038	0,058	0,088	0,109	**0,051**	0,047	0,100	0,052	0,061	**0,034**
130	0,102	0,100	0,121	0,150	0,070	0,046	0,138	0,040	0,084	0,062
142	0,151	0,137	0,151	0,168	0,098	0,068	0,151	**0,027**	0,140	0,115
154	0,176	0,165	0,203	0,175	0,132	0,079	0,174	0,039	0,197	0,186
166	0,204	0,132	0,229	0,160	0,164	0,060	0,139	0,065	0,211	0,146
178	0,165	0,146	0,230	0,201	0,200	0,082	0,105	0,073	0,182	0,183
190	0,162	0,096	0,166	0,169	0,230	0,056	0,091	0,088	0,160	0,152
202	0,052	0,054	0,132	0,187	0,180	0,070	0,087	0,090	0,122	0,063
214	-	-	0,100	0,158	0,146	-	-	0,078	0,038	-
226	-	-	0,045	-	0,071	-	-	-	-	-
min	106	106	94	82	118	106	94	142	106	118

Pomlčky v tabulce 3 znamenají, že pro daný snímek a daný práh nebylo žádné měření úspěšné. Pro snímek číslo 3 nejmenší směrodatná odchylka odpovídá prahové hodnotě 226, ale tak vysoký práh uvažovat nebudeme, vezmeme tedy druhou nejmenší hodnotu. U snímku číslo 7 vidíme dvě minimální hodnoty (0,052), ty se však liší na čtvrtém desetinném místě.

Poslední řádek si pro lepší názornost seřadíme:
82, 94, 94, 106, 106, 106, 106, 118, 118, 142.

Tři hodnoty jsou menší než 106 a tři jsou větší než 106. **Za optimální hodnotu prahu tedy prohlásíme *medián* = 106**.

4. Opakovatelnost a reprodukovatelnost

Analýza opakovatelnosti a reprodukovatelnosti se označuje i jako R&R studie (repeatability and reproducibility). Tato studie umožňuje stanovit, kolik z pozorované variability procesu vzniká v důsledku variability systému měření.

Informace v této kapitole byly čerpány z [1] a z nápovědy programu Minitab.

Opakovatelnost – variabilita výsledků měření vyprodukovaná jedním měřicím přístrojem, použitým opakovaně jedním hodnotitelem měřícím jednu identickou charakteristiku na stejném výrobku

Reprodukovatelnost – variabilita v průměrech měření provedených různými hodnotiteli za pomocí stejného měřícího přístroje pro měření stejné charakteristiky na stejném výrobku

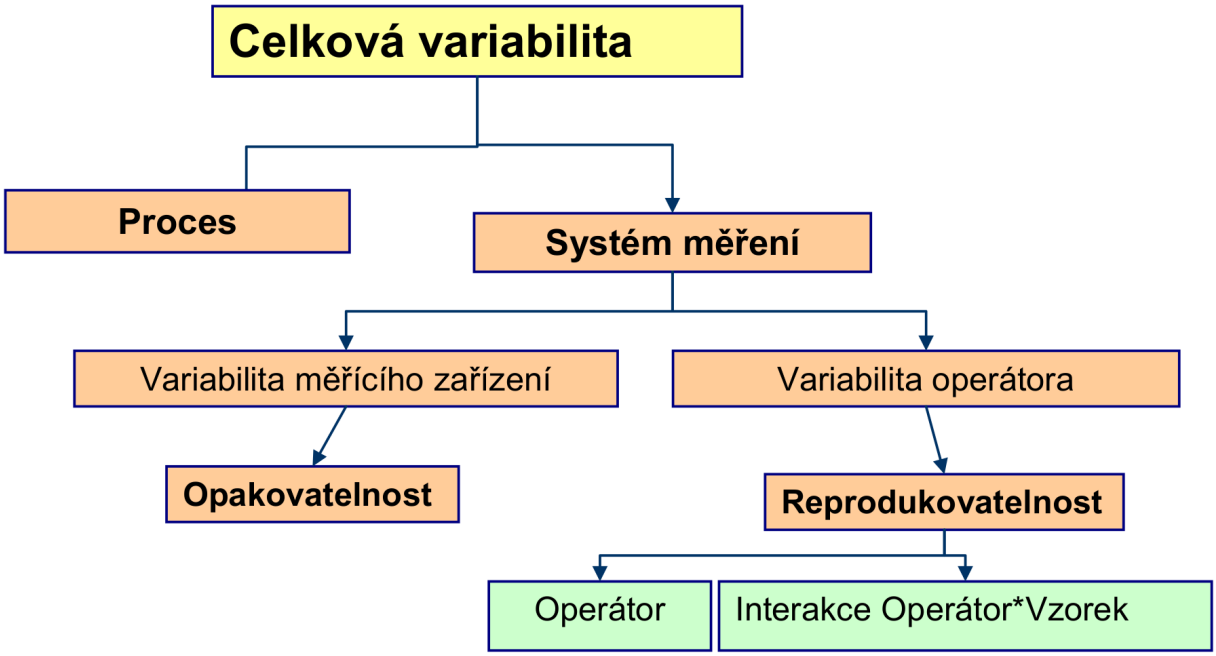

Obrázek 4.1: Toto schéma rozdělení variability bylo převzato z [1].

Naším cílem je zjistit variabilitu měřicího přístroje a metody zpracování snímku. Vlákna jsou ovšem mírně oválná, a to i po navlečení na kalibrační drátek. Kdybychom vlákno změřili, vyjmuli z mikroskopu a chtěli ho vrátit do mikroskopu do předchozí polohy, tak bychom i při sebelepším snažení měřili jiný rozměr než byl ten předchozí. Z tohoto důvodu nebudeme mezi jednotlivými měřeními vyjímat vlákno z mikroskopu, budeme pouze pootáčet snímačem obrazu a měnit zaostření, budeme tak měnit vzájemnou polohu.

Tolerance na odchylku měření nám byla dána 10 µm.

4.1. Opakovatelnost

Nejdříve se budeme zabývat pouze opakovatelností (tj. variabilita měřicího zařízení, ne variabilita operátora). Tato analýza by měla předcházet dalším R&R studiím.

Analýzu provedeme dvakrát, tzn. budeme mít dva operátory. Jeden operátor provede 30 měření jednoho rozměru. Druhý operátor provede 30 měření druhého rozměru. Pro vypovídající výsledky je doporučený počet měření 25 a více. Získaná data zpracujeme v programu Minitab.

