



**ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE**

---

**Fakulta elektrotechnická  
Katedra radioelektroniky**

**Metody rekonstrukce obrazu pro prostorově variantní zobrazovací systémy**

**Image reconstruction methods for spatially variant imaging systems**

Diplomová práce

Studijní program: Komunikace, multimédia a elektronika  
Studijní obor: Multimediální technika

Vedoucí práce: Ing. Karel Fliegel, PhD.

**Tomáš Melechovský**

---

**Praha 2017**

České vysoké učení technické v Praze  
Fakulta elektrotechnická  
katedra radioelektroniky

## ZADÁNÍ DIPLOMOVÉ PRÁCE

Student: **Tomáš Melechovský**

Studijní program: Komunikace, multimédia a elektronika  
Obor: Multimediální technika

Název tématu: **Metody rekonstrukce obrazu pro prostorově variantní zobrazovací systémy**

Pokyny pro vypracování:

Podejte přehled metod rekonstrukce obrazu s prostorově variantním zkreslením. Realizujte model zobrazovacího systému s prostorově variantní bodovou rozptylovou funkcí. Vybrané metody rekonstrukce obrazu implementujte a ověřte jejich účinnost.

Seznam odborné literatury:

- [1] Gonzalez, R. C.: Digital image processing, Pearson, 2002.
- [2] Starck, J., Pantin, E., Murtagh, F.: Deconvolution in astronomy: A review, Publications of the Astronomical Society of the Pacific 114(800), 1051-1069, 2002.

Vedoucí: Ing. Karel Fliegel, Ph.D.

Platnost zadání: do konce letního semestru 2016/2017

L.S.

doc. Mgr. Petr Páta, Ph.D.  
vedoucí katedry

prof. Ing. Pavel Ripka, CSc.  
děkan

V Praze dne 19. 2. 2016

# Čestné prohlášení

Prohlašuji, že jsem předloženou práci vypracoval samostatně a že jsem uvedl veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze dne .....

.....

Tomáš Melechovský

# Poděkování

Na tomto místě bych rád poděkoval svému vedoucímu Ing. Karlu Fliegelovi, PhD. za pomoc při psaní práce a také za cenné rady a poznámky. Dále bych rád poděkoval všem blízkým za podporu během celé doby studia.

# Anotace

Tato diplomová práce se zabývá modelováním zkreslení prostorově variantním zobrazovacím systémem a následně rekonstrukcí takto zkresleného obrazu. Ke zkreslení a rekonstrukci jsou použity bodové rozptylové funkce vytvořené za pomoci Zernikových polynomů, kterými můžeme modelovat různé optické vady. V teoretické části je stručně popsána problematika prostorově variantních i invariantních zobrazovacích systémů, metoda SVOLA pro simulaci prostorově variantního zkreslení a také metody prostorově variantní dekonvoluce. Praktická část je věnována realizaci experimentu, ve kterém jsme nejprve simulovali prostorově variantní zkreslení a následně obrázek rekonstruovali pomocí vybraných algoritmů. Výsledkem je porovnání účinnosti těchto dekonvolučních algoritmů dle objektivních metrik.

## Klíčová slova

Prostorově variantní systém, odšumování, dekonvoluce, MATLAB, SVOLA, Zernikovy polynomy

## Abstract

This master's thesis deals with spatially variant imaging system modeling and subsequent reconstruction of this blurred image. Point spread functions used for blurring and reconstruction are created by using Zernike polynomials, which can model various optical aberrations. The theoretical part begins with a short problem description of spatially invariant and variant imaging systems. Afterwards the text describes SVOLA method for spatially variant blur simulation and also methods for spatially variant deconvolution (deblurring). The practical part is dedicated to our experiment, where spatially variant blur was simulated and then the image was reconstructed by using selected algorithms. As result, we have obtained performance comparison of these algorithms using objective measures.

## Keywords

Spatially variant system, deblurring, deconvolution, MATLAB, SVOLA, Zernike polynomials

# Obsah

Seznam symbolů.....	viii
Seznam zkratek.....	x
Seznam obrázků.....	xi
Seznam tabulek.....	xiv
1 Úvod .....	1
1.1 Struktura dokumentu .....	1
2 Lineární zobrazovací systémy .....	2
2.1 Bodová rozptylová funkce.....	2
2.2 Prostorově invariantní systémy .....	2
2.3 Prostorově variantní systémy.....	4
2.4 Modely šumu .....	5
2.4.1 Gaussovský šum .....	5
2.4.2 Impulzní šum .....	5
2.4.3 Uniformní šum.....	5
2.4.4 Šum s Poissonovým rozdělením.....	6
3 Simulace prostorově variantního systému.....	7
3.1 Simulace LSV systému metodou SVOLA .....	7
3.2 Zernikovy polynomy a modelování PSF .....	9
4 Metody dekonvoluce prostorově variantního zkraslení.....	13
4.1 Využití metody SVOLA.....	13
4.2 Dekonvoluční metody.....	14
4.3 Wienerova filtrace .....	14
4.4 Rekonstrukce pomocí regularizovaného filtru.....	15
4.5 Kepstrální dekonvoluce .....	16
4.6 Lucy-Richardsonův algoritmus .....	16
5 Ověření účinnosti dekonvolučních metod .....	18
5.1 Modelování degradace.....	18
5.2 Vyhodnocení kvality rekonstrukce.....	19

5.2.1	MSE/RMSE .....	19
5.2.2	PSNR.....	19
5.2.3	SSIM .....	20
5.2.4	MS-SSIM .....	20
5.2.5	FSIM .....	20
5.2.6	VIF .....	20
5.2.7	$S_3$ .....	21
5.2.8	Metrika Bjontegaardové.....	22
6	Simulace prostorově variantního zkreslení a dekonvoluce .....	23
6.1	Degradace obrazu.....	23
6.1.1	Výpočet PSF.....	23
6.1.2	Výpočet prostorově variantní konvoluce .....	24
6.1.3	Aditivní šum.....	26
6.2	Obnovení obrazu .....	28
6.2.1	Rekonstrukce obrazu s prostorově variantním zkreslením.....	28
6.3	Vyhodnocení .....	29
7	Analýza výsledků simulace.....	31
7.1	Wienerova filtrace.....	32
7.2	Rekonstrukce s regularizovaným filtrem .....	42
7.3	Lucy-Richardsonův algoritmus .....	49
7.4	Kepstrální dekonvoluce.....	55
7.5	Porovnání všech algoritmů.....	60
8	Závěr .....	67
9	Literatura .....	69
10	Přílohy .....	72
10.1	Příloha A - Obsah datového nosiče.....	72
10.2	Příloha B – Tabulky hodnot ke grafům z kapitoly 7.5 .....	73
10.3	Příloha C – vynechané grafy metrik PSNR, SSIM a $S_3$ .....	80

# Seznam symbolů

$A(u, v)$	Spektrum inverzního filtru
$a$	Velikost apertury
$a_i(x', y')$	Váhovací koeficient pro impulzové odezvy
$f$	Ohnisková vzdálenost
$h(x, y)$	Impulzová odezva, bodová rozptylová funkce
$H(u, v)$	Spektrum impulzové odezvy, (optická) přenosová funkce
$i(x, y)$	Zkreslený obrázek
$I(u, v)$	Spektrum zkresleného obrázku
$k_x, k_y$	Počet oblastí podél osy $x, y$
$l(x, y)$	Laplacův operátor
$L(u, v)$	Spektrum Laplacova operátoru
$\lambda$	Vlnová délka
$m, n$	Rozměry obrázku
$MSE$	Střední kvadratická chyba
$n(x, y)$	Aditivní šum
$N(u, v)$	Spektrum aditivního šumu
$N_{it}$	Počet iterací
$N_n^m$	Normalizační faktor
$N_{samp}$	Počet vzorků
$N_{zones}$	Celkový počet oblastí (PSF)
$NP$	Výkon šumu
$NSR$	Odstup šumu od signálu
$p(z)$	Hustota pravděpodobnosti
$psf_{samp}$	Vzorkování bodové rozptylové funkce
$R$	Matice s radiální souřadnicí



$R_n^{ m }$	Radiální polynom
$r_{norm}$	Normovaný poloměr
$R_{norm}$	Matice s normovanou radiální souřadnicí
$s(x, y)$	Snímaná scéna, originální obrázek
$S(u, v)$	Spektrum snímané scény
$SNR$	Odstup signálu od šumu
$\hat{s}(x, y)$	Odhad snímané scény
$\sigma$	Směrodatná odchylka
$W$	Vlnová funkce
$W_n^m$	Váhovací aberační koeficient
$Z_n^m$	Zernikeho polynom

# Seznam zkratek

FSIM	Feature Similarity
LSI	Linear Space Invariant
LSV	Linear Space Variant
MA	Moving Average
MSE	Mean Square Error
MS-SSIM	Multi-Scale Structural Similarity
NSR	Noise to Signal Ratio
PSF	Point Spread Function
PSNR	Peak Signal to Noise Ratio
RMSE	Root Mean Square Error
SeDDaRa	Self-Deconvolving Data Restoration Algorithm
SNR	Signal to Noise Ratio
SSIM	Structural Similarity
SVOLA	Spatially Variant Overlap Add
VIF	Visual Information Fidelity

# Seznam obrázků

Obr. 1 Model optického zobrazovacího systému (inspirováno v [14]).....	2
Obr. 2 Blokové schéma LSI systému.....	3
Obr. 3 Blokové schéma dekonvoluce LSI systému pomocí inverzní filtrace .....	3
Obr. 4 Blokové schéma prostorově variantního systému.....	4
Obr. 5 Ukázka modelů šumu, (a) gaussovský šum, (b) impulzní šum, (c) uniformní šum, (d) šum s Poissonovým rozdělením, (e), (f), (g), (h) histogramy příslušných modelů.....	6
Obr. 6 Blokové schéma výpočtu prostorově variantní konvoluce metodou SVOLA .....	8
Obr. 7 Ukázka masky, (a) maskovací okno $a_6$ , (b) průběh oken na jednom řádku.....	8
Obr. 8 Ukázka blokových artefaktů .....	9
Obr. 9 Zernikovy polynomy do 4. řádu.....	12
Obr. 10 PSF příslušných aberací modelovaných Zernikovými polynomy do 4. řádu .....	12
Obr. 11 Blokové schéma dekonvoluce za pomoci metody SVOLA .....	13
Obr. 12 Schéma provedení simulace LSV systému, rekonstrukce obrázku a následného vyhodnocení kvality rekonstrukce .....	18
Obr. 13 Použité testovací snímky, (a) baboon.tif, (b) kodim19.png, (c) kodim08.png, (d) kodim13.png .....	21
Obr. 14 Ukázka rozdílu při použití konvoluce a korelace, (a), (b) konvoluce, (c), (d) korelace .....	25
Obr. 15 Ukázka zkraslených testovacích obrázků (a) bez aditivního šumu, (b) s gaussovským šumem SNR = 21 dB, (c) s Poissonovým šumem SNR = 21,5 dB, (d) s gaussovským šumem SNR = 5 dB, (e) s impulzním šumem SNR = 5 dB.....	27
Obr. 16 Srovnání závislostí vybraných metrik na signálu .....	32
Obr. 17 Závislost metrik RMSE, PSNR, SSIM, MS-SSIM, FSIM, VIF a $S_3$ na SNR pro Wienerovu filtraci, (a), (c), (e), (g), (i), (k), (m) pro gaussovský bílý šum, (b), (d), (f), (h), (j), (l), (n) pro impulzní šum.....	34
Obr. 18 Ukázka artefaktů vznikajících při odhadu poměru NSR blízko hranice šumové katastrofy, (a), (b) nezkraslený obrázek a detaily, (c), (d) rekonstruovaný obrázek a detaily .....	35
Obr. 19 Závislost RMSE, PSNR, MS-SSIM, FSIM a VIF na poměru NSR pro Wienerovu filtraci, (a), (c), (e), (g), (i) pro gaussovský bílý šum, (b), (d), (f), (h), (j) pro impulzní šum.....	37
Obr. 20 Ukázka vlivu odhadu NSR, obrázek baboon.tif, impulzní šum se SNR=10 dB, (a) NSR=1e-6, (b) NSR=1, (c) NSR=0,1.....	37
Obr. 21 Závislost RMSE, PSNR, MS-SSIM, FSIM a VIF na počtu oblastí pro Wienerovu filtraci, (a), (c), (e), (g), (i) pro gaussovský bílý šum, (b), (d), (f), (h), (j) pro impulzní šum.....	39
Obr. 22 Ukázka vlivu počtu oblastí a rozmazání, obrázek baboon.tif, impulzní šum, (a) SNR=10 dB, $N_z=225$ , (b) SNR=10 dB, $N_z=4$ , (c) SNR=60 dB, $N_z=225$ , (d) SNR=60 dB, $N_z=4$ .....	40

Obr. 23 Závislost RMSE, MS-SSIM, FSIM a VIF pro Wienerovu filtraci, (a), (c), (e), (g) na poměru NSR, (b), (d), (f), (h) na počtu oblastí, obrázků s šumem s Poissonovým rozdělením .....	42
Obr. 24 Závislost RMSE, MS-SSIM, FSIM a VIF na SNR pro regularizovaný filtr, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum .....	43
Obr. 25 Srovnání potlačení šumu, (a) regularizovaný filtr, (b) Wienerova filtrace.....	44
Obr. 26 Závislost RMSE, MS-SSIM, FSIM a VIF na parametru NP pro regularizovaný filtr, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum .....	45
Obr. 27 Závislost RMSE, MS-SSIM, FSIM, VIF a S3 na počtu oblastí pro regularizovaný filtr, (a), (c), (e), (g), (i) pro gaussovský bílý šum, (b), (d), (f), (h), (j) pro impulzní šum .....	47
Obr. 28 Závislost RMSE, PSNR, SSIM, MS-SSIM, FSIM, VIF a S3 pro rekonstrukci s regularizovaným filtrem (a), (c), (e), (g), (i), (k), (m) na odhadu parametru NP, (b), (d), (f), (h), (j), (l), (n) na počtu oblastí, obrázků s šumem s Poissonovým rozdělením .....	48
Obr. 29 Závislost RMSE, MS-SSIM, FSIM a VIF na SNR u Lucy-Richardsonova algoritmu, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum .....	50
Obr. 30 Závislost RMSE, MS-SSIM, FSIM a VIF na počtu iterací u Lucy-Richardsonova algoritmu, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum .....	51
Obr. 31 Ukázka zesílení šumu, (a) zkraslený obrázek s impulzním šumem, SNR=30 dB, (b) rekonstruovaný obrázek s imp. šumem, (c) zkraslený obrázek s gaussovským šumem, SNR=21 dB, (d) rekonstruovaný obrázek s gauss. šumem .....	52
Obr. 32 Závislost RMSE, MS-SSIM, FSIM a VIF na počtu oblastí u Lucy-Richardsonova algoritmu, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum .....	54
Obr. 33 Závislost RMSE, MS-SSIM, FSIM a VIF pro Lucy-Richardsonův algoritmus, (a), (c), (e), (g) na počtu iterací (b), (d), (f), (h) na počtu oblastí, obrázků s šumem s Poissonovým rozdělením.....	55
Obr. 34 Závislost RMSE, MS-SSIM, FSIM a VIF na SNR u keprstrální dekonvoluce, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum .....	57
Obr. 35 Ukázka chyby při rekonstrukci geometrického zkraslení (a), (b) Wienerova filtrace a RMSE mapa, (c), (d) keprstrální dekonvoluce a RMSE mapa .....	58
Obr. 36 Závislost RMSE, MS-SSIM, FSIM, VIF a S3 na počtu oblastí u keprstrální dekonvoluce, (a), (c), (e), (g), (i) pro gaussovský bílý šum, (b), (d), (f), (h), (j) pro impulzní šum .....	59
Obr. 37 Závislost RMSE, PSNR, SSIM, MS-SSIM, FSIM, VIF a S3 na počtu oblastí pro keprstrální dekonvoluci .....	60
Obr. 38 Závislost RMSE, MS-SSIM, FSIM a VIF na SNR pro porovnání všech algoritmů, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum .....	62
Obr. 39 Závislost RMSE, MS-SSIM, FSIM a VIF na počtu oblastí pro porovnání všech algoritmů, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum.....	63
Obr. 40 Závislosti SSIM a S3 na poměru NSR pro Wienerovu filtraci, (a), (c) gaussovský bílý šum, (b), (d) impulzní šum.....	80

Obr. 41 Závislosti SSIM a S3 na počtu oblastí pro Wienerovu filtraci, (a), (c) gaussovský bílý šum, (b), (d) impulzní šum .....	81
Obr. 42 Závislosti PSNR, SSIM a S3 (a), (c), (e) na poměru NSR, (b), (d), (f) na počtu oblastí pro Wienerovu filtraci a Poissonův šum .....	82
Obr. 43 Závislosti PSNR, SSIM a S3 na poměru SNR pro rekonstrukci s regularizovaným filtrem, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum .....	83
Obr. 44 Závislosti PSNR, SSIM a S3 na odhadu šumu NP pro rekonstrukci s regularizovaným filtrem, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum .....	84
Obr. 45 Závislosti PSNR a SSIM na počtu oblastí pro rekonstrukci s regularizovaným filtrem, (a), (c) gaussovský bílý šum, (b), (d) impulzní šum .....	84
Obr. 46 Závislosti PSNR, SSIM a S3 (a), (c), (e) na odhadu šumu NP, (b), (d), (f) na počtu oblastí pro rekonstrukci s regularizovaným filtrem a Poissonův šum .....	85
Obr. 47 Závislosti PSNR, SSIM a S3 na poměru SNR pro Lucy-Richardsonův algoritmus, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum .....	86
Obr. 48 Závislosti PSNR, SSIM a S3 na počtu iterací pro Lucy-Richardsonův algoritmus, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum .....	87
Obr. 49 Závislosti PSNR, SSIM a S3 na počtu oblastí pro Lucy-Richardsonův algoritmus, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum .....	88
Obr. 50 Závislosti PSNR, SSIM a S3 (a), (c), (e) na počtu iterací, (b), (d), (f) na počtu oblastí pro Lucy-Richardsonův algoritmus a Poissonův šum .....	89
Obr. 51 Závislosti PSNR, SSIM a S3 na poměru SNR pro keprální dekonvoluci, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum .....	90
Obr. 52 Závislosti PSNR a SSIM na počtu oblastí pro keprální dekonvoluci, (a), (c) gaussovský bílý šum, (b), (d) impulzní šum .....	91
Obr. 53 Závislosti PSNR, SSIM a S3 na počtu oblastí pro keprální dekonvoluci a Poissonův šum .....	92
Obr. 54 Závislost PSNR, SSIM a S3 na SNR pro porovnání všech algoritmů, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum .....	93
Obr. 55 Závislost PSNR, SSIM a S3 na počtu oblastí pro porovnání všech algoritmů, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum .....	94

# Seznam tabulek

Tab. 1 Seznam Zernikových polynomů do 4. řádu (převzato z [18]).....	10
Tab. 2 Závislost Zernikových polynomů v prostoru (převzato z [18]).....	11
Tab. 3 Hodnoty pro šum s Poissonovým rozdělením při keprální dekonvoluci .....	60
Tab. 4 Tabulka porovnání závislostí na SNR za pomoci metriky Bjontegaardové .....	64
Tab. 5 Tabulka porovnání závislostí na počtu oblastí za pomoci metriky Bjontegaardové .....	65
Tab. 6 Výpočetní náročnost algoritmů .....	66
Tab. 7 Hodnoty závislosti RMSE na SNR pro porovnání všech algoritmů .....	73
Tab. 8 Hodnoty závislosti RMSE na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB .....	73
Tab. 9 Hodnoty závislosti PSNR na SNR pro porovnání všech algoritmů .....	74
Tab. 10 Hodnoty závislosti PSNR na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB .....	74
Tab. 11 Hodnoty závislosti SSIM na SNR pro porovnání všech algoritmů .....	75
Tab. 12 Hodnoty závislosti SSIM na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB .....	75
Tab. 13 Hodnoty závislosti MSSSIM na SNR pro porovnání všech algoritmů .....	76
Tab. 14 Hodnoty závislosti MSSSIM na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB .....	76
Tab. 15 Hodnoty závislosti FSIM na SNR pro porovnání všech algoritmů .....	77
Tab. 16 Hodnoty závislosti FSIM na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB .....	77
Tab. 17 Hodnoty závislosti VIF na SNR pro porovnání všech algoritmů .....	78
Tab. 18 Hodnoty závislosti VIF na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB .....	78
Tab. 19 Hodnoty závislosti S3 na SNR pro porovnání všech algoritmů .....	79
Tab. 20 Hodnoty závislosti S3 na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB .....	79

# 1 Úvod

Jedním z cílů rekonstrukce obrazu je zlepšení zrakového vjemu člověka při pohledu na snímek. Toho lze dosáhnout různými metodami doostřování či odšumování obrázku. Jednou z významných složek zkreslení je tzv. konvoluční zkreslení, které je způsobené průchodem signálu soustavou. Soustavou rozumíme například objektiv fotoaparátu, či třeba i vrstvu atmosféry mezi snímaným objektem a samotným zařízením. Tato složka má zpravidla charakter filtru typu dolní propust, kde tedy dochází k potlačení vyšších prostorových kmitočtů. Tyto kmitočty reprezentují v obraze ostré hrany a detaily. Jejich potlačením vzniká rozostření obrázku. Proto provádíme tzv. dekonvoluci, kde se snažíme odstranit právě tuto složku zkreslení, obrázek doostřit a získat tím takový obrázek, na kterém budou snímané objekty zobrazeny tak, aby byly co nejvíc podobné realitě.

V této práci se zabýváme lineárními prostorově variantními systémy. Tyto systémy jsou popsány takovou bodovou rozptylovou funkcí, která se mění dle souřadnic obrazu. Tím se odlišují od prostorově invariantních systémů, kde pro všechny body můžeme použít stejnou bodovou rozptylovou funkci.

Modelování lineárních prostorově variantních systémů je dalším krokem přiblížení ke skutečnému modelu reálného systému, jelikož v různých případech je použití prostorově invariantních systému nepřesné a nepřináší dostatečně kvalitní výsledky. Typickým příkladem jsou snímky při použití širokouhlých objektivů, kde dochází zejména na okrajích k většímu rozmazání z důvodu odlišné bodové rozptylové funkce vůči středu snímku.

## 1.1 Struktura dokumentu

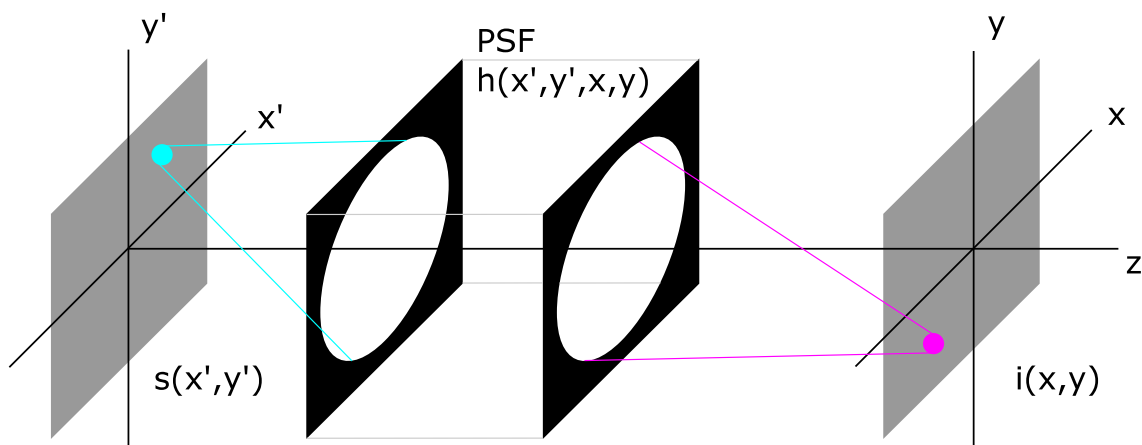
Obecný popis lineárních zobrazovacích systémů je uveden v kapitole 2. V kapitole 3 je pak popsána metoda simulace lineárního prostorově variantního zobrazovacího systému a také modelování bodových rozptylových funkcí pomocí Zernikových polynomů. S metodami dekonvoluce takto degradovaného obrázku se seznámíme v kapitole 4. Kapitoly 5 a 6 jsou pak věnovány vlastnímu experimentu, tedy simulace prostorově variantního systému a následné dekonvoluce, a konkrétní realizaci. Výsledky experimentu jsou prezentovány v kapitole 7.

## 2 Lineární zobrazovací systémy

V této kapitole a jejích pododdílech bylo čerpáno především z literatury [1], doplňující poznatky zejména pro prostorově variantní systémy pak vychází z literatury [8], [9], [14], [18]. Kapitola podává základní informace o lineárních zobrazovacích systémech. Lineární systémy jsou takové systémy, kde platí princip superpozice. Vlastnosti tohoto systému jsou pak popsány bodovou rozptylovou funkcí  $h(x, y)$  pro prostorově invariantní systémy, resp.  $h(x', y', x, y)$  pro prostorově variantní.

### 2.1 Bodová rozptylová funkce

Při snímání obrazu zobrazovacím systémem dochází k projekci z roviny scény do roviny obrazu. Bodová rozptylová funkce (PSF – point spread function) je odezvou tohoto systému na dvourozměrný Diracův impuls. Vyjadřuje tedy, jak daný systém rozptýlí každý bod z roviny scény v rovině obrazu. V reálném systému je pak PSF ovlivněna také důsledkem průchodu světla atmosférou, vzájemného pohybu objektů a snímače a optiky zařízení.



Obr. 1 Model optického zobrazovacího systému (inspirováno v [14])

Na obrázku výše máme model optického zobrazovacího systému. Ten je reprezentován „black boxem“ uprostřed a jeho PSF zahrnuje všechny výše popsaná zkreslení. V levé části je rovina scény, kde se nachází objekt. Obraz se vytváří po průchodu systémem v pravé části obrázku v obrazové rovině.

### 2.2 Prostorově invariantní systémy


U lineárních prostorově invariantních systémů (LSI – linear space-invariant) lze vyjádřit obrázek jako konvoluci skutečné scény a bodové rozptylové funkce, případně jako součin Fourierových obrazů těchto funkcí v oblasti prostorových kmitočtů (viz následující vztahy):



$$i(x, y) = s(x, y) * h(x, y) \quad (2-1)$$

$$i(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} s(x', y') \cdot h(x - x', y - y') dx' dy' \quad (2-2)$$

$$I(u, v) = S(u, v) \cdot H(u, v) \quad (2-3)$$




Obr. 2 Blokové schéma LSI systému

Dle těchto vztahů je dekonvoluce vstupního obrazu  $s(x, y)$  velmi jednoduchá a na první pohled zřejmá. Tato metoda se nazývá inverzní filtrace a funguje skvěle na obraz, který není zatížen aditivním šumem ( $N(u, v) = 0$ ).

$$A(u, v) = \frac{1}{H(u, v)} \quad (2-4)$$

$$S(u, v) = I(u, v) \cdot A(u, v) \quad (2-5)$$



Obr. 3 Blokové schéma dekonvoluce LSI systému pomocí inverzní filtrace

Jelikož bodová rozptylová funkce má charakter filtru typu dolní propust, inverzní filtr je tedy horní propustí. A právě na vyšších kmitočtech je šum dominantní, což po filtraci horní propustí ještě zvýrazníme. Zejména, když  $H(u, v)$  se blíží na vysokých kmitočtech k nule, inverzní filtr  $A(u, v)$  jde tedy limitně k nekonečnu. Tomuto jevu se říká šumová katastrofa.

$$i(x, y) = s(x, y) * h(x, y) + n(x, y) \quad (2-6)$$

$$I(u, v) = S(u, v) \cdot H(u, v) + N(u, v) \quad (2-7)$$

$$\hat{S}(u, v) = I(u, v) \cdot A(u, v) + N(u, v) \cdot A(u, v) \quad (2-8)$$

Problém šumové katastrofy lze řešit různými způsoby. Jedním z nich je například použití Wienerova filtru (dále v kapitole 4.2).


### 2.3 Prostorově variantní systémy

Lineární prostorově variantní systém (LSV – linear space-variant) má proměnlivou PSF v závislosti na pozici obrazových bodů. U LSV systémů nelze využít konvoluční teorém, tedy součin Fourierových obrazů, tím se situace komplikuje a musíme konvoluci řešit v obrazovém prostoru.

$$i(x, y) = s(x, y) * h(x, y) \quad (2-9)$$

$$i(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} s(x', y') \cdot h(x - x', y - y', x', y') dx' dy' \quad (2-10)$$

Souřadnice výstupního obrázku jsou  $\{x, y\}$ , zatímco souřadnice vstupního obrázku jsou  $\{x', y'\}$ . PSF systému se mění podle souřadnic v původním obrázku  $\{x', y'\}$ . Realizace či dekonvoluce takového obrázku je možná, ale kvůli proměnné PSF je velmi náročná na výpočet.



Obr. 4 Blokové schéma prostorově variantního systému

Prostorová variabilita systému je v reálném prostředí způsobena například rozdílnou teplotou vzduchu a turbulencemi v atmosféře, optickými vadami objektivu nebo rotačním pohybem objektu nebo snímače během expozice snímku.

## 2.4 Modely šumu

Šum v obraze vzniká zejména při snímání a přenosu obrazu. Při snímání dochází k zašumění obrazu například vlivem vlastního snímače, teploty snímače či úrovně osvětlení. K dalšímu zašumění může dojít při přenosu obrazu rušením v přenosovém kanále. [1]

Rozlišujeme prostorové a frekvenční vlastnosti šumu. U prostorových vlastností také mimo jiné to, jestli je šum signálově závislý. U frekvenčních vlastností pak zastoupení složek ve frekvenčním spektru. Například šum s konstantním spektrem přes všechny frekvence nazýváme *bílý šum*. [1]

Dále se podíváme na základní modely šumu. Jejich ukázkou a histogram, který možná ještě lépe popisuje rozdíl a vlastnosti daných modelů, můžeme sledovat na Obr. 5. Existují i jiné modely šumu, například Rayleighův šum nebo gamma šum. Více o těchto modelech v literatuře [1].

### 2.4.1 Gaussovský šum

Gaussovský šum je nejčastěji používaným modelem šumu. Je způsoben šumem elektroniky či šumem snímače při špatném osvětlení nebo vysoké teplotě. Hustota pravděpodobnosti Gaussovského šumu je:

$$p(z) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(z-\bar{z})^2}{2\sigma^2}}, \quad (2-11)$$

kde  $z$  je intenzita,  $\bar{z}$  je střední hodnota  $z$  a  $\sigma$  je směrodatná odchylka  $z$ . [1]

### 2.4.2 Impulzní šum

Obraz je rušený krátkými, ale silnými impulzy. Impulzy mohou být kladné či záporné, což má za následek zvýšení nebo snížení jasu v obrázku. Jelikož jsou impulzy většinou mnohem silnější, než samotný obrazový signál, zpravidla předpokládáme extrémní hodnoty u těchto impulzů, tedy bílou a černou barvu. V 8-mi bitovém obrázku tomu odpovídají hodnoty 255 a 0. Hustota pravděpodobnosti impulzního šumu je definována takto:

$$p(z) = \begin{cases} P_a & \text{pro } z = a \\ P_b & \text{pro } z = b. \\ 0 & \text{jinde} \end{cases} \quad (2-12)$$

Pro podmínku  $b > a$ , pak intenzita  $b$  bude světlý bod a intenzita  $a$  tmavý. Pokud  $P_a$  nebo  $P_b$  bude rovno nule, bude šum unipolární, tedy pouze světlé nebo pouze tmavé body. [1]

### 2.4.3 Uniformní šum

Uniformní šum, také někdy příhodně nazývaný jako kvantizační, vzniká například právě při kvantizaci obrázku. Tento model šumu nejméně odpovídá reálným šumům. Je typický svojí hustotou pravděpodobnosti, která je rovnoměrná. [1]

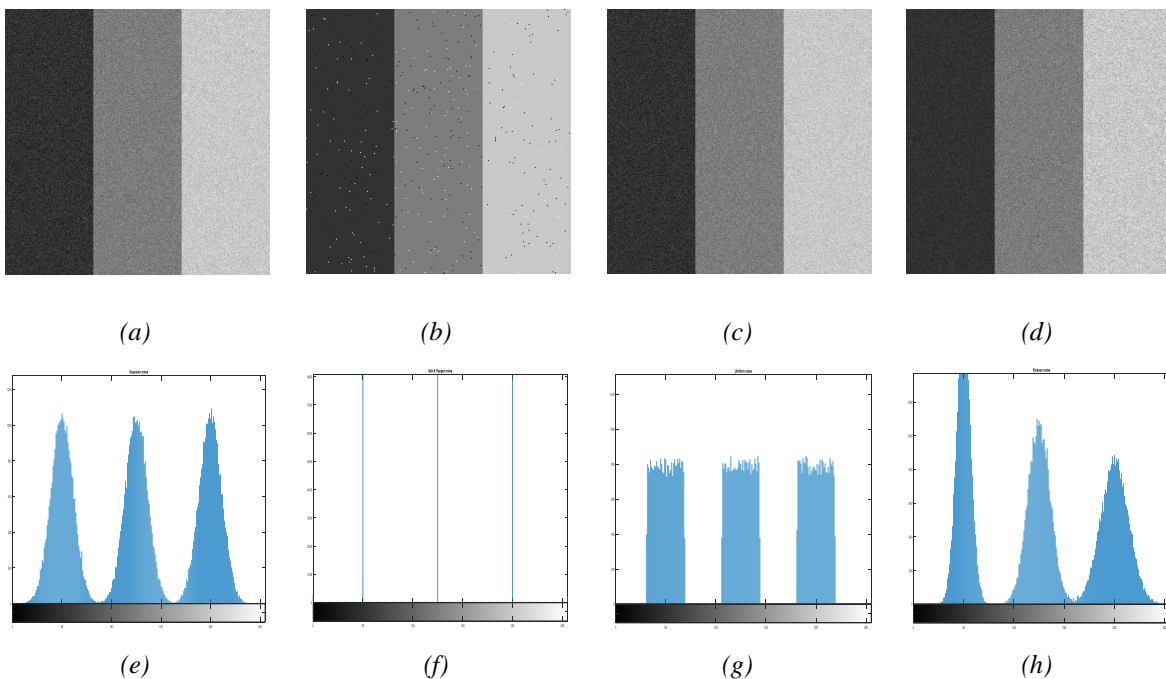
$$p(z) = \begin{cases} \frac{1}{b-a} & a \leq z \leq b \\ 0 & \text{jinde} \end{cases} \quad (2-13)$$

#### 2.4.4 Šum s Poissonovým rozdělením

Tento šum je způsoben fotony, které dopadají na snímač. Díky tomu se šumu také říká fotonový šum nebo snímkový šum (z angl. shot noise). Počet šumových fotonů závisí na počtu dopadajících fotonů, a to v poměru  $\sqrt{N}$ . Tento vztah můžeme přenést i na intenzitu v obrázku. Znamená to, že šum je signálově závislý. Jak název napovídá, tento šum má pravděpodobnostní funkci danou Poissonovým rozdělením:

$$p(z) = \frac{\lambda^z}{z!} e^{-\lambda}, \quad (2-14)$$

kde  $\lambda$  je parametr Poissonova rozdělení. [28]



Obr. 5 Ukázka modelů šumu, (a) gaussovský šum, (b) impulzní šum, (c) uniformní šum, (d) šum s Poissonovým rozdělením, (e), (f), (g), (h) histogramy příslušných modelů

## 3 Simulace prostorově variantního systému

V této kapitole je popsána metoda SVOLA (spatially-variant overlap-add; sčítání přesahů) pro simulaci prostorově variantního systému a modelování PSF pomocí Zernikových polynomů. Zernikovými polynomy lze modelovat vlnoplochu světla, která je ovlivněná optickými vadami soustavy, kterou světlo prochází. V kapitole bylo čerpáno zejména z literatury [3], [4], [6], [8], [9]. V pododdílu, který se věnuje modelování PSF Zernikovými polynomy, bylo čerpáno z literatury [14], [15], [17], [18].

### 3.1 Simulace LSV systému metodou SVOLA

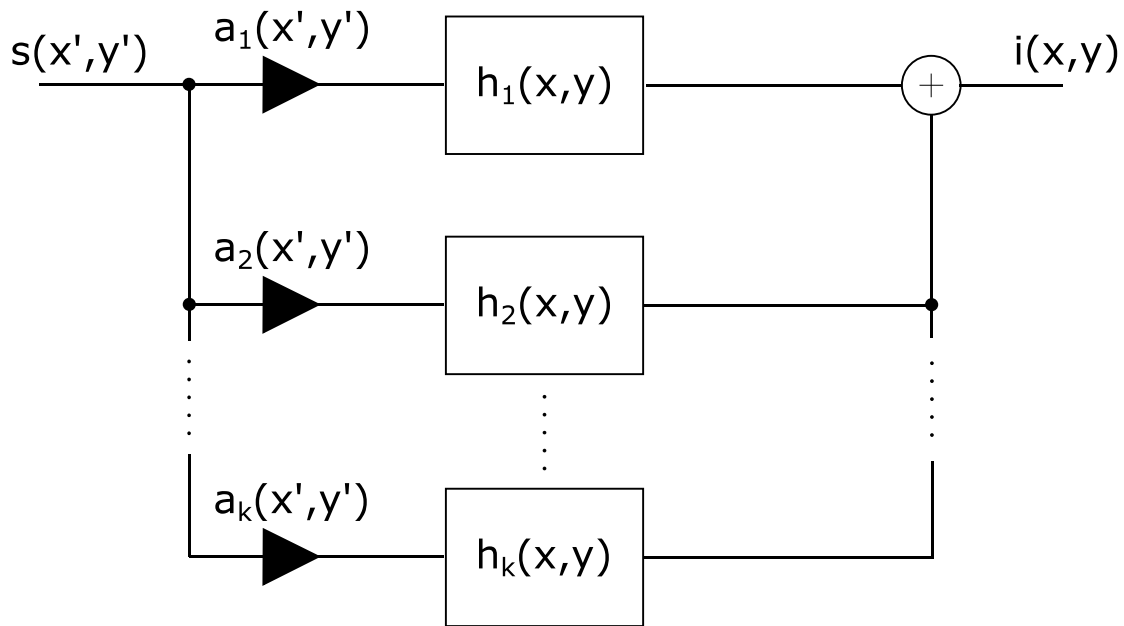
Prostorově variantní zkreslení lze aplikovat za pomoci výše uvedeného vztahu (2-10). Tento výpočet je však náročný a vyžaduje znalost PSF v každém bodě obrázku. Lze ale předpokládat, že dva body ležící vedle sebe budou mít PSF velmi podobnou. Díky tomuto předpokladu pak můžeme vytvořit v obrázku oblasti, kde budeme považovat PSF za prostorově invariantní a kde tedy můžeme použít standardní vztah pro konvoluci (2-2) či využít konvoluční teorém (2-3). Tato metoda výpočtu se nazývá SVOLA a je nejčastěji používanou metodou pro modelování prostorově variantních systémů. Nevýhodou této metody je vznik blokových artefaktů na rozhraní dvou oblastí s odlišnou PSF (viz Obr. 8).[3], [6] Tento artefakt je možné potlačit použitím jiného než pravoúhlého okénka. Prostorově variantní bodovou rozptylovou funkci vytvoříme váhovanou lineární kombinací bázových PSF. Můžeme tedy napsat že:

$$h(x', y', x, y) = \sum_{i=1}^{\infty} a_i(x', y') \cdot h_i(x, y), \quad (3-1)$$

kde  $h_i$  jsou ortogonální báze PSF a  $a_i$  je váhovací funkce, která popisuje prostorovou variabilitu PSF. Tento vztah můžeme dosadit do vztahu pro konvoluci (2-10):

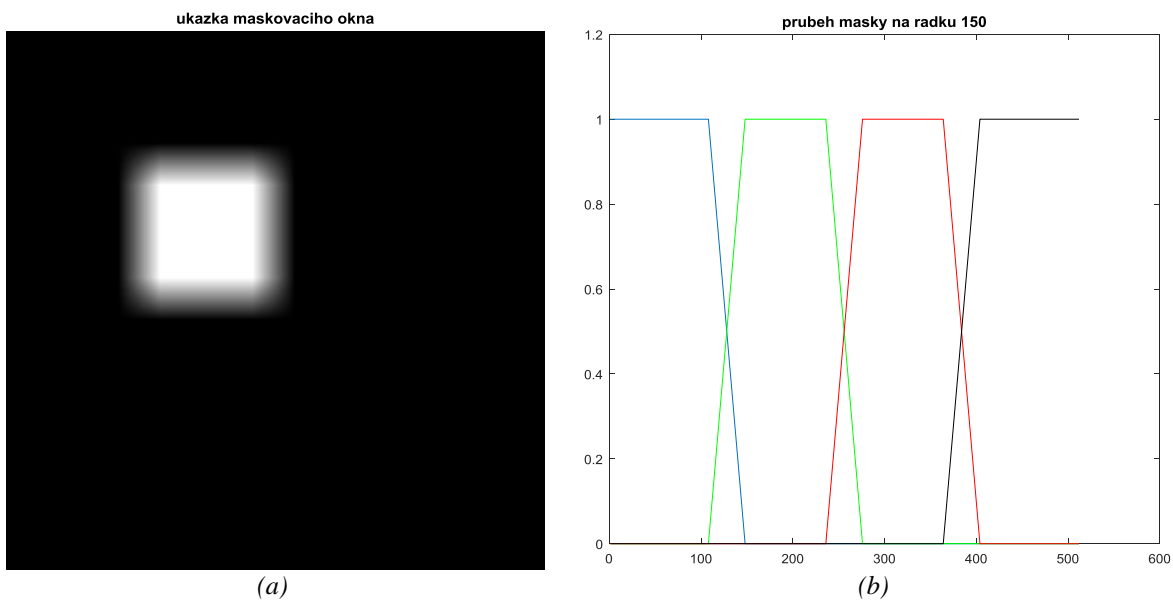
$$i(x, y) = \sum_{i=1}^{\infty} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} s(x', y') \cdot a_i(x', y') \cdot h_i(x - x', y - y') dx' dy', \quad (3-2)$$

kde si lze všimnout, že výsledný obrazový bod je součtem konvolucí jednotlivých bázových PSF s váhovaným původním obrazem. Výhodou tohoto přístupu je možnost využití konvolučního teorému a tedy výpočtu v oblasti prostorových kmitočtů. [4], [8], [9]



Obr. 6 Blokové schéma výpočtu prostorově variantní konvoluce metodou SVOLA

Pokud bychom takto chtěli vypočítat prostorově variantní zkreslení, musíme zajistit dostatečný počet oblastí tak, aby změna PSF nebyla mezi těmito oblastmi extrémně veliká. V takovém případě by v oblasti překryvu oken došlo k rozmazání a znehodnocení obrázku. Tuto situaci lze vyřešit zvětšením počtu oblastí (tím pádem snížení jejich velikosti) a interpolací PSF, pokud uvažujeme, že v daném systému se PSF mění spojitě a po úsecích lineárně.