Následují výsledky:

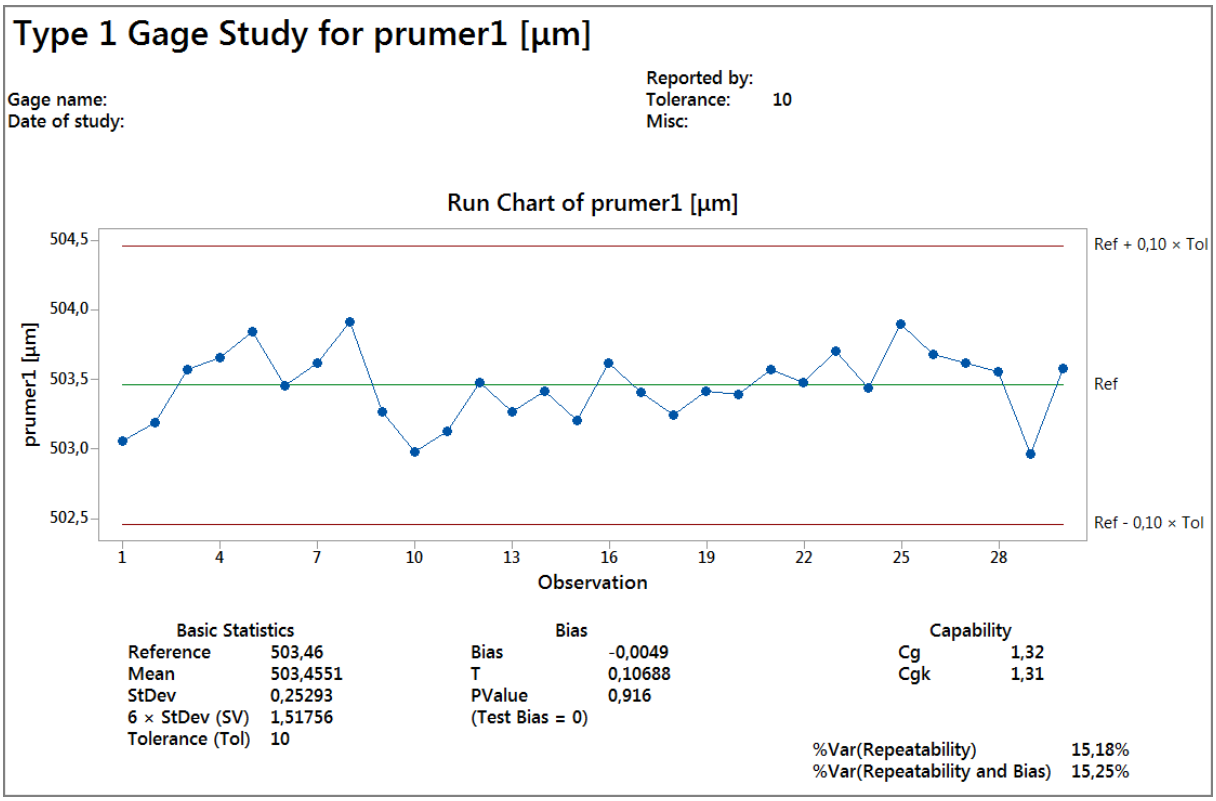

Obrázek 4.2: Výsledky měření prvního rozměru prvním operátorem.

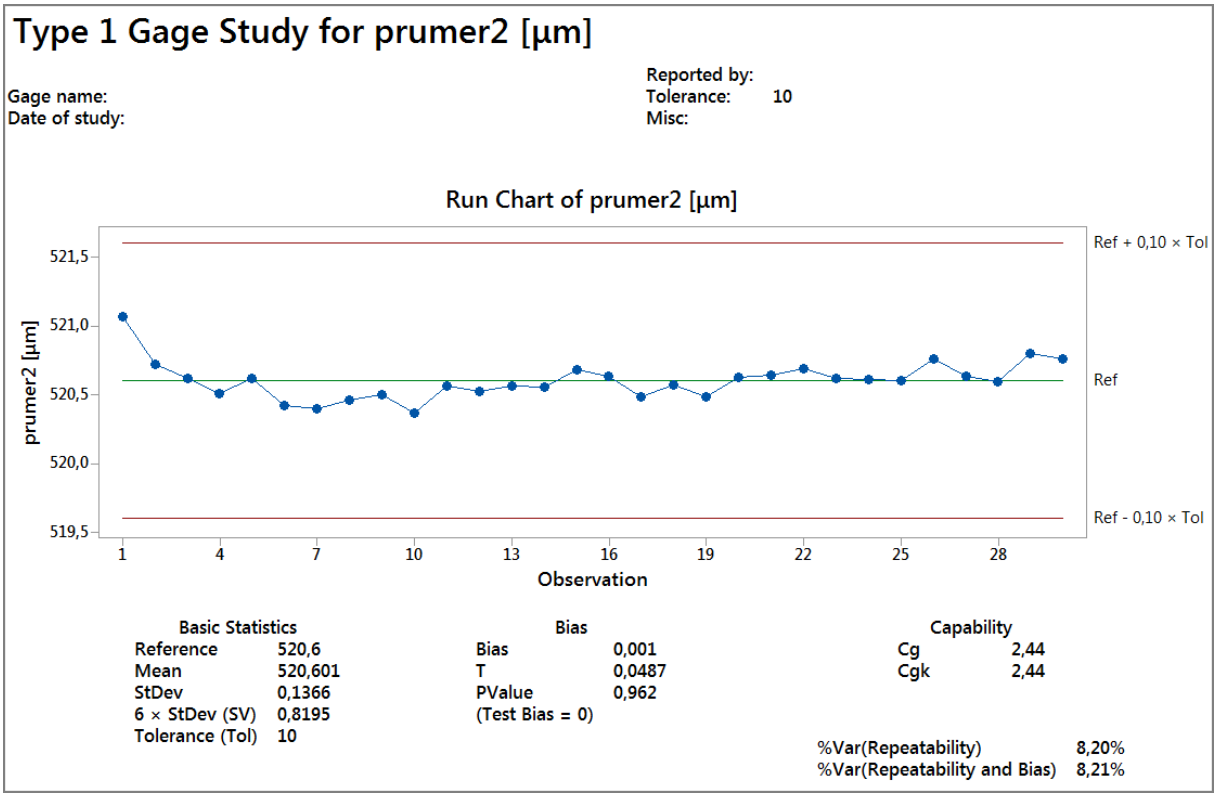

Obrázek 4.3: Výsledky měření druhého rozměru druhým operátorem.

Na první pohled vidíme, že se všechny hodnoty nachází ve vyznačeném pásu, který značí přípustnou odchylku měření ($\pm 10\,\mu m$). Jako referenční hodnotu jsme zvolili průměr z naměřených hodnot, protože přesný průměr vlákna neznáme. Z toho důvodu nám v obou případech vyšla strannost téměř nulová.

Cg srovnává toleranci s variabilitou měření, zatímco Cgk srovnává toleranci s variabilitou měření a stranností. Velké Cg a Cgk značí, že variabilita způsobená měřicím systémem je malá vzhledem k toleranci. Typická mez pro obě hodnoty je 1,33. U prvního operátora nám vyšlo Cg = 1,32 a u druhého Cg = 2,44. Jako důsledek toho, že strannost je nevýznamná, vyšlo v obou případech Cg = Cgk. V prvním případě se nacházíme těsně pod hranicí, ale když vezmeme v úvahu i druhý případ, můžeme říct, že variabilita systému měření je přijatelně nízká.

%Var(Repeatability) je určena koeficientem Cg a %Var(Repeatability and bias) je určena koeficientem Cgk. Nízké hodnoty %Var značí malou variabilitu měření vzhledem k toleranci. Mez Cg = 1,33 odpovídá hodnotě %Var = 15 %. Výsledky $15,18\,\%$ a $8,20\,\%$ jsou pozitivní.