Obr. 7 Ukázka masky, (a) maskovací okno  $a_6$ , (b) průběh oken na jednom řádku



Obr. 8 Ukázka blokových artefaktů

Pro simulaci prostorově variantního systému je zapotřebí prostorově variantní PSF. Tu můžeme získat například měřením konkrétního systému nebo výpočtem modelu degračního procesu. Pro modelování optických vad pak lze použít například funkce jako Seidelovy či Zernikovy polynomy. [14]

### 3.2 Zernikovy polynomy a modelování PSF

Zernikovy polynomy jsou sadou funkcí, které jsou ortogonální na jednotkové kružnici. Jsou pojmenovány po holandském fyzikovi Frederikovi Zernike, který získal v roce 1953 Nobelovu cenu za fyziku díky vynálezu a konstrukci fázově kontrastního mikroskopu. [30] Zernikovy polynomy jsou skvělým nástrojem pro velmi přesný popis vlnových aberací či analýzu dat. Jsou tvořeny normalizačním faktorem  $N_n^m$ , radiálním polynomem  $R_n^{|m|}(\rho)$  a azimutální částí, kde  $\theta$  nabývá hodnot  $\langle 0, 2\pi \rangle$ .

$$Z_n^m(\rho, \theta) = \begin{cases} N_n^m \cdot R_n^{|m|}(\rho) \cdot \cos(m\theta), & \text{pro } m \geq 0 \\ -N_n^m \cdot R_n^{|m|}(\rho) \cdot \sin(m\theta), & \text{pro } m < 0 \end{cases} \quad (3-3)$$

Pro dané  $n$  může  $m$  nabývat hodnot  $\langle -n, -n + 2, -n + 4, \dots, n \rangle$ . Zernikovy polynomy mohou být označeny jediným indexem  $j$ , ze kterého pak lze zpětně dopočítat indexy  $n, m$ .

$$j = \frac{n(n+2) + m}{2} \quad (3-4)$$

$$n = \text{round} \left[ \frac{-3 + \sqrt{9 + 8j}}{2} \right] \quad (3-5)$$

$$m = 2j - n(n+2) \quad (3-6)$$

Normalizační faktor vypočítáme dle vztahu

$$N_n^m = \sqrt{\frac{2(n+1)}{1+\delta_{m0}}}, \quad (3-7)$$

kde Kroneckerovo delta  $\delta_{m0} = 0$ , pro  $m \neq 0$  a  $\delta_{m0} = 1$ , pro  $m = 0$ . Pro výpočet radiálního polynomu pak použijeme následující rovnici:

$$R_n^{|m|}(\rho) = \sum_{s=0}^{\frac{n-|m|}{2}} \frac{(-1)^s (n-s)!}{s! \left(\frac{n+|m|}{2} - s\right)! \left(\frac{n-|m|}{2} - s\right)!} \rho^{n-2s}. \quad (3-8)$$

Aberaci vlnoplochy pak lze popsat pomocí Zernikových polynomů funkcí:

$$W(\rho, \theta) = \sum_n^k \sum_{m=-n}^n W_n^m Z_n^m(\rho, \theta), \quad (3-9)$$

kde  $k$  je maximální řád Zernikových polynomů a  $W_n^m$  je váhovací koeficient jednotlivých Zernikových polynomů, který odpovídá RMSE vlnoplochy. Zernikovy polynomy do 4. řádu nalezneme v následující tabulce:

Tab. 1 Seznam Zernikových polynomů do 4. řádu (převzato z [18])

$j$	$n$	$m$	$Z_j$	Název
0	0	0	1	Píst
1	1	-1	$2\rho \sin(\theta)$	Náklon vertikální
2	1	1	$2\rho \cos(\theta)$	Náklon horizontální
3	2	-2	$\sqrt{6}\rho^2 \sin(2\theta)$	Astigmatismus šikmý
4	2	0	$\sqrt{3}(2\rho^2 - 1)$	Defokus
5	2	2	$\sqrt{6}\rho^2 \cos(2\theta)$	Astigmatismus vertikální
6	3	-3	$2\sqrt{2}\rho^3 \sin(3\theta)$	Trefoil vertikální
7	3	-1	$2\sqrt{2}\rho \sin(\theta)(3\rho^2 - 2)$	Koma vertikální
8	3	1	$2\sqrt{2}\rho \cos(\theta)(3\rho^2 - 2)$	Koma horizontální
9	3	3	$2\sqrt{2}\rho^3 \cos(3\theta)$	Trefoil horizontální
10	4	-4	$\sqrt{10}\rho^4 \sin(4\theta)$	Tetrafoil šikmý
11	4	-2	$\sqrt{10}\rho^2 \sin(2\theta)(4\rho^2 - 3)$	Sekundární astigmatismus šikmý
12	4	0	$\sqrt{5}(6\rho^4 - 6\rho^2 + 1)$	Sférická vada
13	4	2	$\sqrt{10}\rho^2 \cos(2\theta)(4\rho^2 - 3)$	Sekundární astigmatismus vertikální
14	4	4	$\sqrt{10}\rho^4 \cos(4\theta)$	Tetrafoil vertikální



Pro modelování průchodu signálu danou soustavou však potřebujeme znát bodovou rozptylovou funkci. Tu získáme za pomoci Fourierovy transformace modelované vlnoplochy:

$$PSF(x, y) = \left| FT \left\{ p(x, y) \cdot e^{-j\frac{2\pi}{\lambda}W(x,y)} \right\} \right|^2. \quad (3-10)$$

Pro modelování prostorově variantního systému pak použijeme následující vzorec


$$PSF(x', y', x, y) = \left| FT \left\{ p(x, y) \cdot e^{-j\frac{2\pi}{\lambda}W(x,y,h)} \right\} \right|^2, \quad (3-11)$$

kde  $h = \sqrt{x^2 + y^2}$  a vyjadřuje závislost RMSE vlnoplochy jednotlivých Zernikových polynomů na souřadnicích v obraze pro rotačně symetrické systémy. Tato závislost je pro základní typy vad popsána v tabulce. [14], [15], [17], [18]


Tab. 2 Závislost Zernikových polynomů v prostoru (převzato z [18])

<b>j</b>	<b>n</b>	<b>M</b>	<b>Závislost</b>	<b>Název aberace</b>
1	1	-1	$h^3 \sin \theta$	Náklon vertikální
2	1	1	$h^3 \cos \theta$	Náklon horizontální
3	2	-2	$h^2 \sin 2\theta$	Astigmatismus šikmý
4	2	0	$h^2$	Defokus
5	2	2	$h^2 \cos 2\theta$	Astigmatismus vertikální
7	3	-1	$h \sin \theta$	Koma vertikální
8	3	1	$h \cos \theta$	Koma horizontální
11	4	-2	$h^2 \sin 2\theta$	Sekundární astigmatismus šikmý
12	4	0	1	Sférická aberace
13	4	2	$h^2 \cos 2\theta$	Sekundární astigmatismus vertikální
17	5	-1	$h \sin \theta$	Sekundární koma vertikální
18	5	1	$h \cos \theta$	Sekundární koma horizontální
24	6	0	1	Sekundární sférická aberace

Na následujících obrázcích si pak můžeme prohlédnout Zernikovy polynomy do 4. řádu (Obr. 9) a příslušné PSF (Obr. 10).



Obr. 9 Zernikovy polynomy do 4. řádu



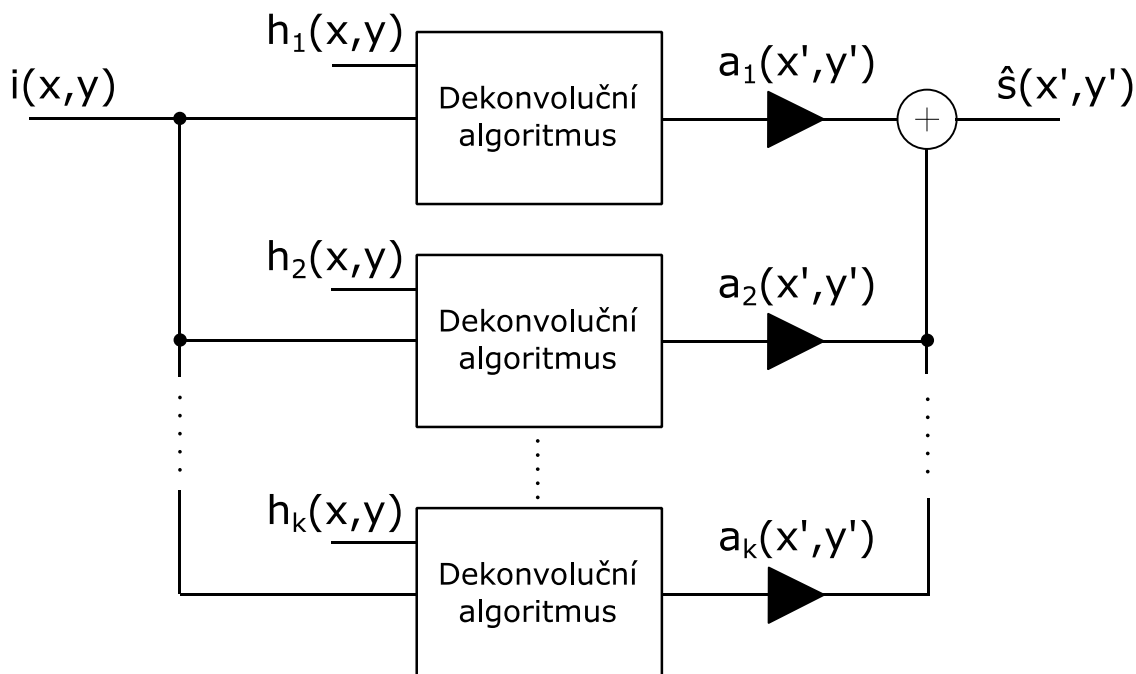
Obr. 10 PSF příslušných aberací modelovaných Zernikovými polynomy do 4. řádu

## 4 Metody dekonvoluce prostorově variantního zkreslení

V předchozí kapitole jsme si popsali, jak prostorově variantní zkreslení můžeme modelovat a simulovat. V tomto oddíle a jeho pododdílech si popíšeme několik metod pro dekonvoluci degradovaného obrázku. Informace byly čerpány zejména ze zdrojů [1], [2], [3], [8], [9], [10], [12], [13], [18].

### 4.1 Využití metody SVOLA

Rekonstrukce snímku degradovaného prostorově variantní PSF podle definice (2-10) je prakticky nemožná a velmi náročná na výpočet, jelikož každý bod je zkreslený odlišnou PSF. Z toho důvodu je velmi efektivní možností využití přístupu SVOLA zmíněného v předchozí kapitole. To tedy znamená, že předpokládáme velmi malou změnu PSF mezi jednotlivými body tak, že lze vytvořit určité oblasti, kde bude PSF pro tyto body stejná. Na základě tohoto přístupu pak můžeme realizovat v příslušných oblastech dekonvoluční algoritmy používané pro prostorově invariantní systémy. Je ovšem nutné mít na paměti, že mohou vzniknout blokové artefakty na rozhraní jednotlivých oblastí.



Obr. 11 Blokové schéma dekonvoluce za pomoci metody SVOLA

## 4.2 Dekonvoluční metody

V tomto pododdíle si vyjmenujeme a stručně popíšeme některé dekonvoluční algoritmy. Základní dělení těchto algoritmů je dle způsobu výpočtu na přímé a iterativní, případně dle znalosti PSF na slepé a neslepé. Daný algoritmus však může být upravený pro slepou nebo neslepou dekonvoluci. Algoritmy pro slepou dekonvoluci bývají většinou iterativní, kdy každou iterací se obrázek blíží svému nezkreslenému vzoru. Dobrý odhad první PSF je důležitý pro rychlost konvergence a tedy i rychlost výpočtu. Odhad PSF lze provést buď měřením PSF daného systému, nebo odhadem z pozorování, kdy si vybereme část obrázku, ve které je vysoký poměr SNR a výrazný objekt (hrana), pak provedeme zostření a odhadneme degradační proces. Třetím způsobem je odhad pomocí modelu, kdy známe model degradačního procesu a hledáme jeho parametry. Pokud bychom PSF znali, můžeme ji použít jako vstup do daného dekonvolučního algoritmu. Tím se dostáváme k neslepé dekonvoluci.

Existuje velké množství různých dekonvolučních algoritmů. Když je budeme rozlišovat pouze na přímé a iterativní, můžeme mezi přímé zařadit například Wienerovu filtraci, keprální dekonvoluci, metodu SeDDaRA (Self-Deconvolving Data Restoration Algorithm) [20], metodu APEX [19] či metodu s dvojitou expozicí. Poslední zmíněná je zajímavá metoda, kde je využíváno obrázku s dlouhou a krátkou expoziční dobou. Na prvním se uplatňuje konvoluční zkreslení, druhý obrázek je naopak velmi zašuměný. Pomocí těchto dvou obrázků lze získat PSF, kterou pak použijeme pro dekonvoluci snímku s dlouhým expozičním časem. Tato metoda je vhodná pro odstraňování malých pohybů a chvění během expozice [7].

Iterativní algoritmy jsou založené většinou na principu hledání maximální věrohodnosti, které probíhá během několika iterací. Mezi tyto algoritmy patří například Lucy-Richardsonův algoritmus, Landweberova iterace, metoda sdružených gradientů (Conjugate Gradient) nebo nejstrmějšího sestupu (Steepest Descent).

## 4.3 Wienerova filtrace

S využitím přístupu SVOLA se nabízí nejjednodušší dekonvoluce v podobě inverzní filtrace. Ta je však nevhodná z důvodu šumové katastrofy (viz kapitola 2). Tento problém lze vyřešit právě například použitím Wienerova filtru. Ten bere v úvahu výkon šumu a upravuje tak běžný inverzní filtr, aby k šumové katastrofě nedošlo:

$$\hat{S}(u, v) = \frac{H^*(u, v) \cdot P_s(u, v)}{P_s(u, v) \cdot |H(u, v)|^2 + P_n(u, v)} \cdot I(u, v). \quad (4-1)$$

$\hat{S}(u, v)$  je spektrum rekonstruovaného obrázku,  $P_s(u, v)$  je výkonové spektrum původního nezkresleného obrázku,  $P_n(u, v)$  je výkonové spektrum šumu,  $I(u, v)$  je spektrum zkresleného obrázku a  $H^*(u, v)$  je komplexně sdružené spektrum PSF. Nevýhodou tohoto filtru je, jak vidíme ve výše uvedené rovnici, že musíme znát mimo jiné výkonové spektrum nezkresleného obrázku

$P_s(u, v)$ . Pokud bychom ale znali toto výkonové spektrum, pravděpodobně bychom znali i obrázek a tudíž bychom žádnou rekonstrukci obrazu nemuseli provádět. Vztah ale můžeme upravit do podoby:

$$\hat{S}(u, v) = \frac{1}{H(u, v)} \cdot \frac{|H(u, v)|^2}{|H(u, v)|^2 + \frac{P_n(u, v)}{P_s(u, v)}} \cdot I(u, v), \quad (4-2)$$

zde nám stačí znát poměr SNR, respektive NSR (noise-to-signal ratio), který můžeme snadněji odhadnout a tak provést rekonstrukci obrazu.

Použití Wienerovy filtrace (4-2) potlačuje nežádoucí efekt šumové katastrofy, avšak je nutné dobře odhadnout úroveň šumu, resp. poměr NSR. Pokud určíme menší šum, šumovou katastrofu dostatečně nepotlačíme, naopak pokud určíme větší úroveň šumu, než je ve skutečnosti, ve výsledném obraze dojde k nežádoucímu snížení kontrastu.

#### 4.4 Rekonstrukce pomocí regularizovaného filtru

Tato metoda bývá v literatuře pojmenovaná různými názvy, nejčastěji to je Constrained Least Square Filtering a nebo Regularized Filter [1], [21]. Proto jsem zvolil v češtině název rekonstrukce pomocí regularizovaného filtru. Podobně jako Wienerovu filtraci můžeme použít filtraci s regularizovaným filtrem. Její výhodou oproti Wienerově filtraci je fakt, že pro omezení šumové katastrofy, a tedy i odhad šumu, je potřeba znát pouze střední hodnotu a rozptyl šumu. Tyto hodnoty můžeme poměrně snadno zjistit ze samotného obrázku, na rozdíl od výkonového spektra či poměru NSR, jak tomu je u Wienerovy filtrace. Odhad původního obrázku  $\hat{S}(u, v)$  ve frekvenční doméně získáme dle následujícího vztahu:

$$\hat{S}(u, v) = \frac{H^*(u, v)}{|H(u, v)|^2 + \gamma \cdot |L(u, v)|^2} \cdot I(u, v), \quad (4-3)$$

kde  $L(u, v)$  je Laplacův operátor  $l(x, y)$  ve frekvenční oblasti a  $\gamma$  je parametr, který se musí vhodně určit. Pokud tento parametr nastavíme na 0, stává se z rovnice inverzní filtr. [1]

$$l(x, y) = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} \quad (4-4)$$

Tato metoda nemusí nutně používat jako regulační operátor výše uvedený Laplacián. Pokročilejší metody využívají například různé směrové operátory, které dále zlepšují účinnost algoritmu. Je však potřeba implementovat rozhodování dle určitých kritérií tak, aby byl vždy vybrán správný směrový operátor. Takovýto algoritmus pak dokáže potlačit některé artefakty, které mohou vzniknout při rekonstrukci, jako jsou například kroužkové artefakty nebo rozmazané hrany. [21]

## 4.5 Kepstrální dekonvoluce

Díky metodě SVOLA lze také využít dekonvoluci pomocí 2D kepstra. V kepstrální oblasti přechází konvoluce na součet, čehož můžeme využít a snadno provést dekonvoluci, jak můžeme vidět v následujících vztazích (4-5)-(4-8). Pro jednotlivé oblasti obrázku vypočítáme kepstrum a také kepstrum příslušné bodové rozptylové funkce. Provedeme rozdíl těchto kepester a získáme kepstrum nezkresleného obrázku, které pak zpětně můžeme převést do obrazové domény. [13]

$$i(x, y) = s(x, y) * h(x, y) \quad (4-5)$$

$$S(u, v) = I(u, v) \cdot \frac{1}{H(u, v)} \quad (4-6)$$

$$\ln S(u, v) = \ln \frac{I(u, v)}{H(u, v)} = \ln I(u, v) - \ln H(u, v) \quad (4-7)$$

$$C_S(x', y') = C_I(x', y') - C_H(x', y') \quad (4-8)$$

Tato metoda v naší implementaci nevyužívá potlačení aditivního šumu, a tedy při nízkém SNR jsou její výsledky neuspokojivé.

## 4.6 Lucy-Richardsonův algoritmus

Lucy-Richardsonův algoritmus je iterativní metoda dekonvoluce odvozená z Bayesova teorému o podmíněné pravděpodobnosti. S každou iterací se zvyšuje věrohodnost získaného obrázku (pozorování). Někdy se tomuto algoritmu říká maximalizace očekávání. [10], [11], [12], [18]

$$p(X|Y) = p(Y|X) \cdot \frac{p(X)}{p(Y)}, \quad (4-9)$$

kde  $p(X|Y)$  je aposteriorní pravděpodobnost,  $p(Y|X)$  je věrohodnost a  $p(X)$  je apriorní model obrázku. Věrohodnost pro obrázek lze zapsat Poissonovým procesem jako:

$$p(Y|X) = \prod_{\mathbf{v}} \frac{[H * X(\mathbf{v})]^{Y(\mathbf{v})} \cdot e^{-(H * X)(\mathbf{v})}}{Y(\mathbf{v})!}, \quad (4-10)$$

kde  $X, Y, H : R^3 \rightarrow R, \mathbf{v} \in R^3$ .  $X$  je skutečný obrázek,  $Y$  je přijatý obrázek a  $H$  je bodová rozptylová funkce. Z tohoto vztahu pak lze odvodit následující:

$$\hat{X}^{(n+1)}(\mathbf{v}) = \hat{X}^{(n)}(\mathbf{v}) \cdot C^{(n)}(\mathbf{v}) \quad (4-11)$$

$$C^{(n)}(\mathbf{v}) = H(-\mathbf{v}) * \frac{Y(\mathbf{v})}{S^p(\mathbf{v})} \quad (4-12)$$

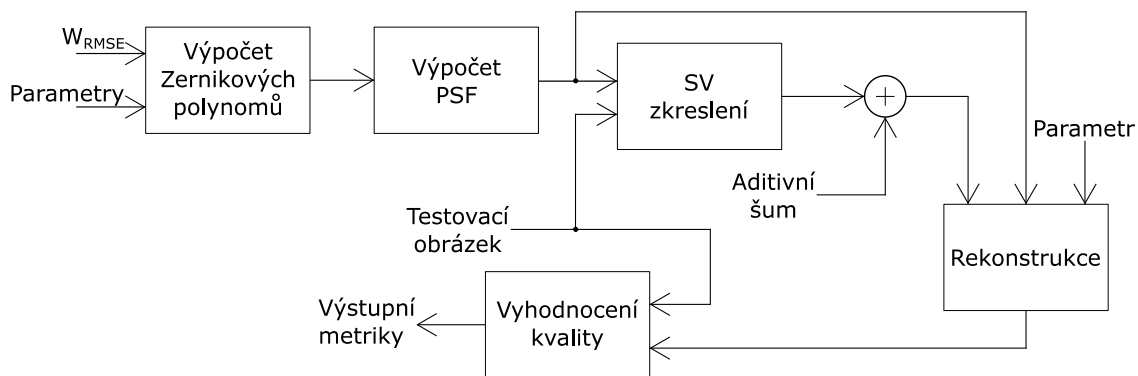
$\hat{X}^p$  je současný odhad původního obrázku,  $S$  je obrázek simulovaný pomocí PSF  $H$ . V každém kroku  $n$  je původní odhad  $\hat{X}$  násoben korekčním faktorem  $C$ . Celé odvození je k nalezení v literatuře [12].

Tento algoritmus předpokládá šum s Poissonovým rozložením, které odpovídá fotonovému šumu. Proto je využíván zejména pro astronomické snímky, kde je právě tento šum dominantní. Pro šum s Gaussovým rozložením nedosahuje takových výsledků.

## 5 Ověření účinnosti dekonvolučních metod

Touto kapitolou začíná praktická část práce. Nejprve si popíšeme, jak bude experiment probíhat, v další kapitole pak konkrétní realizaci. Výsledkům celého experimentu je pak věnována kapitola 7.

Experiment se týká simulace prostorově variantního zobrazovacího systému, průchodu signálu-obrázku tímto systémem a pak následné rekonstrukce obrázku pomocí různých dekonvolučních metod. Cílem experimentu je porovnání rekonstrukčních metod pro obrázky zkreslené prostorově variantním systémem. Schéma celého experimentu můžeme vidět na následujícím obrázku.



Obr. 12 Schéma provedení simulace LSV systému, rekonstrukce obrázku a následného vyhodnocení kvality rekonstrukce

### 5.1 Modelování degradace

V první řadě je nutné vygenerovat prostorově variantní bodovou rozptylovou funkci. K tomu využijeme zmiňované Zernikovy polynomy (viz kapitola 3.2). Pro jejich výpočet je nutné zadat parametr  $W_{RMSE}$ , který je vlastně efektivní hodnotou odchylky dané vlnoplochy od ideální vlnoplochy. Dalšími vstupními parametry jsou vlnová délka, velikost apertury, ohnisková vzdálenost, počet bodů PSF a vzorkování PSF. Vstupním parametrem je také počet oblastí – tedy i počet PSF, které budeme generovat. Jednotlivé PSF pak vypočítáme pomocí vztahů z kapitoly 3.2.

Když už máme vygenerované PSF, můžeme začít se zkreslením obrázku. K tomu použijeme metodu SVOLA pro prostorově variantní konvoluci popsanou v kapitole 3.1. Vstupem je tedy naše matice PSF a vybraný obrázek. Po dokončení zkreslení je potřeba přidat ještě aditivní šum, aby byl model degradace kompletní.

Na degradovaný obrázek pak použijeme vybrané metody rekonstrukce, které jsou popsány v kapitole 4. Vstupem je mimo obrázku i vygenerovaná PSF (a s ní i počet oblastí) a u některých metod specifický vstupní parametr. Pro Lucy-Richardsonův algoritmus to je například počet iterací, pro Wienerovu filtraci pak poměr NSR.



## 5.2 Vyhodnocení kvality rekonstrukce

Po dokončení rekonstrukce obrázku následuje vyhodnocení kvality rekonstrukce. K tomu využíváme zejména objektivní metriky kvality obrázku s plnou referencí. To znamená, že vstupem je jak rekonstruovaný obrázek, tak i obrázek originální. Tyto metriky vynášíme do grafu v závislosti na počtu použitých PSF, SNR či specifických parametrech jako např. počet iterací. Jiný pohled na kvalitu jednotlivých rekonstrukčních metod získáme např. pomocí RMSE mapy, která nám ukáže, jak se mění hodnota RMSE v závislosti na poloze v obrázku. Tím můžeme posoudit, jak se algoritmus vypořádal právě s prostorovou proměnností. Posledním kritériem hodnocení rekonstrukčních metod je doba výpočtu. Ta je důležitá z hlediska využití algoritmů v praxi, například pro rekonstrukci obrazu v reálném čase apod. V dalších podkapitolách se podíváme na všechny použité metriky.

### 5.2.1 MSE/RMSE

Základní a nejjednodušší objektivní metrikou je střední kvadratická chyba (MSE - mean square error). Je to spolehlivá metoda, její nevýhodou je, že je ovlivněná např. poklesem jasu v obrázku. Také nebere ohled na lidské vnímání, které může způsobit, že artefakt s malou chybou MSE způsobí mnohem horší vnímanou kvalitu pozorovatelem než artefakt, který má větší chybu MSE. Většinou se tento parametr používá jako RMSE (root mean square error). Důvodem je ale pouze úprava výstupních hodnot.

$$MSE = \frac{1}{m \cdot n} \sum_m \sum_n (s - \hat{s})^2. \quad (5-1)$$

$$RMSE = \sqrt{MSE} \quad (5-2)$$

Kde  $s$  je původní obrázek,  $\hat{s}$  je rekonstruovaný obrázek a  $m, n$  jsou rozměry obrázku.

### 5.2.2 PSNR

Metrika PSNR (peak signal-to-noise ratio) vychází právě z metriky RMSE a určuje poměr maximálního signálu vůči šumu (chybě). Výsledek je velmi podobný jako u předchozí metriky, jde spíše o snadnost při vyhodnocení, jelikož zde platí, že čím vyšší hodnota, tím lepší je výsledek. Také se většinou uvádí v logaritmickém měřítku, jelikož většina signálů má velký dynamický rozsah.

$$PSNR = 20 \cdot \log_{10} \frac{MAX_s}{RMSE} \quad (5-3)$$

Kde  $MAX_s$  je maximální možná hodnota v obrázku, pro 8-mi bitový obrázek to je hodnota 255.

### 5.2.3 SSIM

Pokročilá metrika SSIM (structural similarity) porovnává struktury v obrázku. Bere v úvahu lidské vnímání a díky tomu dosahuje podobných výsledků jako subjektivní testy. Při výpočtu metriky se porovnává zvlášť jas, kontrast a struktura obou vstupních obrázků. Výslednou kombinací dílčích parametrů se složí výstupní hodnota SSIM. Detailnější popis této metriky najedeme v literatuře [16].

$$l(\mathbf{x}, \mathbf{y}) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \quad (5-4)$$

$$c(\mathbf{x}, \mathbf{y}) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (5-5)$$

$$s(\mathbf{x}, \mathbf{y}) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \quad (5-6)$$

$$SSIM(\mathbf{x}, \mathbf{y}) = [l(\mathbf{x}, \mathbf{y})]^\alpha \cdot [c(\mathbf{x}, \mathbf{y})]^\beta \cdot [s(\mathbf{x}, \mathbf{y})]^\gamma \quad (5-7)$$

Kde  $\mu_x, \sigma_x^2$  a  $\sigma_{xy}$  jsou střední hodnota obrázku  $\mathbf{x}$ , jeho rozptyl a kovariance  $\mathbf{x}$  s  $\mathbf{y}$ . Konstanty  $C_1, C_2, C_3$  jsou určeny v závislosti na dynamickém rozsahu obrázku.  $l$  je metrika pro jas,  $c$  pro kontrast a  $s$  pro strukturu. Parametry  $\alpha, \beta, \gamma$  pak určují důležitost jednotlivých součástí.

### 5.2.4 MS-SSIM

Multi-scale SSIM je rozšířením předchozí metody, která zohledňuje detaily v obrázku, jejich umístění (v popředí, daleko vzadu, ...) a vjem těchto detailů. Na celý signál je iterativně aplikována filtrace dolní propustí a decimace. Po celou dobu jsou počítány hodnoty pro kontrast a strukturu, pro jas se počítá hodnota až po poslední iteraci. Této metrice se věnuje literatura [24].

$$SSIM(\mathbf{x}, \mathbf{y}) = [l_M(\mathbf{x}, \mathbf{y})]^{\alpha_M} \cdot \prod_{j=1}^M [c_j(\mathbf{x}, \mathbf{y})]^{\beta_j} \cdot [s_j(\mathbf{x}, \mathbf{y})]^{\gamma_j} \quad (5-8)$$

Podobně jako u předchozí metriky SSIM, je zde  $l$  metrika pro jas,  $c$  pro kontrast,  $s$  pro strukturu a pak příslušné parametry  $\alpha, \beta, \gamma$ , které určují důležitost.  $M$  pak je maximální počet iterací.

### 5.2.5 FSIM

Další metrikou vycházející z SSIM je Feature Similarity. Ta používá k určení kvality primárně fázovou shodu v obrázku, druhým parametrem je pak rozsah gradientu. Tyto parametry se vypočítají lokálně v celém obrázku a z nich se určí funkce podobnosti. Ta je pak váhovaná mapou, která zohledňuje lidské vnímání (např. vjem hran). Tato mapa se určí z již vypočítané fázové shody. Více o této metodě nalezneme v literatuře [23].


### 5.2.6 VIF

Visual Information Fidelity je objektivní metrika, která vyhodnocuje informaci v obraze a její vnímání člověkem. Tím vzniká tzv. vzájemná informace, která ukazuje, kolik vizuální informace

z obrázku je schopen člověk zachytit. Využívá k tomu model lidského vnímání vytvořený pomocí vlnkové transformace a Gaussovských směsí. Vlastní hodnota VIF je dána poměrem vzájemné informace zkrasleného obrázku a vzájemné informace nezkrasleného obrázku. Tato vzájemná informace se navíc počítá zvlášť v každém pásmu, o kterých předpokládáme, že jsou nezávislé. Metrice VIF a problematice informace v obraze se věnuje literatura [26].

### 5.2.7 $S_3$

Metrika  $S_3$  je z použitých metod jediná metrika bez reference. To znamená, že pro její výpočet nepotřebujeme znát původní nezkraslený obrázek. Měření se skládá ze dvou částí: spektrální měření ostrosti a prostorové měření ostrosti. Pro obě měření se obrázek rozdělí na bloky, ve kterých jsou pak tyto dvě části měřeny. Pro spektrální měření ostrosti se provede DFT daného bloku a pak se určí slope parametr  $\alpha$ , který určuje, jak ubývá amplitudové spektrum s frekvencí. Oblasti, kde  $0 \leq \alpha \leq 1$ , vnímáme jako ostré, oblasti s  $\alpha > 1$  jako rozmazané. Prostorové měření ostrosti se provádí výpočtem celkové změny v daných blocích (absolutní hodnoty rozdílu). Pro vybranou oblast se pak použije maximum z několika těchto bloků. Výsledná hodnota  $S_3$  je pak dána součinem obou částí. Detailnější popis této metriky nalezneme v literatuře [27].




(a)



(b)



(c)



(d)

Obr. 13 Použité testovací snímky, (a) baboon.tif, (b) kodim19.png, (c) kodim08.png, (d) kodim13.png

### 5.2.8 Metrika Bjontegaardové

Metrika Bjontegaardové je metoda k výpočtu rozdílu mezi dvěma křivkami, a to závislosti PSNR na bitové rychlosti. Nejdříve se změřené body proloží polynomem 3. řádu, vypočítá se integrál jednotlivých křivek a na závěr se vypočítá průměrný rozdíl mezi křivkami. Pro potřebu experimentu využijeme tuto metodu pro porovnání závislostí jednotlivých metrik. Díky integraci tak získáme jednu hodnotu, díky které dokážeme snadno porovnat dvě křivky, u kterých by například bylo obtížné srovnání, neboť se různě protínají. Více o této metrice najdeme v literatuře [29].

## 6 Simulace prostorově variantního zkreslení a dekonvoluce

Tato část se věnuje konkrétní vlastní realizaci celého experimentu. Celý experiment proběhl v prostředí programu MATLAB. Testovacími obrázky byly šedotónové verze obrázků *baboon.tif*, *kodim19.png*, *kodim08.png* a *kodim13.png* (viz Obr. 13) upravené na velikost  $512 \times 512$  pixelů. Kritériem volby obrázků bylo, aby na snímku byla reálná scéna, ale zároveň jsou na snímku zastoupeny i vyšší prostorové kmitočty – různé detaily, na kterých lze pozorovat případné artefakty. Tyto obrázky se dále mohou vyskytnout pod novými názvy, které je lépe charakterizují: *lighthouse*, *houses* a *stream*. V následujících podkapitolách si postupně popíšeme celý experiment.

### 6.1 Degradace obrazu

Pro experiment bylo nejprve nutné testovací obrázky zkreslit prostorově variantní PSF tak, abychom je mohli po následné rekonstrukci porovnávat s původními nezkreslenými obrázky. Degradace obrazu proběhla ve třech krocích. Nejprve bylo potřeba vygenerovat bodové rozptylové funkce za pomoci Zernikových polynomů. Tyto PSF pak byly vstupem funkce pro výpočet prostorově variantní konvoluce *sv\_conv2\_grid*, a na závěr byl přidán aditivní šum funkcí *imnoise*, která je součástí Image Processing Toolboxu v MATLABu.

#### 6.1.1 Výpočet PSF

Pro výpočet PSF byly použity Zernikovy polynomy (viz kapitola 3.2) až do 4. řádu, které jsou zadávány pomocí koeficientů  $W$  jako RMSE vlnoplochy na výstupním otvoru čočky v násobcích vlnové délky pro jednotlivé aberace a oblasti. Pro větší počet oblastí je možné zadat jen několik koeficientů  $W$ , které pak lze interpolovat tak, aby bylo dosaženo požadovaného počtu oblastí. V našem případě bylo zadáváno 25 koeficientů pro každý polynom ( $5 \times 5$  oblastí), poté byly hodnoty interpolovány na  $15 \times 15$  oblastí (225 různých PSF). Mimo použitého dělení oblastí ve směru os  $x$  a  $y$  se také používá dělení dle polárních souřadnic (viz [18]). Návrh koeficientů byl proveden experimentální metodou tak, aby výsledná matice PSF simulovala vlastnosti objektivu s množstvím optických vad a prostorově variantním zkreslením. K výpočtu bylo dále nutné nastavit správné vzorkování PSF. K tomu byla zadána ohnisková vzdálenost  $f = 50 \text{ mm}$ , velikost apertury  $a = f/2,8$ , vlnová délka  $\lambda = 632,8 \text{ nm}$ , počet vzorků  $N_{samp} = 486$  a vzorkování  $0,5 \mu\text{m}$ . Z těchto parametrů byl vytvořen vektor  $x$  a pak následně vypočítána matice  $R$ , která obsahuje hodnoty vzdálenosti od středu matice.

$$x = \left( \left[ -\frac{N_{samp}}{2} \right] : \left[ \frac{N_{samp} - 1}{2} \right] \right) \cdot \frac{\lambda \cdot f}{N_{samp} \cdot psf_{samp}} \quad (6-1)$$

$$R_{norm} = \frac{\sqrt{x^2 + y^2}}{\frac{a}{2}} \quad (6-2)$$

$R_{norm}$  je pak matice  $R$  normovaná poloměrem apertury. Abychom mohli rekonstruovat celou vlnoplochu, potřebujeme mít poloměr  $r_{norm} \geq 1$ , nebo také  $\max(R_{norm} \geq \sqrt{2})$ . Teď už můžeme vypočítat samotné Zernikovy polynomy dle příslušných vztahů (3-3)-(3-9), kde  $R_{norm} \sim \rho$ . Z vypočítaného polynomu pak za pomoci Fourierovy transformace určíme PSF (3-10), kterou pak ještě upravíme tak, aby jednotlivé body PSF odpovídaly pixelům na čipu senzoru. Jelikož používáme vzorkování  $0,5 \mu m$ , musíme posčítat několik bodů naší PSF, které vlastně dopadají na oblast jednoho pixelu. Tato oblast má zvolenou velikost  $3 \times 3 \mu m$ . Tento výpočet pak opakujeme pro všechny oblasti.

### 6.1.2 Výpočet prostorově variantní konvoluce

Pro výpočet prostorově variantní konvoluce byla vytvořena funkce `sv_conv2_grid`. V ní je implementována metoda SVOLA (viz kapitola 3). Využívá daný vztah (3-2) v diskrétní podobě:

$$i(x, y) = \sum_{i=1}^{N_{zones}} \sum_{x'} \sum_{y'} s(x', y') \cdot a_i(x', y') \cdot h_i(x - x', y - y'). \quad (6-3)$$

Vstupními parametry této funkce jsou:

- Vstupní obrázek ( $s$ )
- Počet oblastí ve směru osy  $x$  - ( $k_x$ )
- Počet oblastí ve směru osy  $y$  - ( $k_y$ )
- Velikost překryvu - ( $size_{MA}$ )
- Matice PSF - ( $h$ )

Překryv jednotlivých oblastí je realizován pomocí filtru MA (moving average – klouzavý průměr), který je aplikován na masku jednotlivých oblastí. Dojde tak k vytvoření lichoběžníkového až trojúhelníkového okna dle nastavení daného parametru. Pro tento experiment byla velikost překryvu vypočítána vztahem:

$$size_{MA} = \left\lceil \frac{m + n}{2 \cdot \frac{k_x + k_y}{2}} \right\rceil, \quad (6-4)$$

který se při stejném počtu oblastí ve směru obou os a také při čtvercových rozměrech obrázku zjednoduší na:

$$size_{MA} = \left\lceil \frac{m}{k} \right\rceil \quad (6-5)$$

Pro filtraci i pro konvoluci jednotlivých oblastí je pak využita funkce *imfilter* implementovaná v Image Processing Toolboxu. Tato funkce používá ve výchozím nastavení k výpočtu korelaci, což nevádí pro realizaci překryvu a konvoluci se symetrickou PSF. V našem případě ale používáme i nesymetrické PSF, proto je velmi důležité použít nastavení *,conv'*, které k výpočtu používá konvoluci, tedy jádro otočené o  $180^\circ$ . Pokud bychom použili korelaci, pak by rekonstrukční algoritmy nemusely fungovat správně, jelikož zkreslení vlastně bylo vytvořeno jinou PSF (otočenou o  $180^\circ$ ). Matice PSF zadávaná do této funkce je trojrozměrná, v prvních dvou dimenzích jsou jednotlivé PSF a třetí rozměr je vlastně index jednotlivých oblastí. Ty jsou vyčítány z levého horního rohu směrem k pravému dolnímu rohu.