Získané výsledky naznačují, že systém měření funguje konzistentně a s dostatečnou přesností. Přistoupíme tedy k R&R studii.

4.2. R&R studie

Provedeme další sérii měření. Náhodně jsme vybrali 12 vzorků. Měření opakovali tři operátoři. Každé měření bylo provedeno třikrát.

Naměřené hodnoty:

	operátor1	operátor2	operátor3
vlákno1	499,8092	499,6334	499,3819
	499,5659	499,6567	499,2968
	500,0572	499,6775	499,5158
vlákno2	502,0272	502,1569	501,5310
	502,1552	502,3196	501,8342
	502,1363	502,3486	502,5938
vlákno3	502,4956	502,6050	502,4968
	502,5256	502,6771	502,3820
	502,7658	502,5628	502,3227
vlákno4	505,8403	505,6204	505,7303
	505,6672	505,4730	505,4459
	505,8837	505,4965	505,1890
vlákno5	500,4782	500,5173	500,2464
	500,5219	500,4972	499,6946
	500,6124	500,3507	500,0584
vlákno6	484,9348	484,7548	484,0722
	484,8012	484,5447	484,2274
	484,7496	484,3970	484,7558
vlákno7	493,1294	493,1935	492,9757
	493,1367	492,7533	492,8053
	493,1074	492,7936	492,7783
vlákno8	505,3205	505,5211	505,6308
	505,5259	505,5517	505,0172
	505,5339	505,5506	505,1134
vlákno9	512,9476	512,9068	512,8651
	512,7724	512,9881	511,9730
	512,7701	512,8771	512,2707
vlákno10	500,3591	500,0510	500,5071
	500,3547	500,2103	500,3659
	500,2956	500,3153	500,8956
vlákno11	505,3172	505,1331	504,8747
	505,3149	504,9340	504,9610
	505,1902	504,7637	505,0175
vlákno12	496,1332	495,6758	495,6176
	495,9694	495,6006	495,9711
	495,9939	495,2244	496,0514

Tato měření zpracujeme v programu Minitab pomocí Gage R&R Study ANOVA Method.

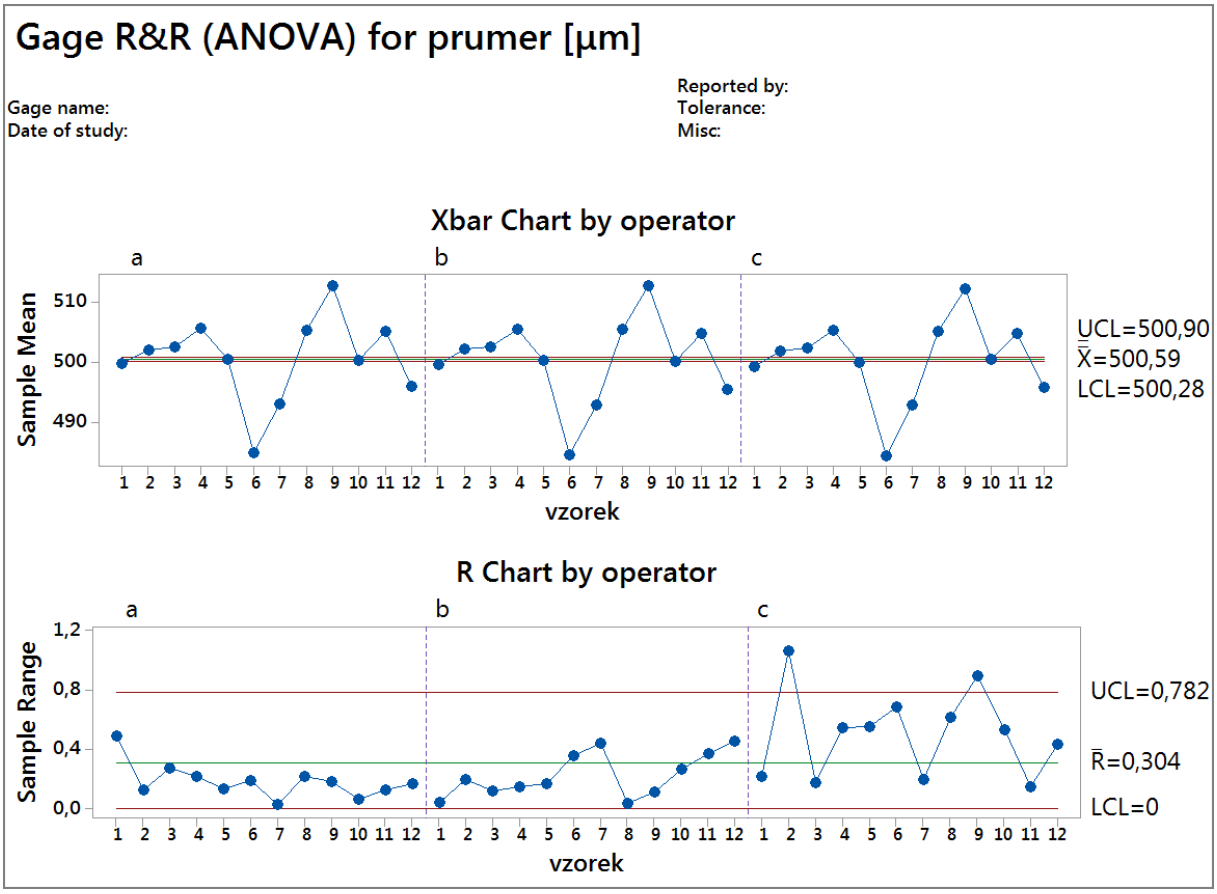

Obrázek 4.4: V grafu Xbar Chart vidíme, že naprostá většina bodů leží mimo vyznačené hranice. To naznačuje, že velká část celkové variability je způsobena rozdíly mezi vzorky. V grafu R Chart vidíme, že operátor C měřil vzorky nekonzistentně.