(a)



(b)



(c)



(d)

Obr. 14 Ukázka rozdílu při použití konvoluce a korelace, (a), (b) konvoluce, (c), (d) korelace

Výše popsany problém můžeme pozorovat na Obr. 14, kde je v detailních záběrech (b), (d) vidět dobře rozdíl v použití konvoluce a korelace. Například na ploše zabrané lesem (šedá plocha v levém horním rohu) či na posunu a konstrukci oken. V tomto případě s použitím stejné konkrétní

PSF se při konvoluci jednotlivé body rozmazávají směrem od středu ke krajům, při korelaci naopak od krajů ke středu.

### 6.1.3 Aditivní šum

Přidání aditivního šumu je posledním krokem modelování průchodu obrázku systémem. Pro vlastní modelování šumu a jeho aplikaci na obrázek byla použita funkce *imnoise* z Image Processing Toolboxu v MATLABu, která nabízí několik typů šumu. My jsme použili bílý gaussovský šum, impulzní šum, kterému se často říká „salt and pepper“ tedy „sůl a pepř“, a šum s Poissonovým rozdělením (viz kapitola 2.4). Množství šumu je určeno poměrem SNR, který byl zvolen v rozmezí 5 až 60 dB pro testování robustnosti algoritmů. Pro gaussovský bílý šum bylo potřeba vypočítat jeho rozptyl ze zadaného poměru SNR, který je jedním ze vstupních parametrů této funkce pro gaussovský šum. Vztah pro výpočet SNR upravíme na (6-6), pro výpočet rozptylu gaussovského bílého šumu s nulovou střední hodnotou pak můžeme použít konkrétní vztah (6-7).

$$P_{\text{šum}} = \frac{P_{\text{obr}}}{10^{\frac{SNR_{dB}}{10}}} \quad (6-6)$$

$$\sigma^2 = \frac{\frac{\overline{s^2}}{m \cdot n}}{10^{\frac{SNR_{dB}}{10}}} \quad (6-7)$$


$P_{\text{šum}}$  je výkon šumu,  $P_{\text{obr}}$  je výkon obrázku,  $SNR_{dB}$  je zadaný poměr odstupe signálu od šumu,  $s$  je signál obrázku,  $m$ ,  $n$  jsou rozměry obrázku a  $\sigma^2$  je rozptyl šumu, který potřebujeme vypočítat. Během realizace se však nepodařilo získat požadovaného SNR tímto, dle teorie správným, způsobem. Naštěstí se nám podařilo dosáhnout stejného výsledku použitím iterační techniky, kterou si popíšeme v následujícím odstavci a která byla použita ke generování impulzního šumu.

Generování impulzního šumu s daným SNR je složitější. Impulzní šum nabývá zpravidla extrémních hodnot v obrázku, tedy 0 nebo 255 (v případě 8mi bitového obrázku). Vstupním parametrem funkce *imnoise* je hustota šumu, která určuje množství pixelů ovlivněných šumem a je zadávána v procentech. Z tohoto důvodu nelze použít pro impulzní šum přímo výše uvedené vztahy, a tak bylo generování impulzního šumu implementováno pomocí iterativního algoritmu, kdy měříme SNR a postupně upravujeme parametr hustoty šumu o 10% z minulé hodnoty a celý cyklus opakujeme, dokud SNR nedosáhne požadované hodnoty, resp. se dostane do požadovaného intervalu. K měření SNR používáme funkci *psnr*, která umí počítat i PSNR a která využívá vztah (6-8). V našem případě byl to interval  $(SNR_{dB} - 0,25; SNR_{dB} + 0,25)$ .

$$SNR = 10 \cdot \log_{10} \frac{\overline{s^2}}{\frac{(i - s)^2}{m \cdot n}} \quad (6-8)$$

Kde  $SNR$  je měřený poměr odstupe signálu od šumu,  $s$  je původní obrázek,  $i$  je obrázek zatížený šumem,  $m$  a  $n$  jsou rozměry obrázku.





Obr. 15 Ukázka zkreslených testovacích obrázků (a) bez aditivního šumu, (b) s gaussovským šumem  $SNR = 21$  dB, (c) s Poissonovým šumem  $SNR = 21,5$  dB, (d) s gaussovským šumem  $SNR = 5$  dB, (e) s impulzním šumem  $SNR = 5$  dB

Posledním typem šumu byl šum s Poissonovým rozdělením. Tento šum je signálově závislý a funkce *imnoise* tak nenabízí žádné volitelné parametry k tomuto šumu. Hodnoty šumu jsou vypočítávány na základě vstupních dat (obrázku). Pokud tedy je hodnota v daném bodě například 20, bude generován šum s Poissonovým rozdělením se střední hodnotou 20 ( $\lambda = 20$ ). Pro tento šum tak budeme mít pouze jednu úroveň SNR. Například pro obrázek *baboon.tif* je  $SNR \cong 21,5 \text{ dB}$ .

## 6.2 Obnovení obrazu

Pro rekonstrukci obrazu bylo potřeba vygenerování PSF, resp. odhadu PSF, které obraz zkreslily. K tomu byly opět využity Zernikovy polynomy (viz kapitola 3.2). Pro rekonstrukci obrazu bylo zajímavé vygenerovat menší počet PSF a tedy větší oblasti, nebo také nepoužít totožné PSF, ale pouze podobné. S využitím metody SVOLA byla vytvořena funkce *sv\_deconv\_grid*, která provádí rekonstrukci několika dekonvolučními algoritmy.

### 6.2.1 Rekonstrukce obrazu s prostorově variantním zkreslením

Pro rekonstrukci obrazu byla vytvořena funkce *sv\_deconv\_grid*, která je obdobou funkce *sv\_conv2\_grid* (viz kapitola 6.1.2). Funkce provádí prostorově variantní dekonvoluci za pomoci metody SVOLA (viz Obr. 11) a využívá následující dekonvoluční algoritmy: Wienerova filtrace, Lucy-Richardsonův algoritmus, rekonstrukce s regularizovaným filtrem a keprální dekonvoluce (viz kapitola 4). Vstupními parametry této funkce jsou:

- Metoda dekonvoluce
- Vstupní obrázek - (*i*)
- Počet oblastí na ose x - ( $k_x$ )
- Počet oblastí na ose y - ( $k_y$ )
- Velikost překryvu - ( $size_{MA}$ )
- Matice PSF - (*h*)
- Parametr dekonvolučního algoritmu - ( $NSR, NP, N_{it}$ )

Výběr metody je realizován specifickým slovem. Tato slova jsou: *,wiener‘*, *,reg‘*, *,lucy-rich‘* a *,cepstral‘* pro Wienerovu filtraci, rekonstrukci s regularizovaným filtrem, Lucy-Richardsonův algoritmus a keprální dekonvoluci. Funkce používá již implementované funkce v Image Processing Toolboxu v MATLABu: *,deconvwnr‘*, *,deconvreg‘* a *,deconvlucy‘*. Keprální dekonvoluce byla implementována přímo do funkce *sv\_deconv\_grid*, kde k výpočtu keprster byly použity funkce *fft2*, *log*, *ifft2* a *exp* (viz kapitola 4.5). Velikost překryvu byla počítána podle stejného vzorce jako při degradaci (6-5). Stejně tak i zadávání matice PSF, na které se musí dát pozor, aby byla rekonstrukce provedena správně. Matice PSF tedy v prvních dvou souřadnicích obsahuje jednotlivé PSF, v třetí souřadnici jsou PSF řazené od levého horního rohu směrem do

pravého dolního (jako když čteme knihu). Posledním vstupem je parametr dekonvolučního algoritmu. Pro Wienerovu filtraci je to poměr NSR v lineární míře, který je odhadnut dle vztahu:

$$NSR = \frac{1}{10^{\frac{SNR}{10}}}, \quad (6-9)$$

kde  $SNR$  je předpokládaný odstup signálu od šumu v obrázku. Po několika proběhnutí skriptu bylo zjištěno, že tento vztah je optimální pro impulzní šum a že pro gaussovský šum a šum s Poissonovým rozdělením je vhodnější použít vztah:

$$NSR = \frac{1}{10^{\frac{SNR}{20}}}, \quad (6-10)$$

Pro rekonstrukci s regularizovaným filtrem je vstupní parametr výkon šumu ( $NP$ ), pro který byl navržen empirický vzorec k odhadu tohoto parametru:

$$NP = \left( \frac{1}{10^{\frac{SNR}{20}}} \cdot \bar{i} \right)^2 \cdot size(i_{patch}). \quad (6-11)$$

Kde  $\bar{i}$  je průměrná hodnota obrázku zatíženého šumem a  $size(i_{patch})$  znamená rozměr oblasti (patche), pro kterou výkon šumu odhadujeme. Vstupem do funkce `sv_conv2_grid` je však pouze první část parametru  $NP$  (druhá mocnina závorky), aby z důvodu změny velikosti oblasti nemusela být tato velikost vypočítávána externě mimo funkci `sv_conv2_grid`. Lucy-Richardsonův algoritmus má jako vstupní parametr počet iterací ( $N_{it}$ ). Jak uvidíme v následující kapitole 7.3, počet iterací ovlivňuje kvalitu obrázku a pro optimální kvalitu je třeba měnit počet iterací v závislosti na šumu v obrázku. Za tímto účelem byl odhadnut z charakteristik na obrázku empirický vzorec, který upravuje počet iterací v závislosti na odstupu signálu od šumu:

$$N_{it} = \left\lfloor \frac{SNR}{2} \right\rfloor + 1 \quad (6-12)$$

Kepstrální dekonvoluce žádný speciální parametr nepoužívá.


### 6.3 Vyhodnocení

K vyhodnocení kvality obrázků byla použita objektivní metrika RMSE, PSNR, SSIM, MS-SSIM, FSIM, VIF a  $S_3$ . Tyto metriky jsou popsány v kapitole 5.2 a příslušné literatuře uvedené také v kapitole 5.2. Hodnoty těchto metrik byly vyneseny v závislosti na několika možných parametrech: SNR obrázku, počet oblastí použitých pro metodu SVOLA či parametr daného algoritmu. Hodnoty jednotlivých metrik byly vyneseny do samostatných grafů. Metriky RMSE a PSNR byly počítány dle vztahů (5-2) a (5-3). Další metriky byly vypočítány pomocí funkcí, které jsou dostupné na stránkách o příslušné metrice. Názvy funkcí jsou následující: `ssim.m` [16], `msssim.m` [25], `FeatureSIM.m` [23], `vifvec.m` [33], `s3_map.m` [32] a `bjontegaard2.m` [31]. Vstupem těchto metrik je pouze referenční obrázek a měřený obrázek, výstupem je pak zpravidla jedna

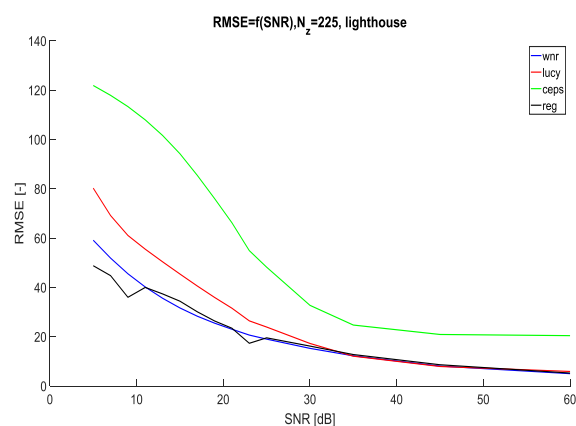
hodnota. SSIM nabízí navíc možnost mapy SSIM, kde můžeme vidět, jak se hodnota SSIM mění v různých oblastech obrázku. Metrika  $S_3$  je tzv. bez reference a jejím vstupem je jen měřený obrázek. Funkce pro metriku  $S_3$  nabízí výstup pouze jako mapu, ale v dokumentaci se píše, že výstupní hodnota se vypočítá jako průměr z 1% nejvyšších nenulových hodnot. Tento výpočet byl implementován, a tak můžeme porovnávat i tuto metriku s ostatními. Mimo tyto metriky byla k vyhodnocení vytvořena mapa RMSE, kde můžeme také porovnávat kvalitu v různých částech obrázku. Díky RMSE mapě také můžeme zkoumat, kde v obrázku vznikají největší chyby, a také, jak tyto chyby ovlivňují jiné metriky, když si porovnáme například mapu SSIM a RMSE. Pro jednodušší srovnání všech použitých metod byla vypočítána metrika Bjontegaardové, která byla využita pro získání jediného čísla, které určuje rozdíl dané metriky mezi jednotlivými metodami. Pro porovnání jednotlivých rekonstrukčních metod byla také změřena doba výpočtu. K tomu byla využita funkce *timeit*. Tato hodnota je ale spíše orientační, neboť každý z použitých algoritmů nemusí být stoprocentně optimalizován pro rychlý výpočet.

## 7 Analýza výsledků simulace


V této kapitole jsou prezentovány výsledky experimentu popsaného v předcházejících kapitolách. Porovnáváme robustnost algoritmů – tedy jejich odolnost vůči šumu. Rozsah SNR je 5 až 60 dB, kde obrázky s  $SNR < 20$  dB jsou velmi zašuměné a reálně se s nimi příliš často neseškáváme. Obrázky se  $SNR > 30$  dB jsou ve vynikající kvalitě, hodnota 60 dB pak představuje obrázek prakticky bez šumu. Dále můžeme srovnávat závislost na specifických parametrech daných algoritmů. To je zajímavé zejména pro optimalizaci určení těchto parametrů ke zlepšení kvality rekonstrukce. Na závěr pak porovnáváme závislost na počtu použitých oblastí, kde nás zajímá, jaké zlepšení získáme použitím prostorově variantní PSF, případně můžeme vidět, jestli je možné počet oblastí snížit a za jaký úbytek na kvalitě. Jednotlivým algoritmům jsou věnovány samostatné pododdíly. Většina závislostí byla vypočítána na obrázku *baboon.tif*, ale jsou platné i pro jiné obrázky.



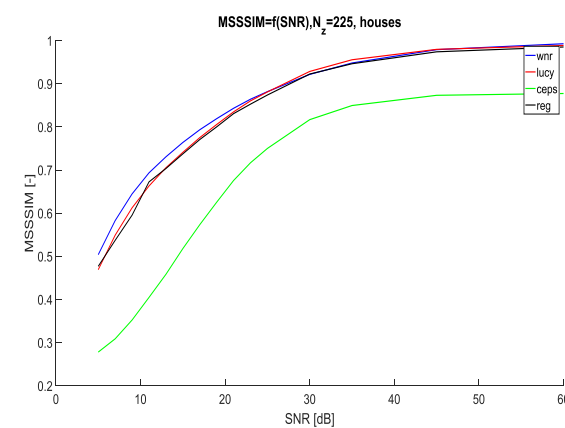
(a)



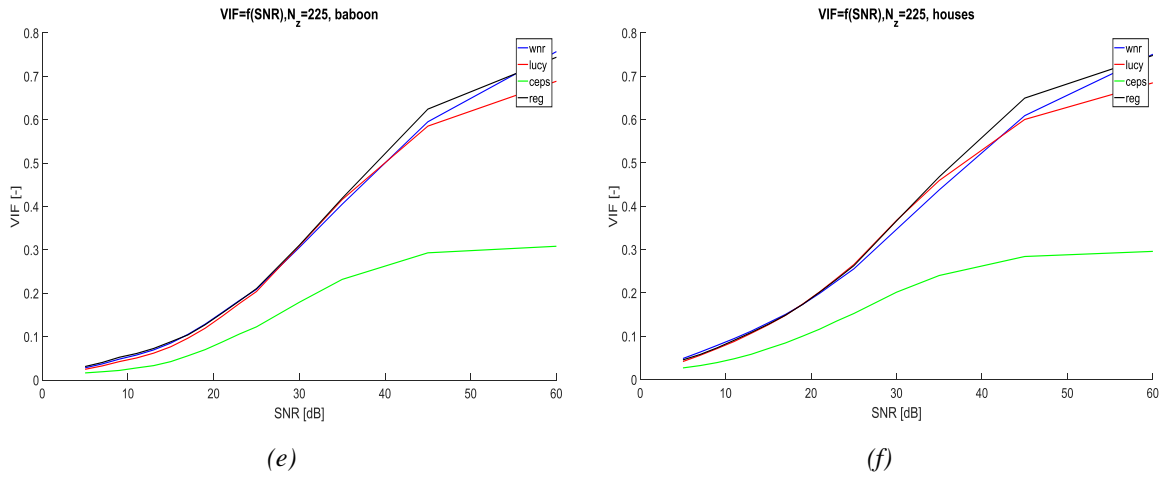
(b)



(c)



(d)

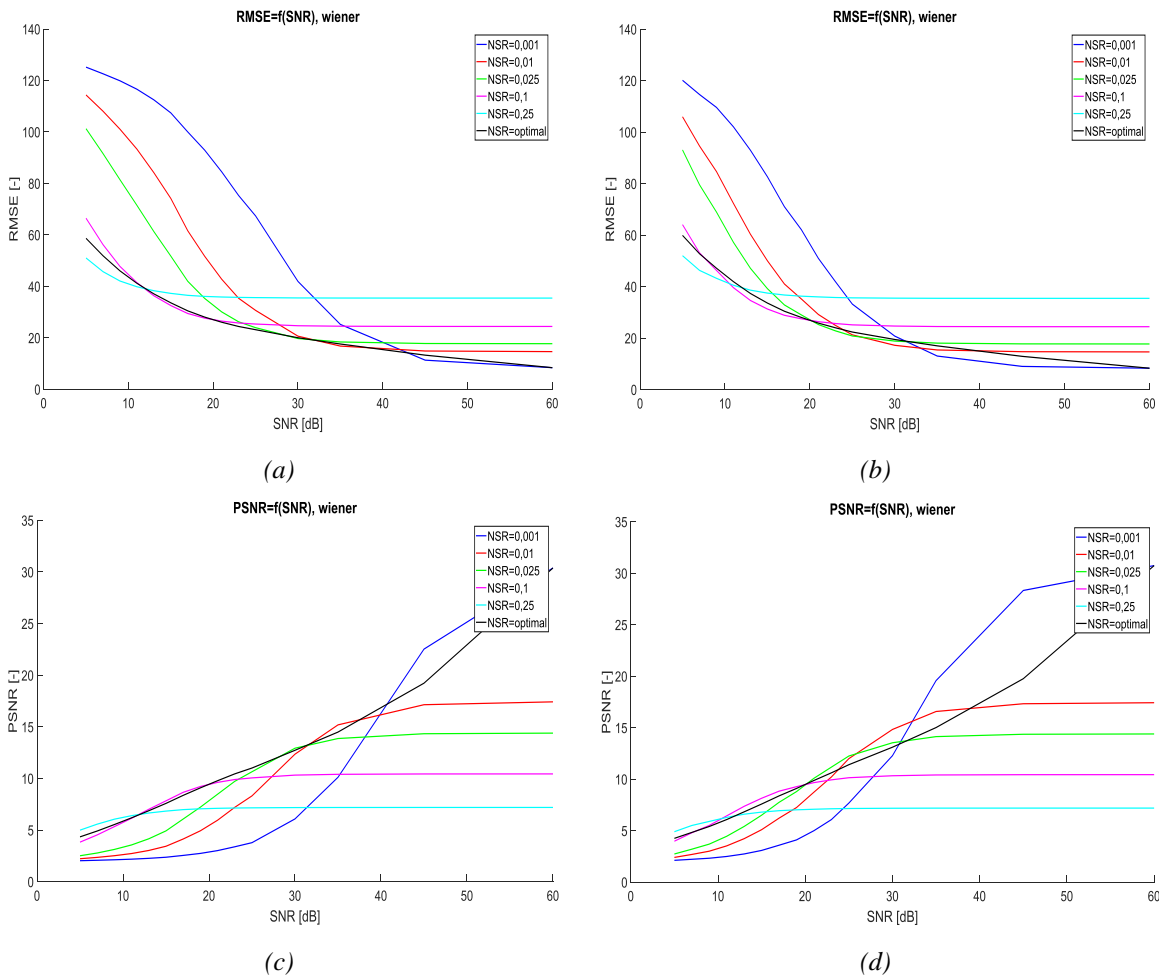


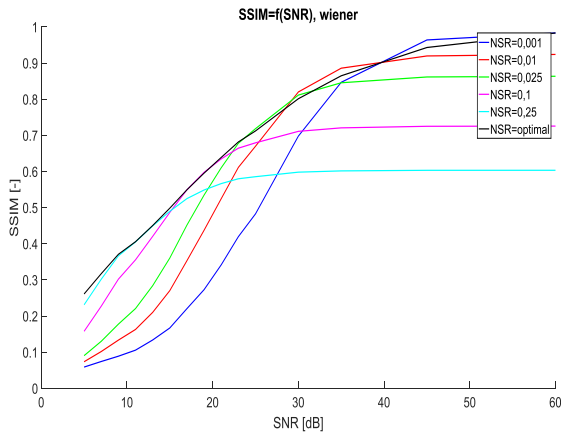
Obr. 16 Srovnání závislosti vybraných metrik na signálu

Jak vidíme na Obr. 16, vybrané závislosti jsou si velmi podobné pro různé obrázky. Mohou se mírně lišit v absolutní hodnotě, ale trend těchto charakteristik zůstává stále stejný.


## 7.1 Wienerova filtrace

Nejprve se podíváme na Wienerovu filtraci z pohledu závislosti kvality na SNR.






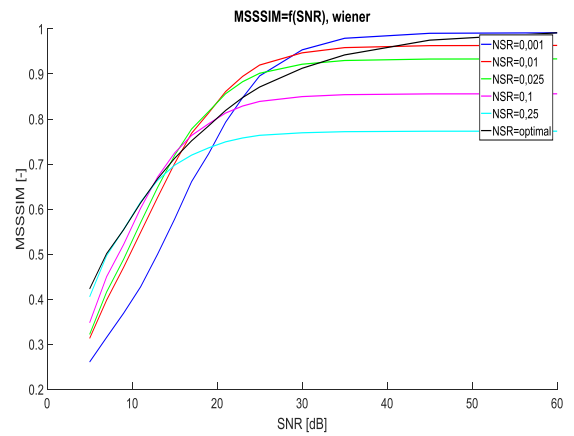
(e)



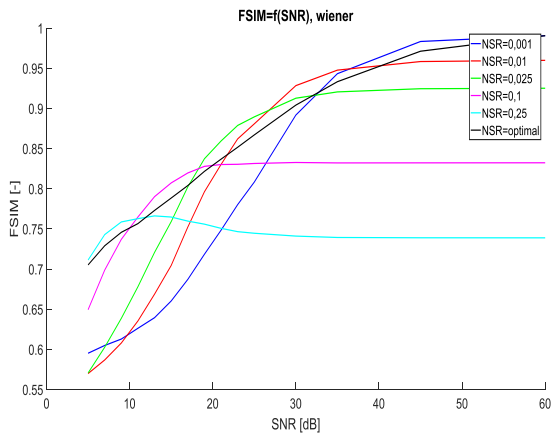
(f)



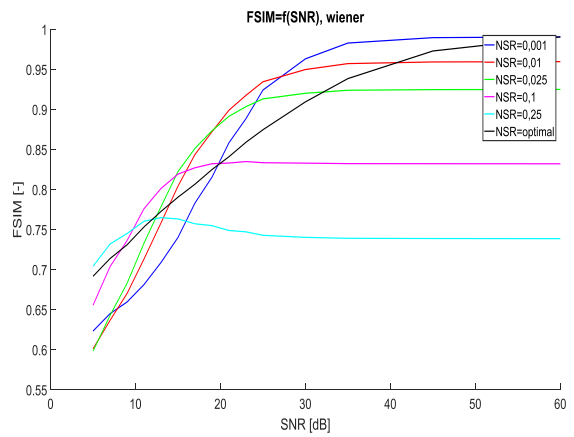
(g)



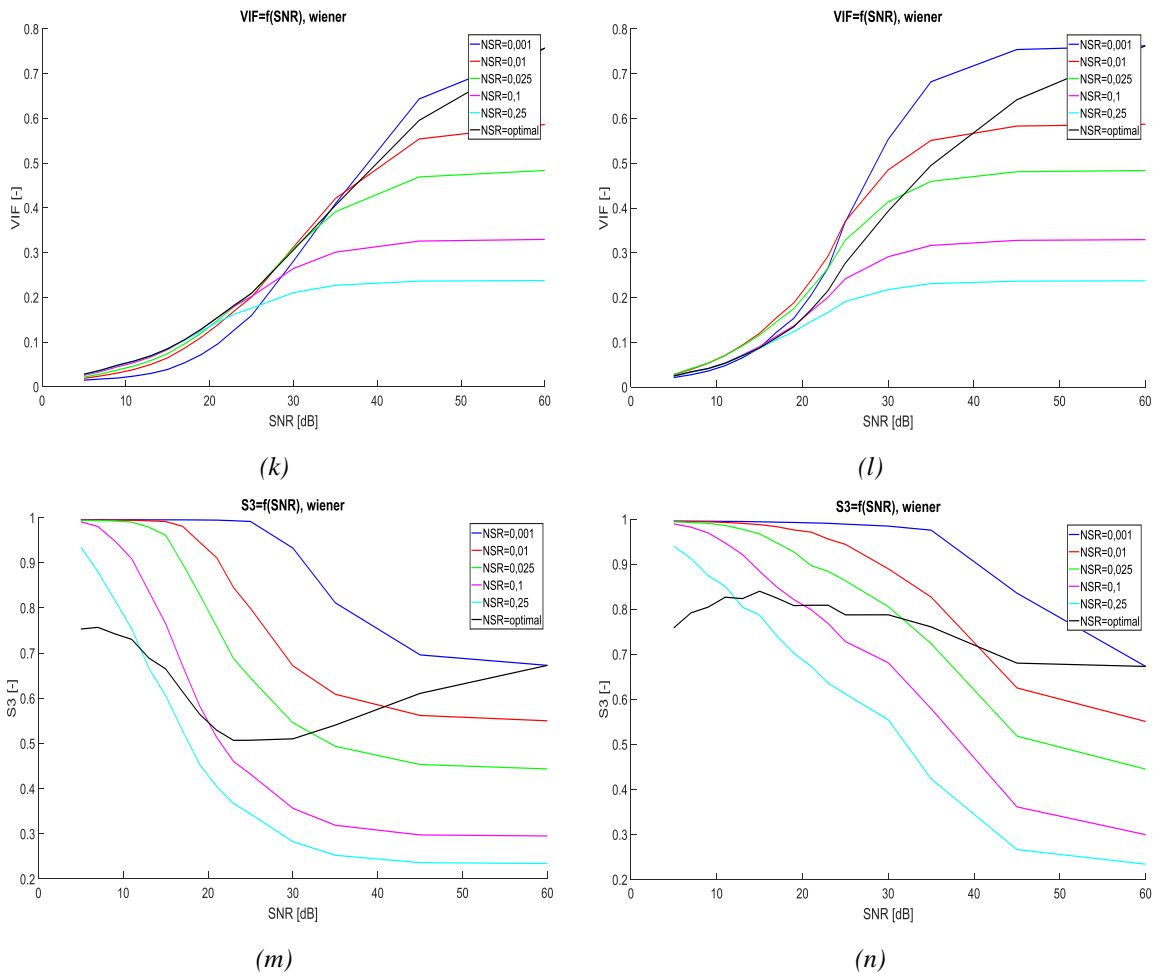
(h)



(i)



(j)

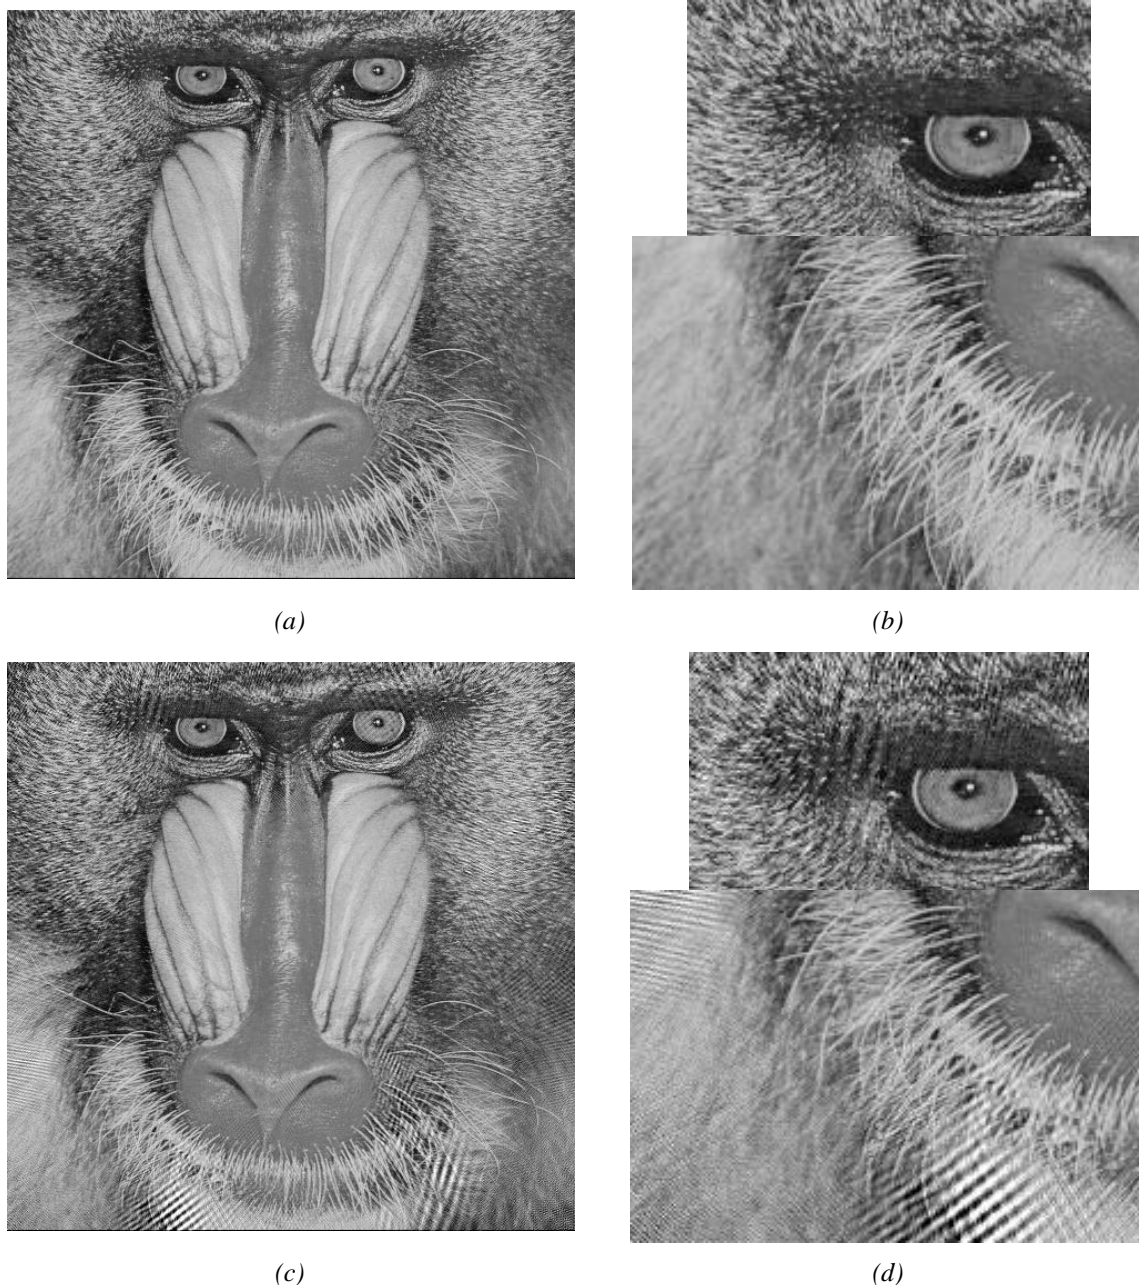


Obr. 17 Závislost metrik RMSE, PSNR, SSIM, MS-SSIM, FSIM, VIF a  $S_3$  na SNR pro Wienerovu filtraci, (a), (c), (e), (g), (i), (k), (m) pro gaussovský bílý šum, (b), (d), (f), (h), (j), (l), (n) pro impulzní šum

Můžeme vidět, že kvalita závisí samozřejmě na poměru signálu a šumu, tedy kvalitě vstupního obrázku, ale zejména na odhadu šumu – zde poměru NSR. Lze si všimnout, že při nízkém poměru (velmi malý šum) dochází často k šumové katastrofě, a proto jsou v levé části grafu vždy lepší rekonstrukce s vyšším NSR. Směrem vpravo, do oblasti s malým šumem, se postupně zlepšují rekonstrukce s nižším odhadem NSR. Ale například i pro obrázek téměř bez šumu (60 dB) dochází k zhoršení kvality, jelikož už jsme velmi blízko šumové katastrofě a nějaký miniaturní šum v nějakých oblastech obrázku už tak generujeme.


Také si můžeme všimnout, že metriky SSIM a MS-SSIM si jsou velmi podobné, proto dále budeme používat jen metriku MS-SSIM. Stejně tak i metrika PSNR, která přímo závisí na RMSE. Metrika  $S_3$  pak nepodává výsledky, které by odrážely přímo kvalitu rekonstrukce. Závislosti všech chybějících metrik nalezneme v příloze 10.3.






*Obr. 18 Ukázka artefaktů vznikajících při odhadu poměru NSR blízko hranice šumové katastrofy, (a), (b) nezkreslený obrázek a detaily, (c), (d) rekonstruovaný obrázek a detaily*


Na obrázku Obr. 18 můžeme pozorovat právě artefakty, které vznikají, pokud poměr NSR se blíží k hranici, od které nastává šumová katastrofa. V porovnání s nezkresleným obrázkem (a), (b) vidíme jemné struktury zejména na krajích rekonstruovaného obrázku (c), (d). Dále se podíváme na závislost odhadu NSR.



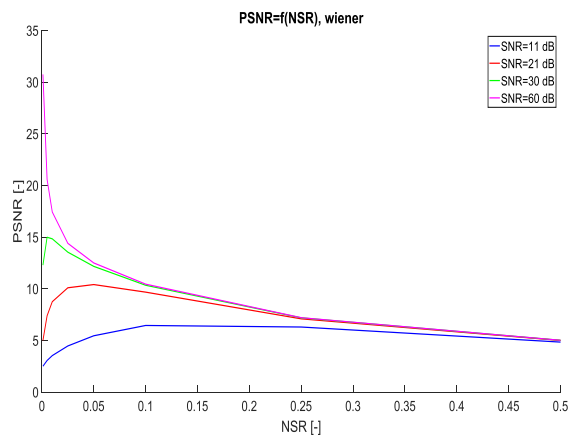
(a)




(b)




(c)



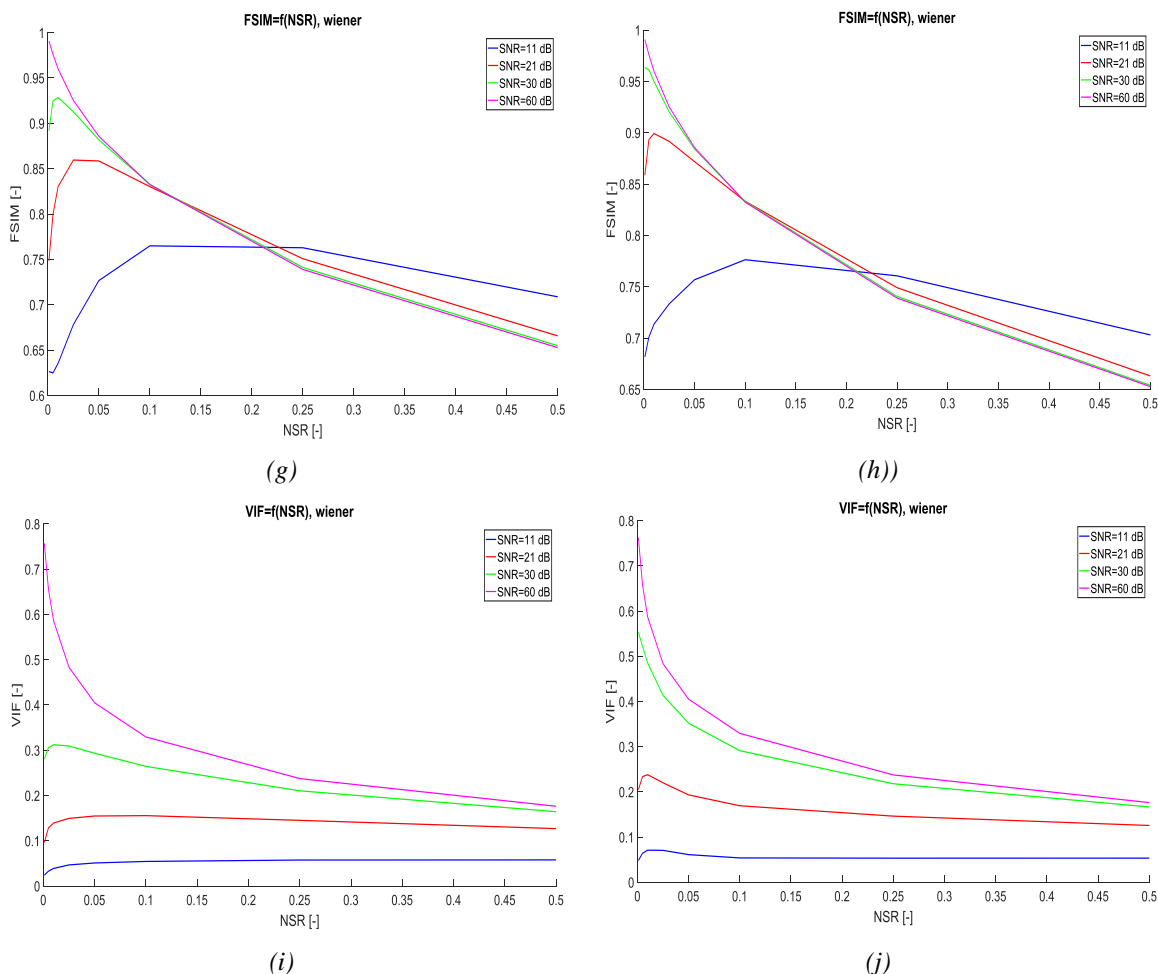
(d)



(e)




(f)



Obr. 19 Závislost RMSE, PSNR, MS-SSIM, FSIM a VIF na poměru NSR pro Wienerovu filtraci, (a), (c), (e), (g), (i) pro gaussovský bílý šum, (b), (d), (f), (h), (j) pro impulzní šum


Na těchto grafech (Obr. 19) můžeme sledovat vliv odhadu NSR na kvalitu pro různě degradované obrázky. Také z grafů můžeme odečíst ideální poměr NSR pro daný poměr SNR, který pak můžeme použít při další či opakované rekonstrukci.




Obr. 20 Ukázka vlivu odhadu NSR, obrázek baboon.tif, impulzní šum se SNR=10 dB, (a) NSR=1e-6, (b) NSR=1, (c) NSR=0,1

Na obrázku výše (Obr. 20) můžeme vidět vliv odhadu NSR na rekonstrukci. Pokud bude odhad NSR malý, tak dojde k šumové katastrofě, pokud bude odhad příliš velký, dojde ke snížení


kontrastu, v ideálním případě bude obraz s dobrým kontrastem i poměrem signálu k šumu. Teď se podíváme na závislost počtu oblastí použitých při rekonstrukci. Počet oblastí je v grafech vyjádřen jako odmocnina z celkového počtu oblastí  $\sqrt{N_{zones}}$ . Jelikož používáme vždy stejný počet oblastí podél osy  $x$  i  $y$ ,  $\sqrt{N_{zones}}$  značí vlastně počet oblastí v jednom směru.