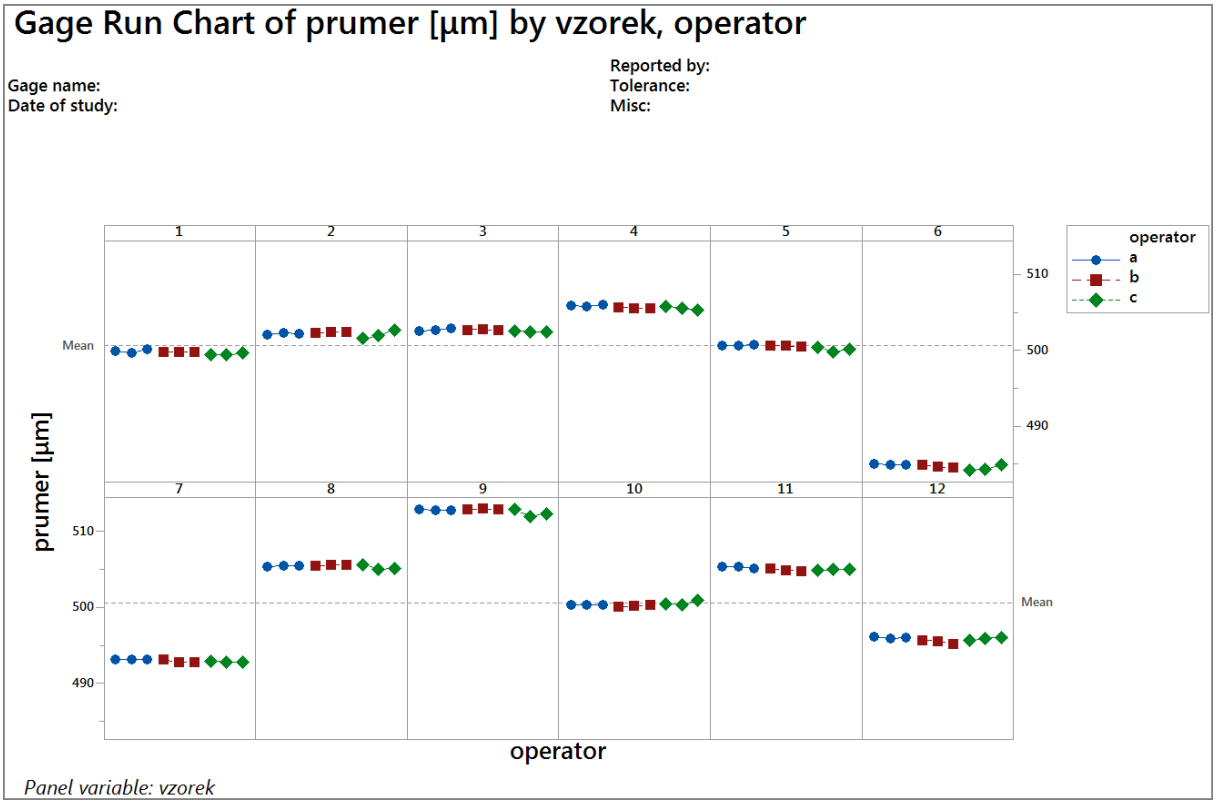

Obrázek 4.5: V tomto průběhovém diagramu vidíme, že pro jednotlivé vzorky jsou naměřené hodnoty téměř konstantní. Naměřená hodnota tedy téměř nezávisí na tom, kdo ji měřil.

Následuje první odstavec textové části výsledků z Minitabu:

```
Two-Way ANOVA Table With Interaction

Source              DF       SS       MS        F      P
vzorek              11  5036,92  457,902  5349,11  0,000
operator             2     1,32    0,658     7,68  0,003
vzorek * operator   22     1,88    0,086     2,13  0,009
Repeatability       72     2,90    0,040
Total              107  5043,02

alpha to remove interaction term = 0,05
```

Z této tabulky můžeme vyčíst následující:

- Pozitivní je, že je významný faktor `vzorek`, ale špatné je, že je významný i faktor `operátor`.
- Pro interakci `vzorek * operator` vyšla p-hodnota = 0,009, což je méně než 0,05. Interakce je tedy významná a Minitab ji zahrne do plného modelu.

```
Gage R&R

                              %Contribution
Source                VarComp   (of VarComp)
Total Gage R&R         0,0713           0,14
  Repeatability        0,0402           0,08
  Reproducibility      0,0310           0,06
    operator           0,0159           0,03
    operator*vzorek    0,0151           0,03
Part-To-Part          50,8685          99,86
Total Variation       50,9398         100,00


Process tolerance = 10


                                   Study Var  %Study Var  %Tolerance
Source                StdDev (SD)   (6 x SD)       (%SV)  (SV/Toler)
Total Gage R&R            0,26694     1,6016        3,74       16,02
  Repeatability           0,20060     1,2036        2,81       12,04
  Reproducibility         0,17611     1,0567        2,47       10,57
    operator              0,12608     0,7565        1,77        7,56
    operator*vzorek       0,12297     0,7378        1,72        7,38
Part-To-Part              7,13222    42,7933       99,93      427,93
Total Variation           7,13721    42,8233      100,00      428,23


Number of Distinct Categories = 37
```

Komentář k výsledkům:

- Podívejme se na sloupec `%Contribution` v tabulce `Gage R&R`. Hodnota `Part-To-Part` ($99,86\,\%$) je větší než `Total Gage R&R` ($0,14\,\%$). To znamená, že většina celkové variability je způsobena variabilitou vzorků.
- Vzhledem k procesu (sloupec `%Study Var`) jsme dostali hodnotu $3,74\,\%$, což je méně než $10\,\%$. Náš systém měření je tedy přípustný ke sledování procesu.
- Vzhledem k tolerančnímu rozpětí $\pm\,10\,\mu\mathrm{m}$ (sloupec `%Tolerance`) jsme dostali hodnotu $16,02\,\%$. Jsme tedy v intervalu $\langle 10\,\%, 30\,\% \rangle$. Tzn. náš systém je podmíněně přípustný vzhledem k tolerančnímu rozpětí, závisí to na poměru ceny nápravy a významnosti sledované veličiny.
- Podle AIAG (Automotive Industry Action Group) je třeba mít alespoň 5 různých kategorií, aby byl měřicí systém adekvátní. Náš systém měření rozezná 37 různých kategorií výrobků, takže adekvátní je.
  Variační rozpětí našeho statistického souboru činí necelých $29\,\mu\mathrm{m}$, rozpětí jedné kategorie potom vychází na cca $0{,}78\,\mu\mathrm{m}$. Můžeme tedy říct, že jsme schopni měřit s přesností $0{,}8\,\mu\mathrm{m}$.

Závěr

Tato práce se zabývala měřením průměru extrudovaných vláken s přesností na mikrometry při průměru 500 µm. Byl popsán postup využívající numerických metod zpracování obrazu (kterým je snímek vlákna z optického mikroskopu). Tento postup je alternativou k laserovému mikrometru. Výhodou tohoto postupu je například uchování zdrojových informací a vizuální kontrola nad měřením.

Na analýzu snímků byla vytvořena jednoúčelová aplikace ve vývojovém prostředí Lazarus.

Navržený postup jsme několika způsoby otestovali na reálných datech. Podařilo se nám najít hodnoty parametrů jednotlivých numerických metod pro automatickou analýzu. Je však nutné mít na paměti, že nalezené hodnoty parametrů úzce souvisí s danou optickou soustavou a daným typem měřeného objektu. Při změně konfigurace optického systému nebo materiálu měřeného vlákna je nutné znovu najít vhodné parametry pro jednotlivé numerické metody.

Podle výsledků R&R studie je navržená metoda podmíněně způsobilá ke sledování požadavku zákazníka, tím se myslí kontrola dodržení požadované tolerance průměru vlákna.

Variabilita systému měření je vzhledem k procesu způsobilá, tzn. systém měření je způsobilý ke sledování procesu výroby.

Rozpětí jedné kategorie vyšlo 0,8 µm, tzn. je splněn prvotní požadavek měření průměru vlákna s přesností alespoň na jeden mikrometr.

Pro minimalizaci variability operátora by bylo možné systém ostření provést automaticky na základě obrazové analýzy. Tímto způsobem by bylo možné systém měření více zautomatizovat.

Literatura

[1] BEDNÁŘ, Josef. *Aplikovaná statistika v průmyslu.* Brno: VUT v Brně Fakulta strojního inženýrství, 2012.

[2] DRUCKMÜLLER, Miloslav. *Numerické metody analýzy obrazů.* (přednášky) Brno: VUT v Brně Fakulta strojního inženýrství, 2016.

[3] ČERMÁK, Libor a Rudolf HLAVIČKA. *Numerické metody.* Vyd. 2. Brno: Akademické nakladatelství CERM, 2008. ISBN 978-80-214-3752-4.

[4] KLÍMA, Miloš. *Zpracování obrazové informace.* V Praze: České vysoké učení technické, 1996. ISBN 80-010-1436-3.

[5] MARTIŠEK, Dalibor. *Matematické principy grafických systémů.* Brno: Littera, 2002. ISBN 80-857-6319-2.

[6] WILLIAM K. PRATT. *Digital Image Processing (Third Edition) PIKS Inside* [online]. 3rd ed. New York: Wiley-Interscience, 2001 [cit. 2017-05-24]. ISBN 04-712-2132-5. Dostupné z: http://www.csupomona.edu/∼kding/materials/Digital Image Processing - Third Edition - William K.Pratt.pdf

Seznam použitých zkratek a symbolů

$\otimes$	operace konvoluce
$\perp$	relace kolmosti dvou geometrických útvarů
BMP	Windows bitmap, typ souboru s obrazovými daty
$\exp(x)$	$\exp(x) = e^x$, kde e je Eulerovo číslo, tj. $e \doteq 2,71828$
$\mathcal{F}()$	Fourierova transformace
HPF	high-pass filter, filtr typu horní propust
LPF	low-pass filter, filtr typu dolní propust, v kapitole 3 použito i jako označení parametru
MNČ	metoda nejmenších čtverců
R&R	repeatability and reproducibility, opakovatelnost a reprodukovatelnost
$\mathbf{X}^T$	transponovaná matice $\mathbf{X}$

Seznam příloh

Příloha A – bodové diagramy (scatter plot)

CD1 – elektronická verze textu

CD2 – Obsahuje software na zpracování snímků vláken. Sestavena byla pouze 64-bitová verze pro Windows. Vytvořeno v programu Lazarus IDE verze 1.8.2.
Příloha CD2 dále obsahuje snímky vláken.

Příloha A

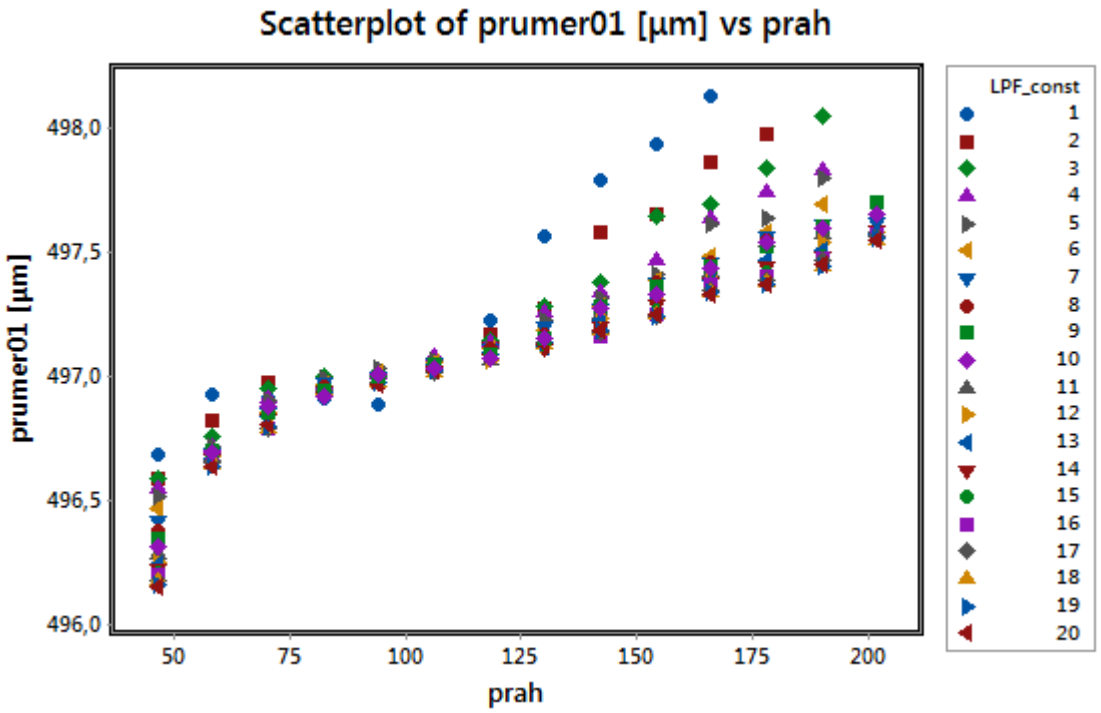

Obrázek A-01: Vytvořeno v programu Minitab 17.

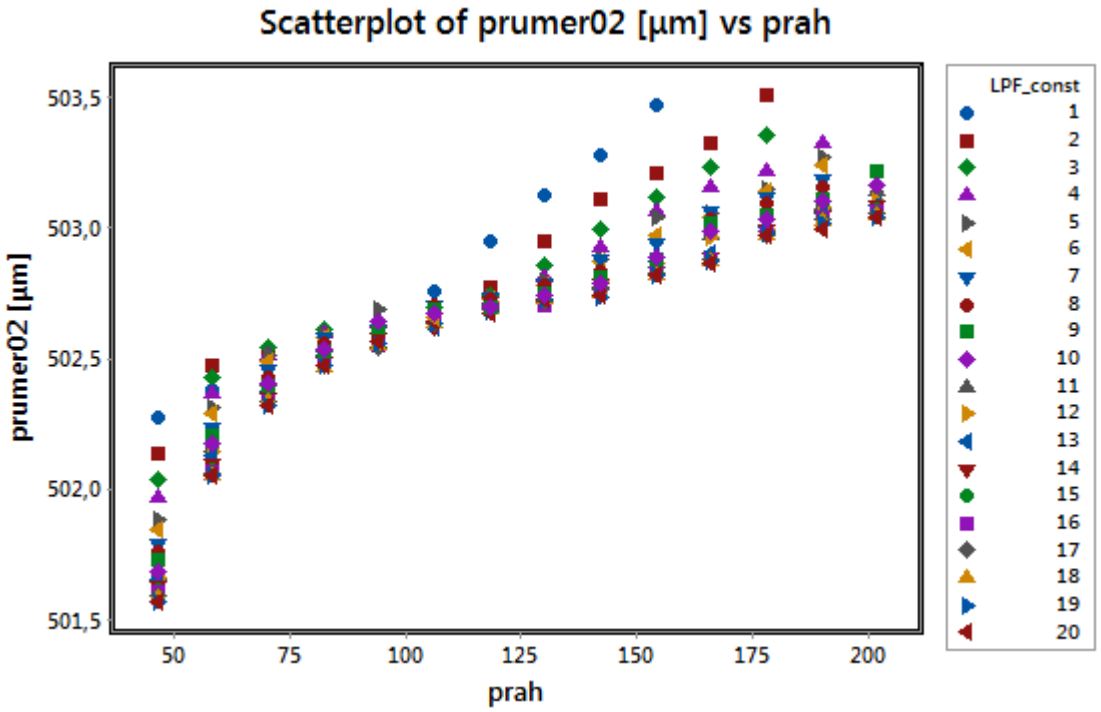

Obrázek A-02: Vytvořeno v programu Minitab 17.