(a)




(b)




(c)



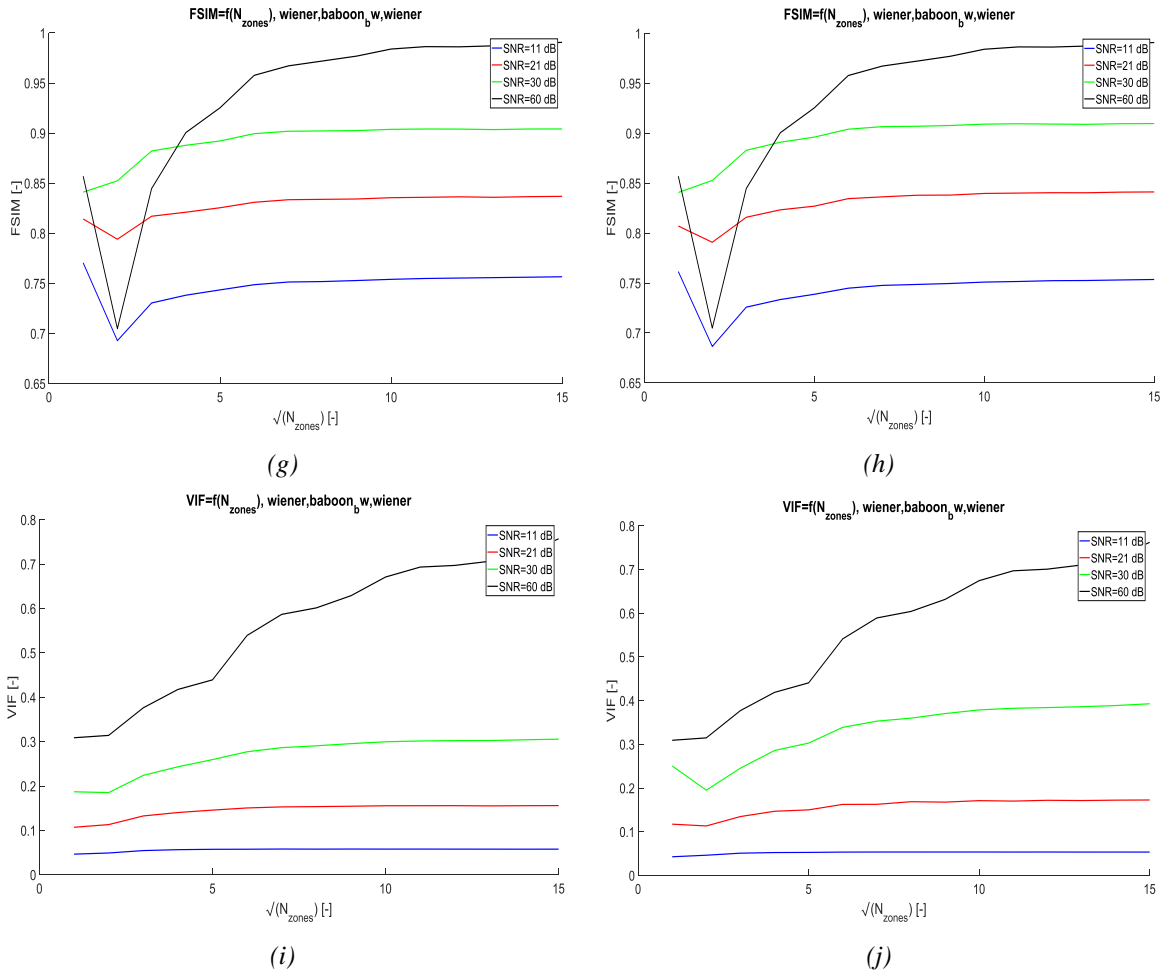
(d)



(e)




(f)



Obr. 21 Závislost RMSE, PSNR, MS-SSIM, FSIM a VIF na počtu oblastí pro Wienerovu filtraci, (a), (c), (e), (g), (i) pro gaussovský bílý šum, (b), (d), (f), (h), (j) pro impulzní šum


Jak můžeme vidět na grafech (Obr. 21), pro maximální počet oblastí ( $\sqrt{N_{zones}} = 15$ ) dosahujeme nejlepších výsledků zejména u obrázku s nízkým šumem. U obrázků s vyšším šumem je výhodnější použít méně oblastí, jelikož zde dochází k zajímavému jevu, kdy právě díky menšímu počtu oblastí a tím pádem mírně odlišným PSF, které např. jsou průměrem sousedících a pokrývají část jejich plochy, dochází ke snížení šumu. Nejlepším příkladem pro tento jev je použití  $2 \times 2$  oblastí, kde dochází k velké redukci šumu i pro hodně zašuměné obrázky. Samozřejmě tím dochází k rozmazání, takže pro obrázky s nízkou úrovní šumu je tento postup nevhodný z pohledu kvality obrázku a ostroty detailů.




Obr. 22 Ukázka vlivu počtu oblastí a rozmazání, obrázek baboon.tif, impulzní šum, (a)  $SNR=10$  dB,  $N_z=225$ , (b)  $SNR=10$  dB,  $N_z=4$ , (c)  $SNR=60$  dB,  $N_z=225$ , (d)  $SNR=60$  dB,  $N_z=4$

Můžeme vidět, že při  $SNR = 10$  dB a počtu oblastí  $N_z = 4$  v Obr. 22 (b) dochází k potlačení šumu oproti (a). Naopak pro  $SNR = 60$  dB pak dochází v (d) spíše k rozmazání a tím pádem ke zhoršení kvality vůči (c).


Na závěr se podíváme na šum s Poissonovým rozložením.




(a)




(b)




(c)




(d)



(e)



(f)

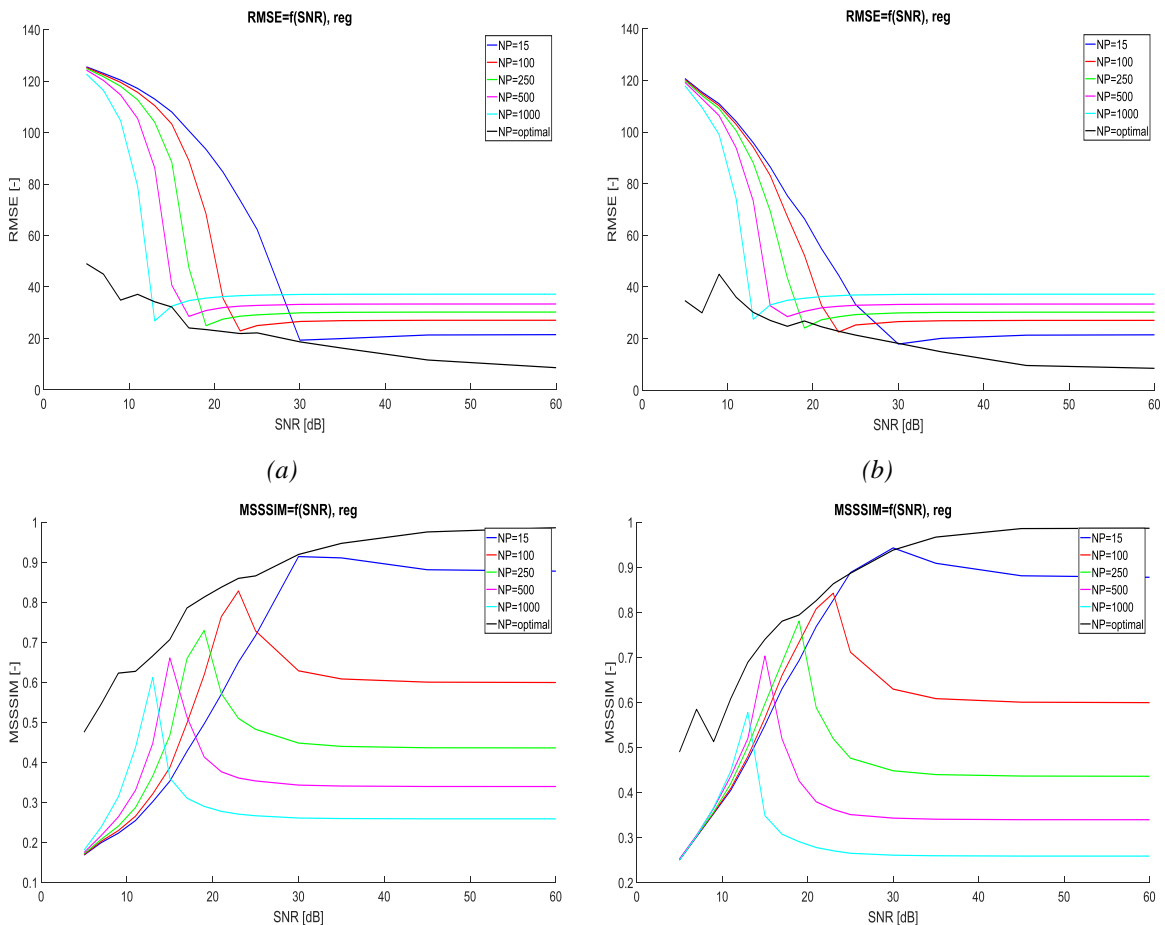


Obr. 23 Závislost RMSE, MS-SSIM, FSIM a VIF pro Wienerovu filtraci, (a), (c), (e), (g) na poměru NSR, (b), (d), (f), (h) na počtu oblastí, obrázek s šumem s Poissonovým rozdělením

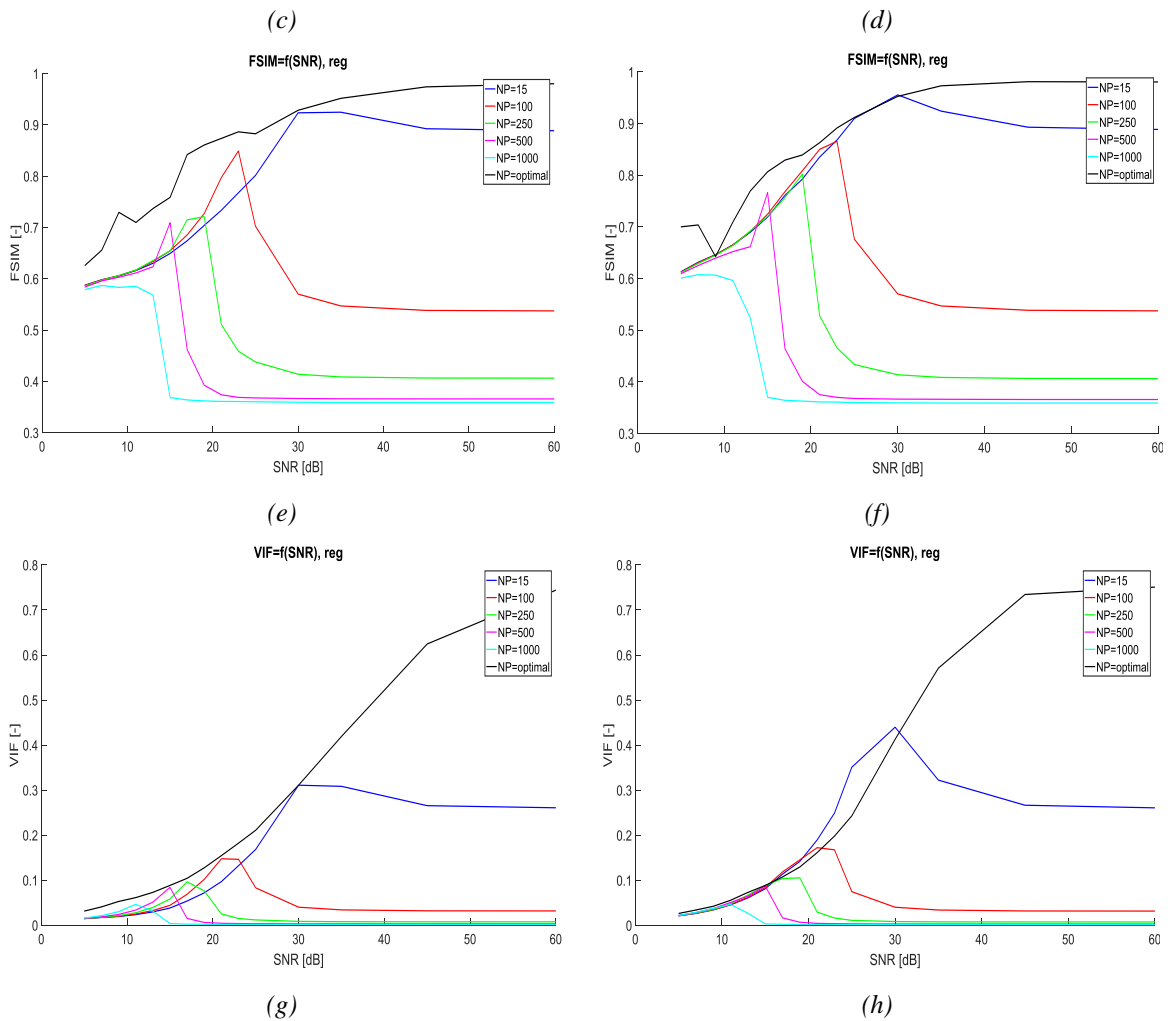
Z obrázku Obr. 23 lze vidět, že Wienerova filtrace si se šumem s Poissonovým rozdělením poradí stejně či nepatrně lépe, než s gaussovským šumem.

## 7.2 Rekonstrukce s regularizovaným filtrem

Rekonstrukce s regularizovaným filtrem se principiálně podobá Wienerově filtraci. Podíváme se tedy na závislost kvality na poměru SNR.








Obr. 24 Závislost RMSE, MS-SSIM, FSIM a VIF na SNR pro regularizovaný filtr, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum

Na grafech (Obr. 24) můžeme vidět, že výsledná kvalita rekonstrukce opět závisí na přesnosti odhadu šumových parametrů. Zde je to přímo výkon šumu. Ve srovnání s Wienerovou filtrací můžeme pozorovat nepatrně lepší parametry při rekonstrukci. Rozdílný je také způsob potlačení šumu. U Wienerovy filtrace dochází ke ztmavení obrázku, u regularizovaného filtru dochází k rozmazání.




(a)


(b)

Obr. 25 Srovnání potlačení šumu, (a) regularizovaný filtr, (b) Wienerova filtrace

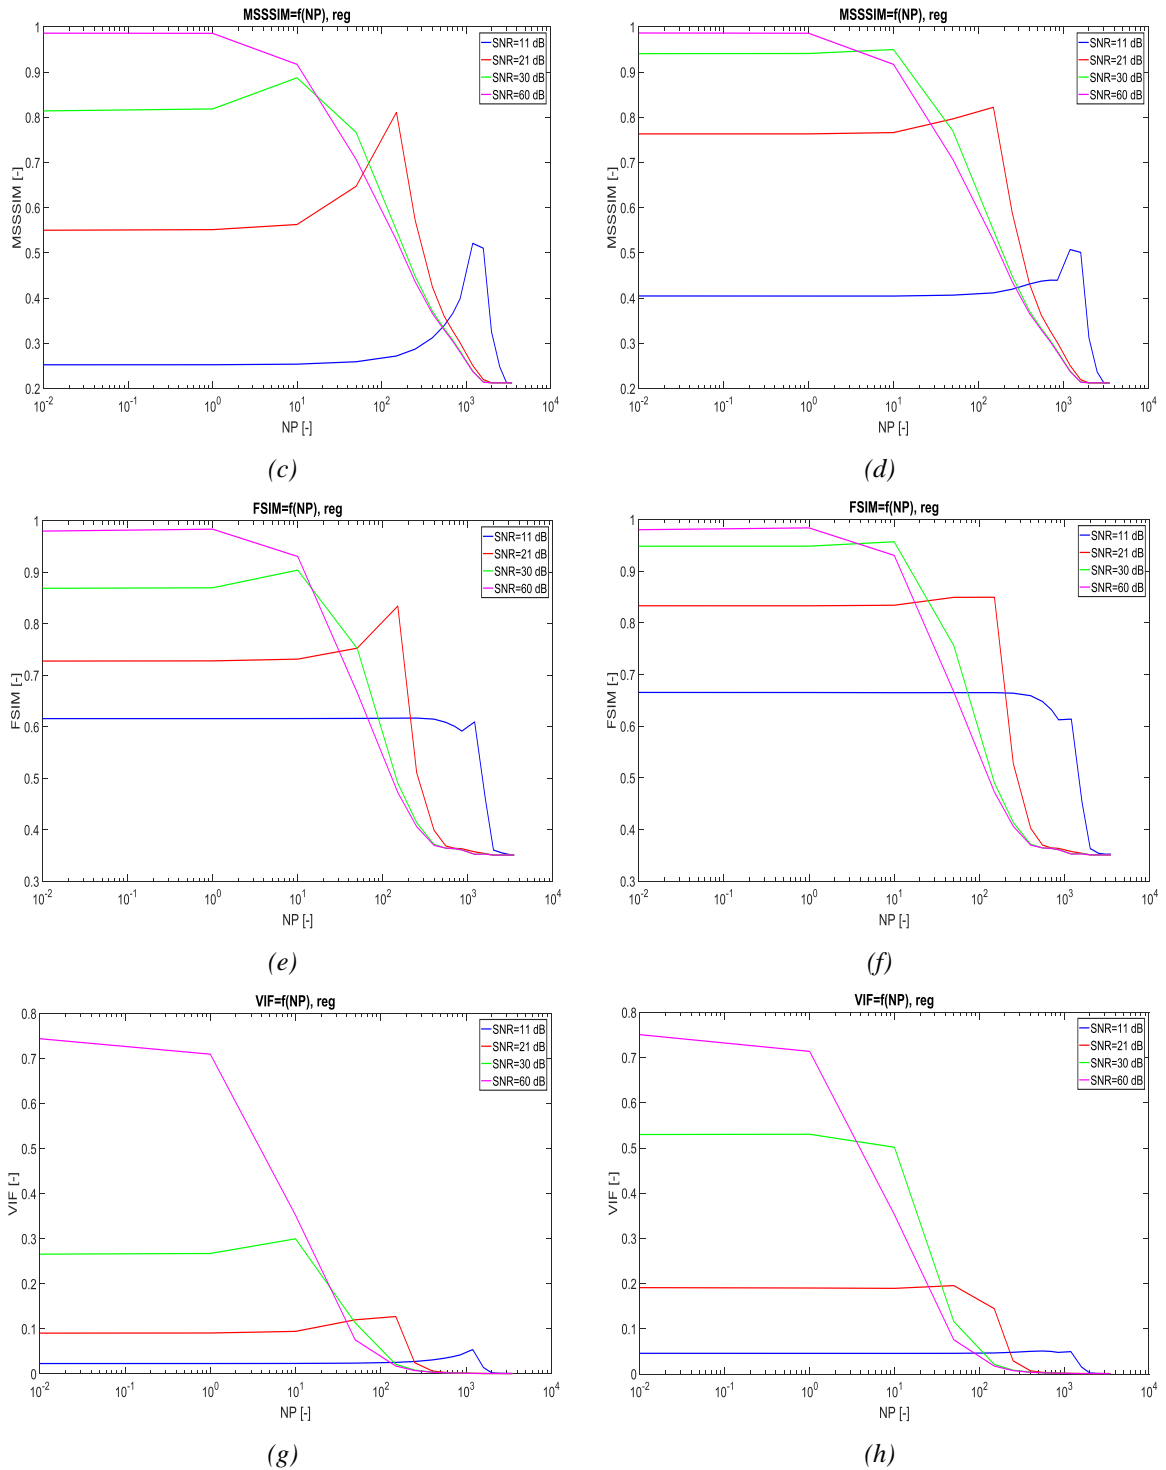
Na obrázku Obr. 25 (a) vidíme rekonstrukci s regularizovaným filtrem, kde si můžeme všimnout poměrně značného rozmazání oproti obrázku (b), který je naopak tmavší. I přes zesílení šumu v rozích však pro obrázek (a) můžeme z grafů odečíst např. hodnoty  $RMSE_a \cong 37$ ,  $SSIM_a \cong 0,44$ , pro obrázek (b)  $RMSE_b \cong 45$ ,  $SSIM_b \cong 0,35$ . Dále se podíváme na závislost na odhadu šumu.