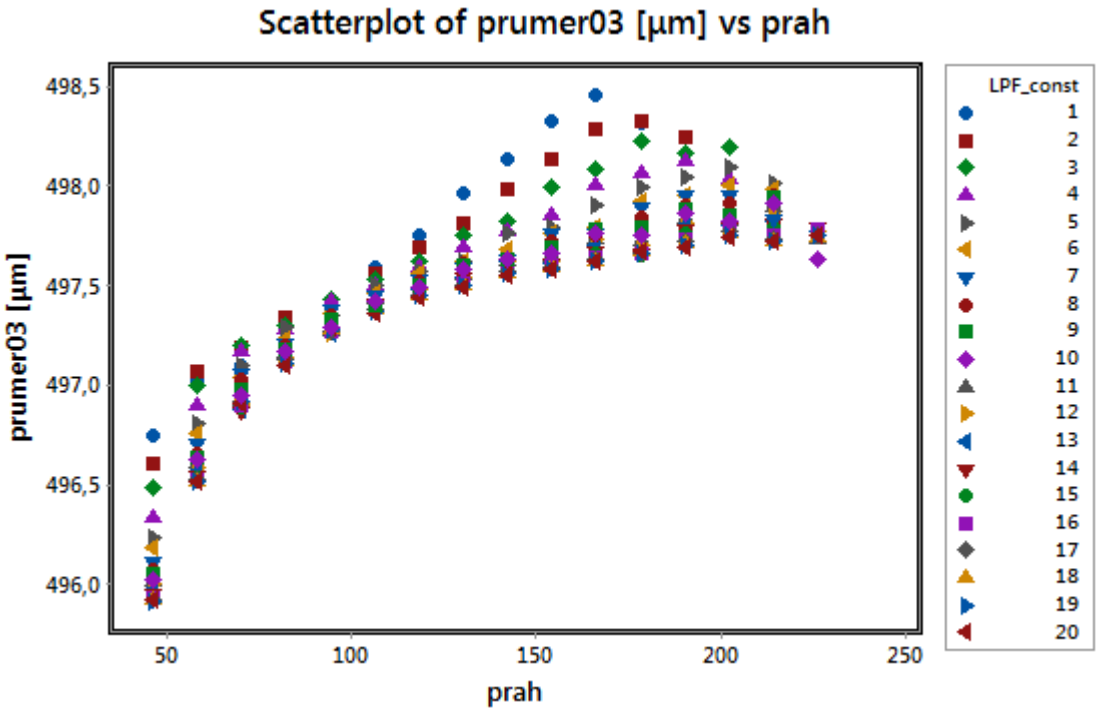

Obrázek A-03: Vytvořeno v programu Minitab 17.

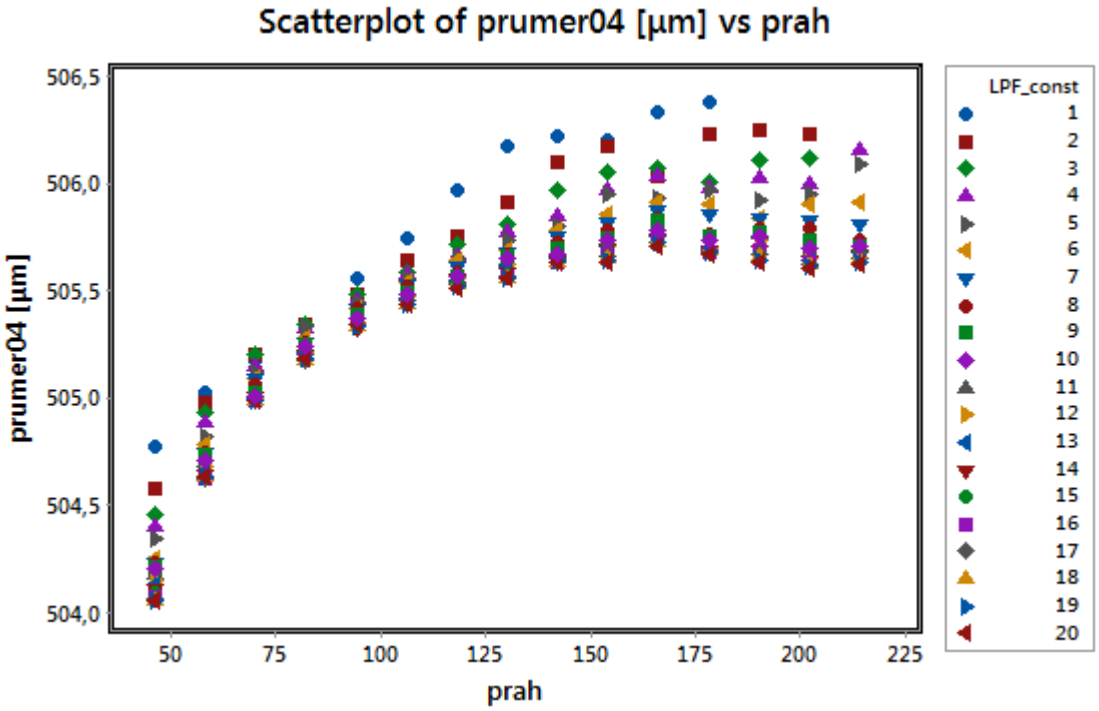

Obrázek A-04: Vytvořeno v programu Minitab 17.

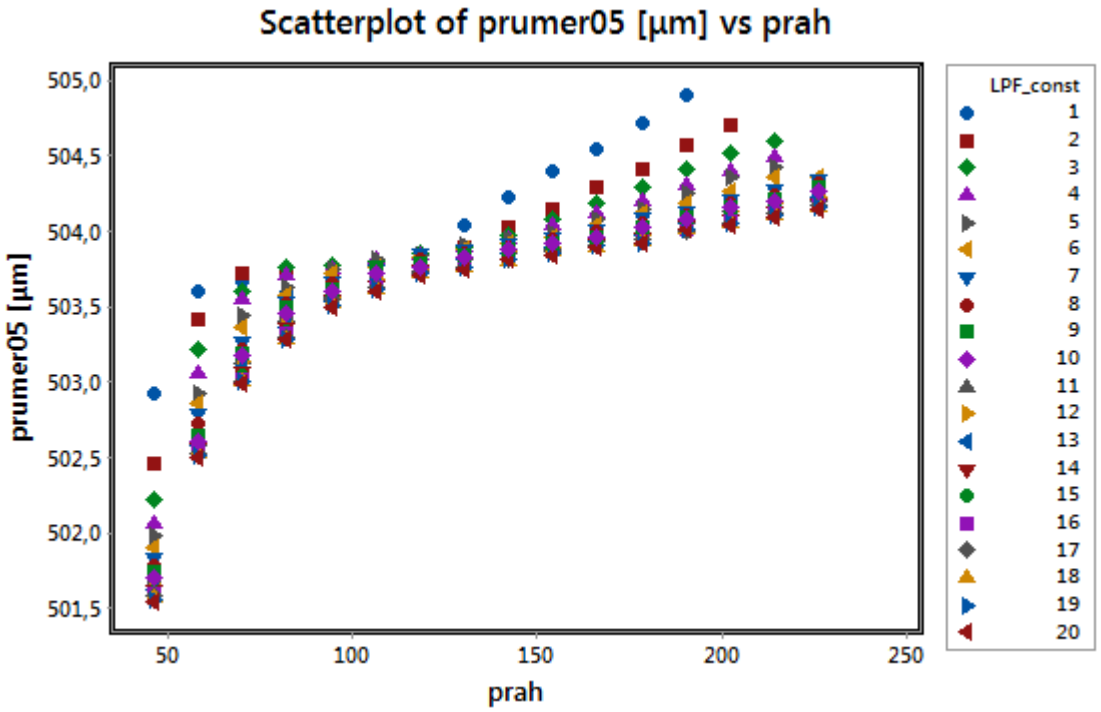

Obrázek A-05: Vytvořeno v programu Minitab 17.

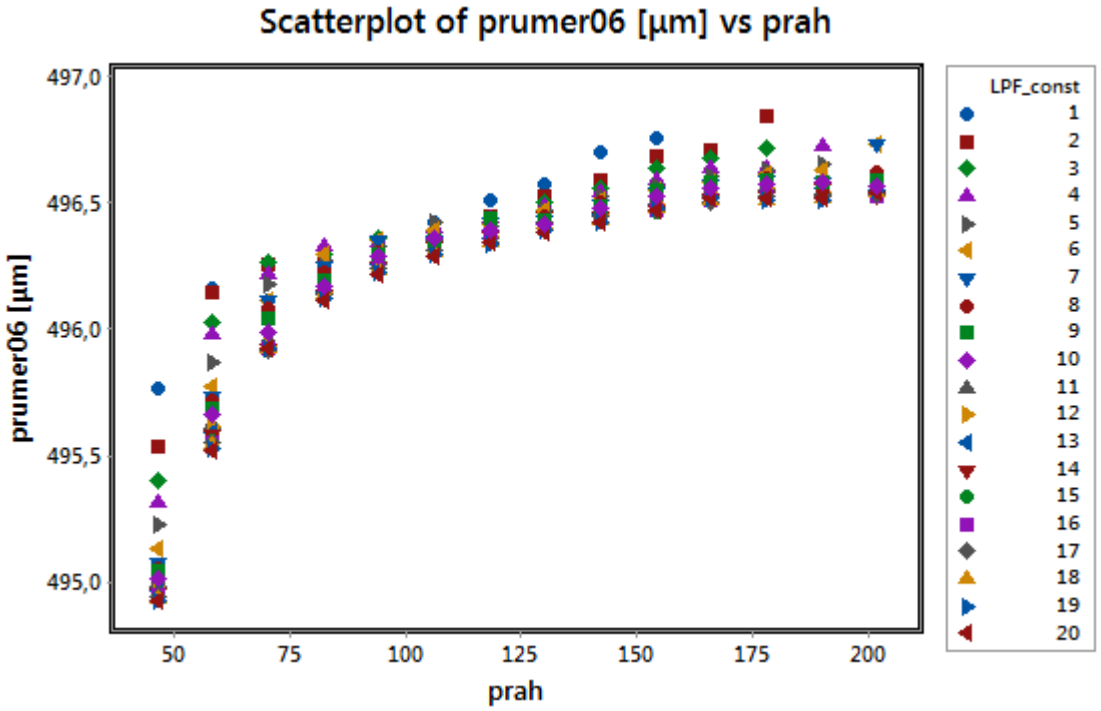

Obrázek A-06: Vytvořeno v programu Minitab 17.

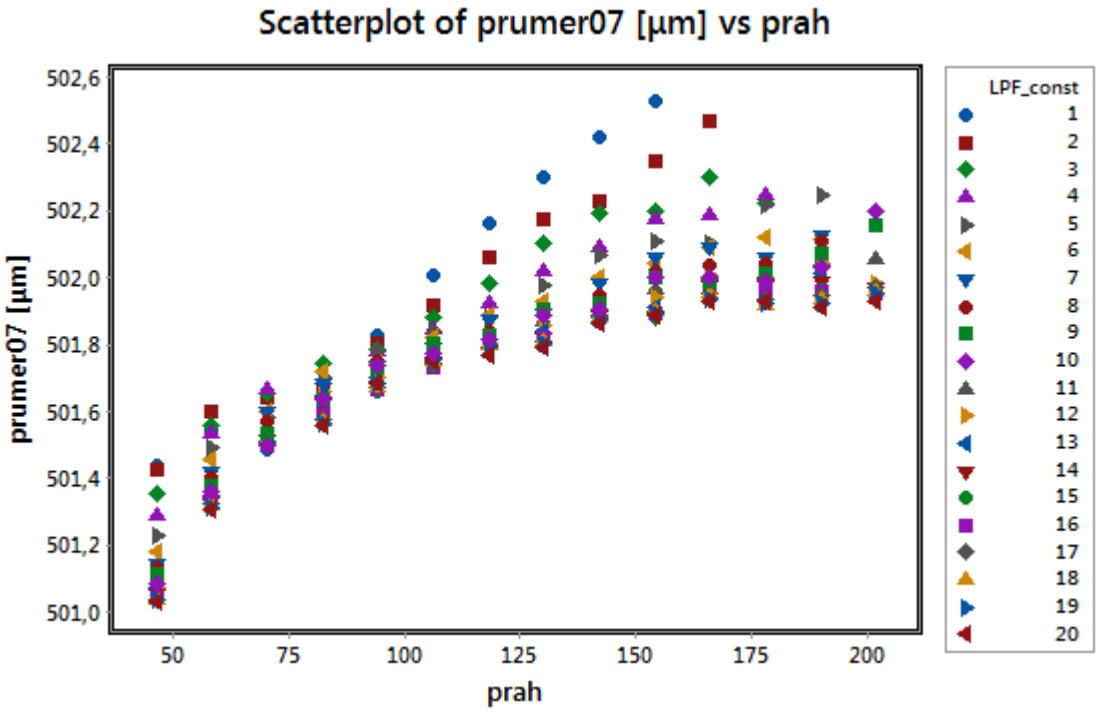

Obrázek A-07: Vytvořeno v programu Minitab 17.

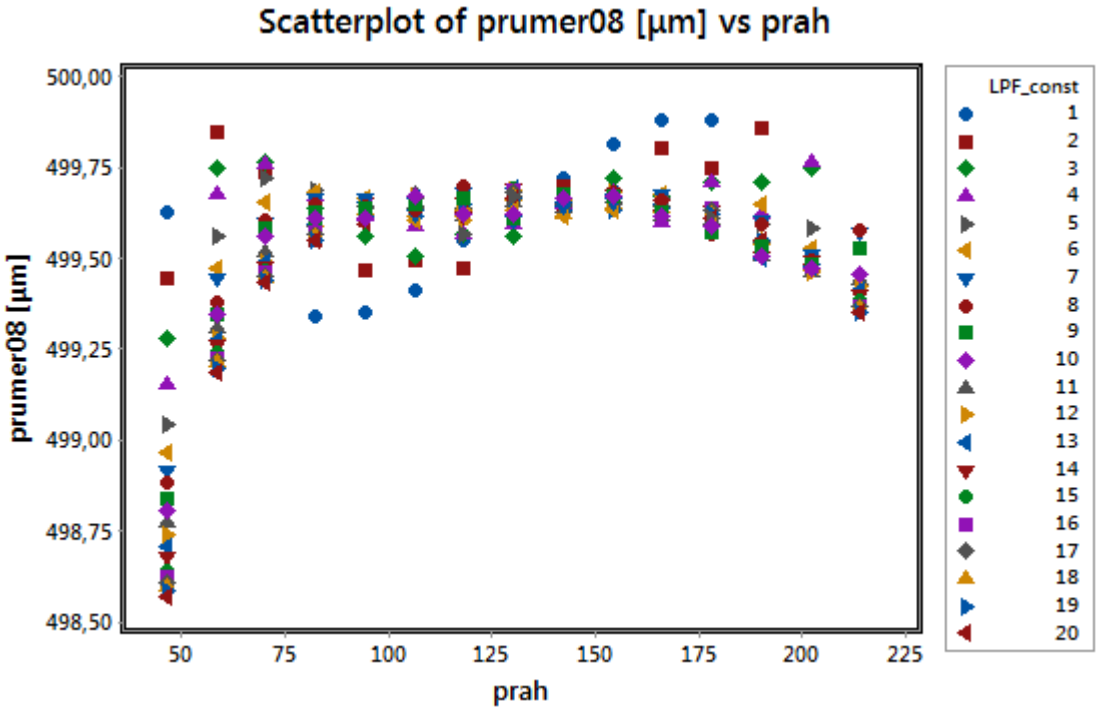

Obrázek A-08: Vytvořeno v programu Minitab 17.

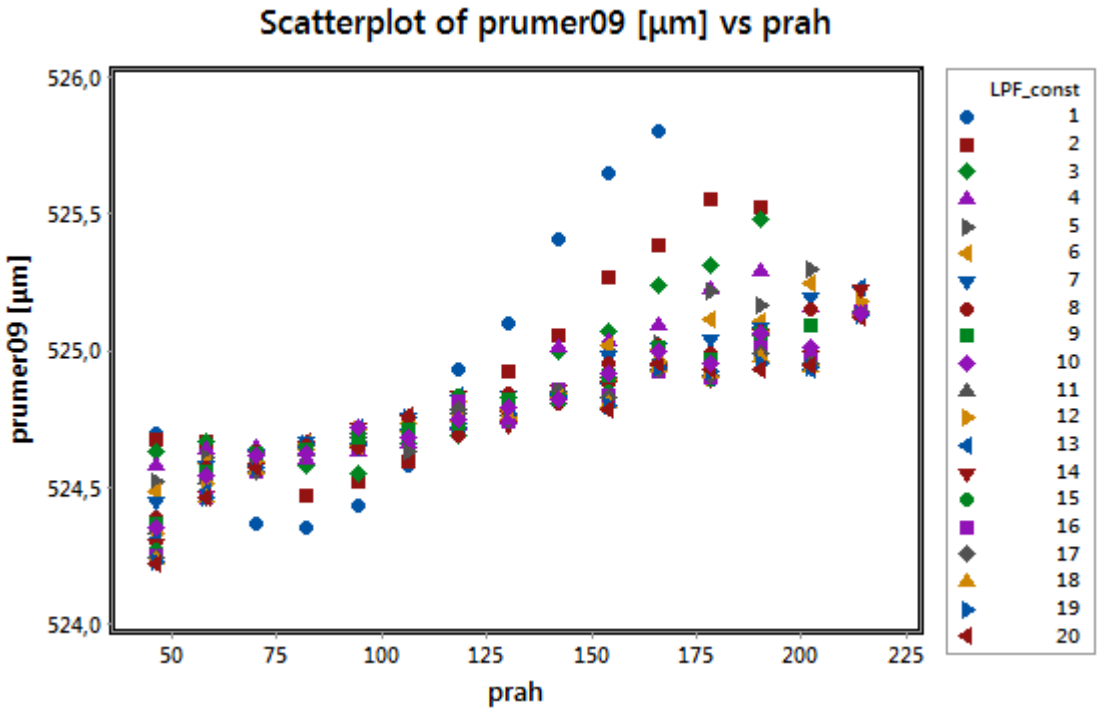

Obrázek A-09: Vytvořeno v programu Minitab 17.

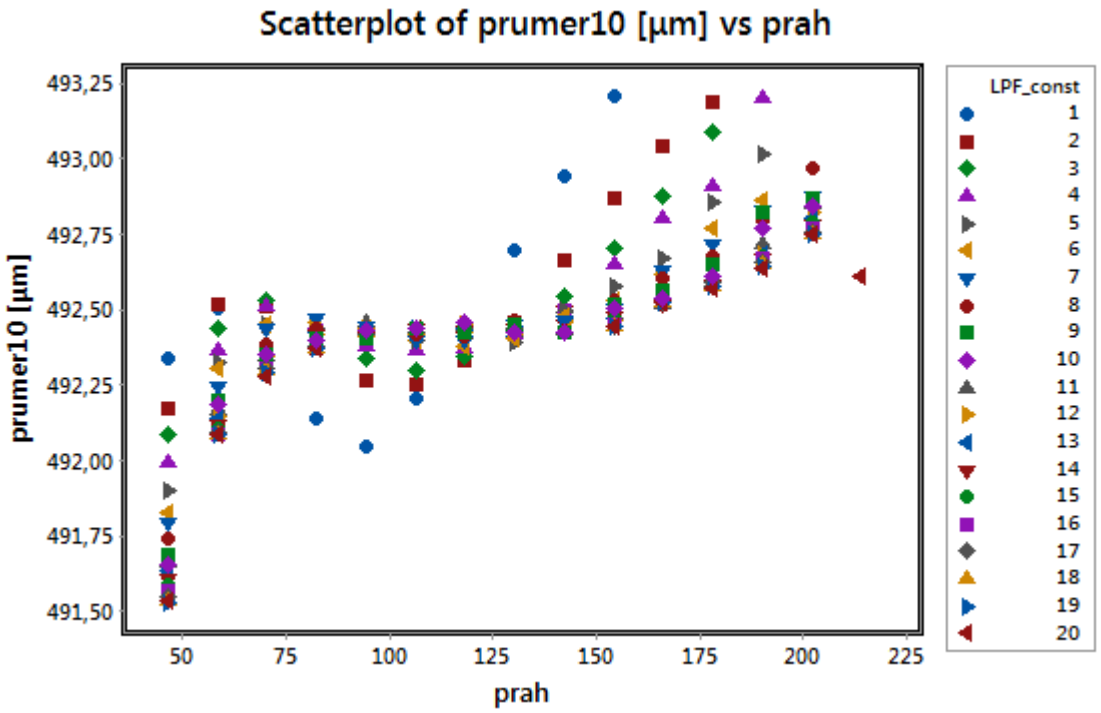

Obrázek A-10: Vytvořeno v programu Minitab 17.