(a)




(b)




Obr. 26 Závislost RMSE, MS-SSIM, FSIM a VIF na parametru NP pro regularizovaný filtr, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum

Jak vidíme, správný odhad šumu je zásadní pro zlepšení kvality rekonstrukce. Můžeme pozorovat na většině grafů vodorovnou čáru, kdy je odhadovaný šum malý, poté dochází k nárůstu a tedy zlepšení. Pokud ale odhad přeženeme, dochází k strmému pádu, který je způsoben obrovským rozmazáním obrázku. Nyní se podíváme na závislost na počtu oblastí.


## 7 Analýza výsledků simulace




(a)




(b)




(c)



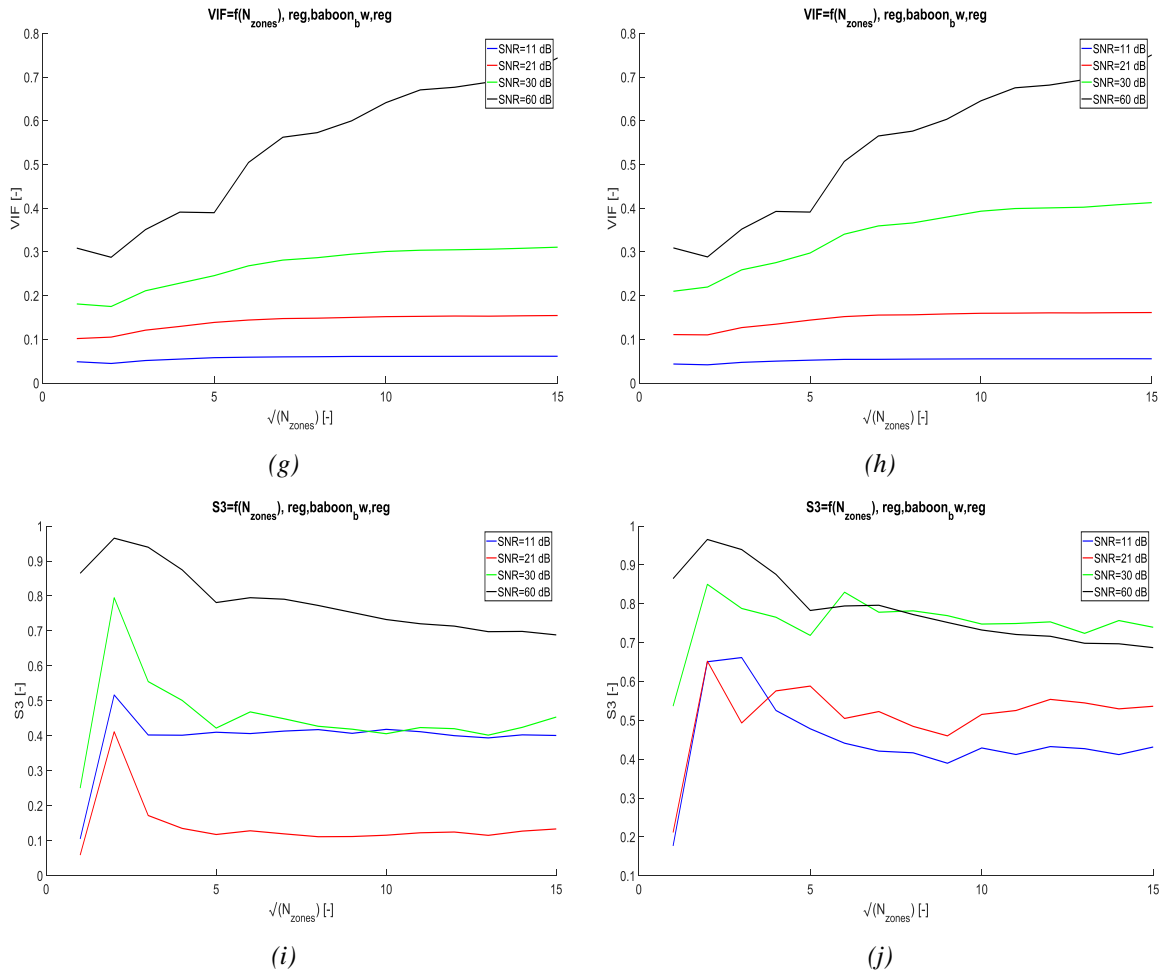
(d)



(e)




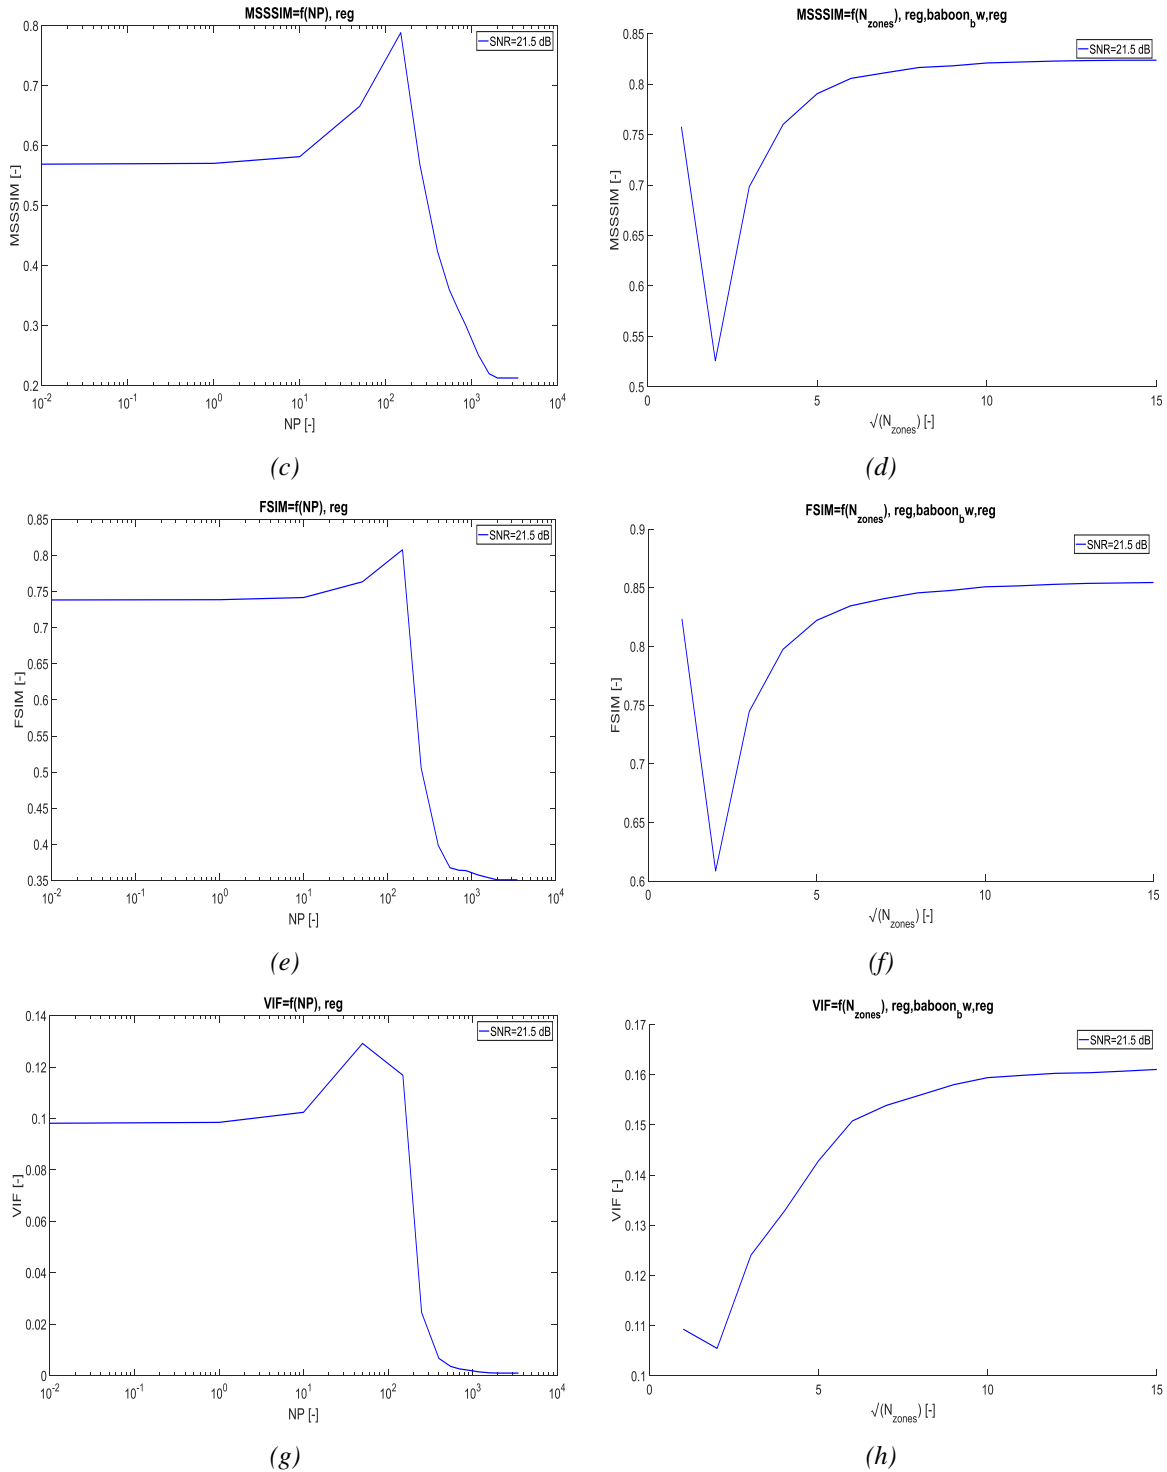
(f)



Obr. 27 Závislost RMSE, MS-SSIM, FSIM, VIF a  $S_3$  na počtu oblastí pro regularizovaný filtr, (a), (c), (e), (g), (i) pro gaussovský bílý šum, (b), (d), (f), (h), (j) pro impulzní šum

Na obrázcích výše (Obr. 27) můžeme pozorovat vliv počtu použitých oblastí na kvalitu rekonstrukce. Lze si všimnout, že u regularizovaného filtru nedochází k efektu potlačení šumu rozmazáním při počtu oblastí  $N_z = 4$ . Dochází zde naopak k přestření, což je negativně hodnoceno použitými metrikami (kromě metriky  $S_3$ ).



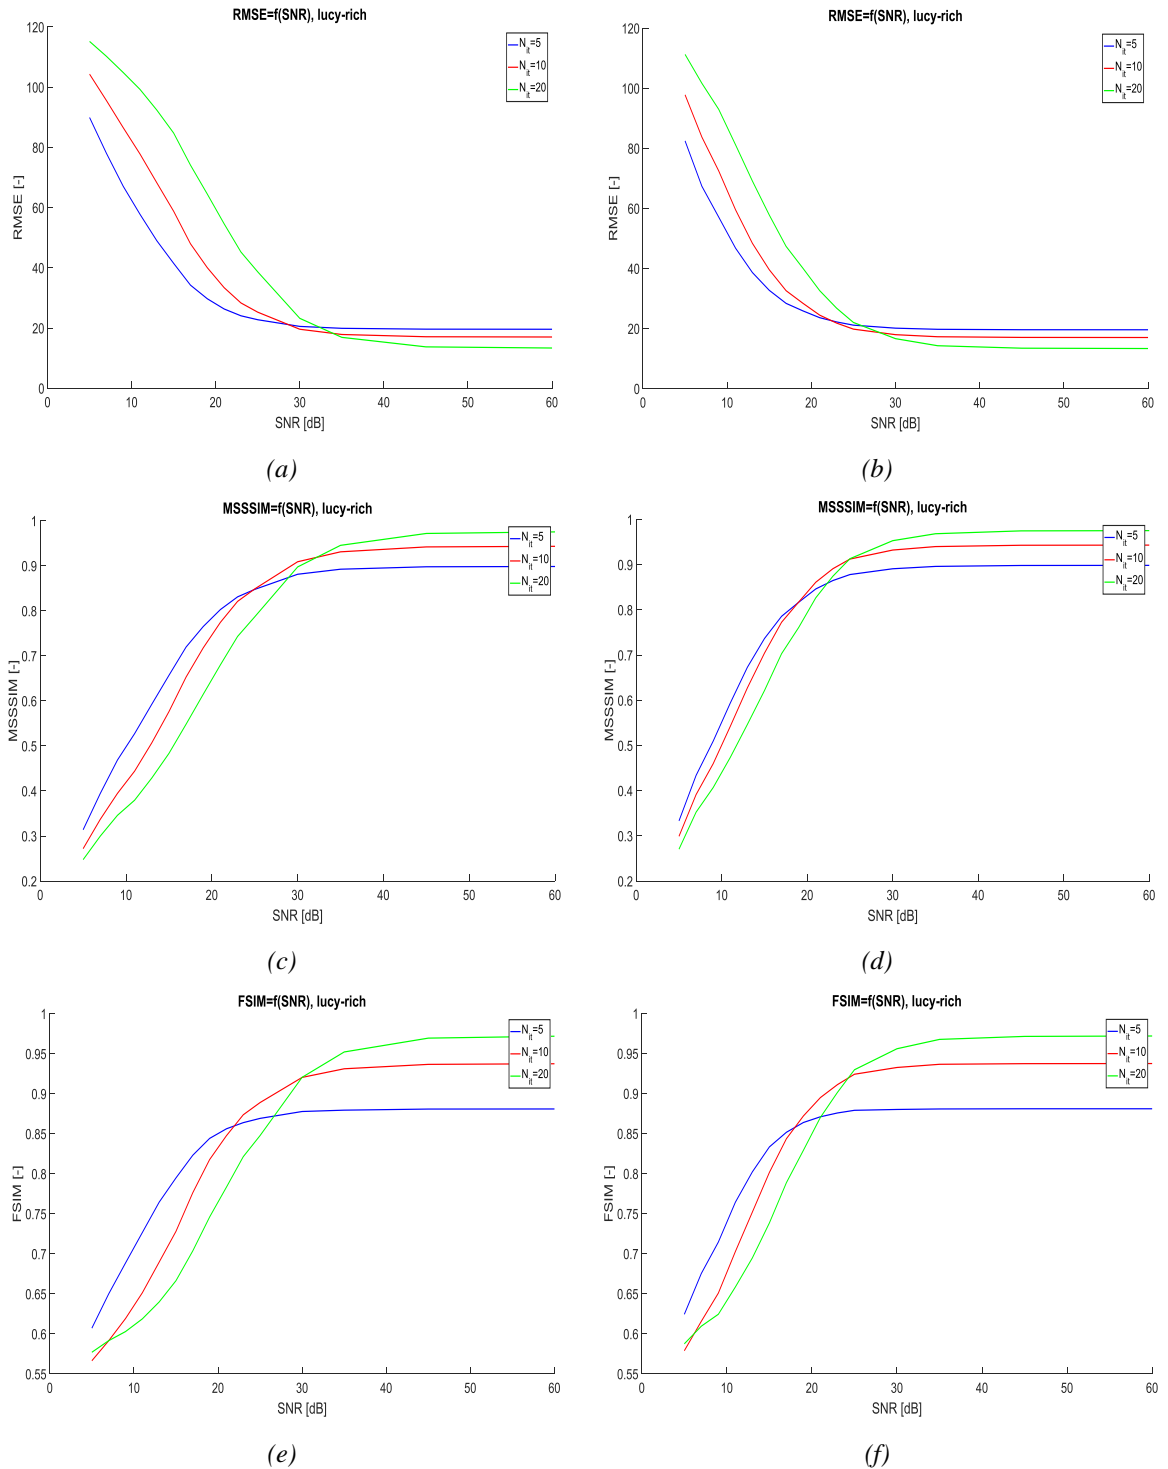



Obr. 28 Závislost RMSE, PSNR, SSIM, MS-SSIM, FSIM, VIF a S3 pro rekonstrukci s regularizovaným filtrem (a), (c), (e), (g), (i), (k), (m) na odhadu parametru NP, (b), (d), (f), (h), (j), (l), (n) na počtu oblastí, obrázek s šumem s Poissonovým rozdělením

Při srovnání rekonstrukce obrázku se šumem s Poissonovým rozdělením (Obr. 28) vůči rekonstrukci obrázku s gaussovským či impulzním šumem (Obr. 26, Obr. 27) vidíme opět jen nepatrný rozdíl v kvalitě. Můžeme ale říci, že šum s Poissonovým rozdělením má menší vliv na rekonstrukci obrázku, než šum gaussovský.

### 7.3 Lucy-Richardsonův algoritmus

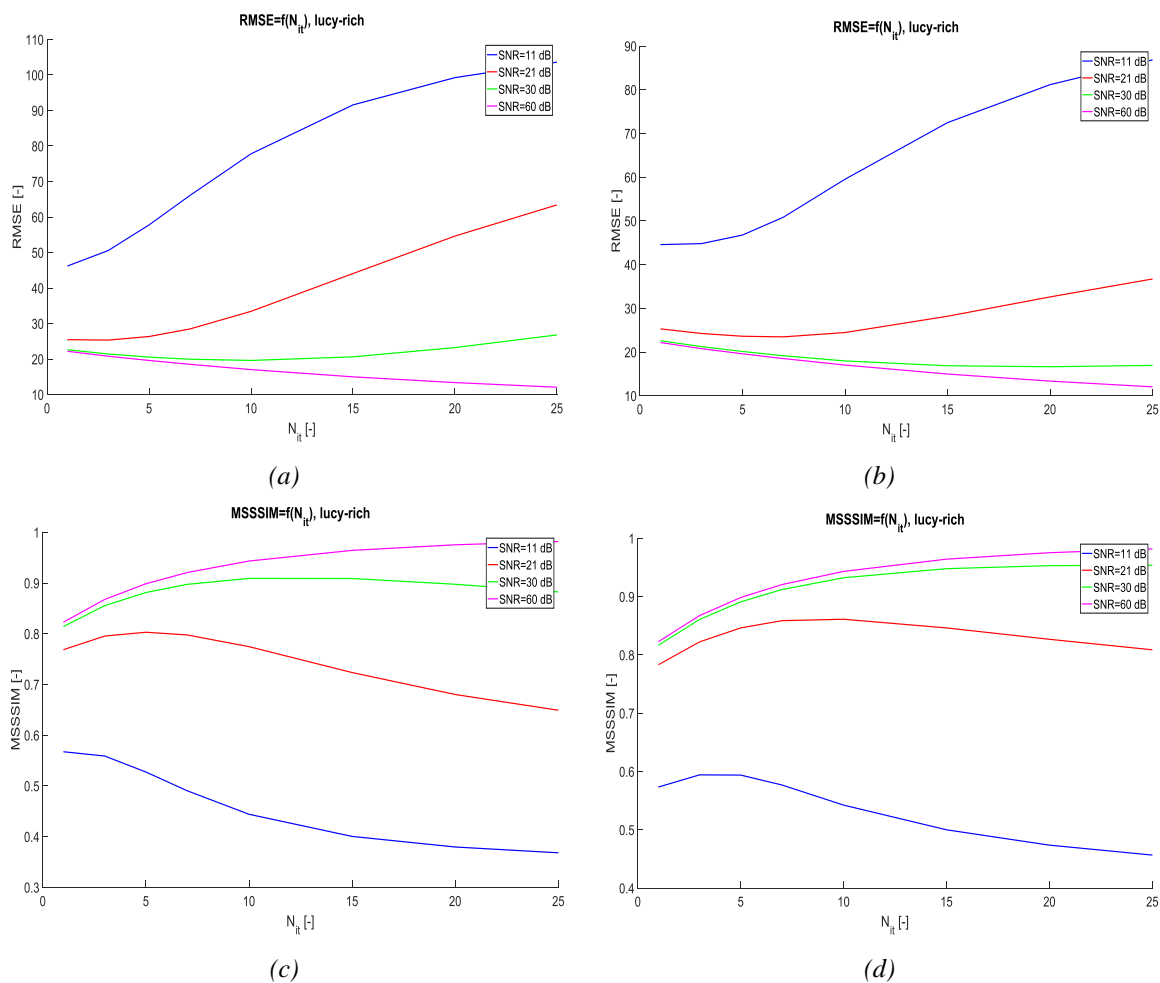
U rekonstrukce pomocí Lucy-Richardsonovým algoritmem můžeme ovlivňovat kvalitu počtem iterací  $N_{it}$ . Nejprve se ale podíváme na závislost kvality na poměru  $SNR$ .



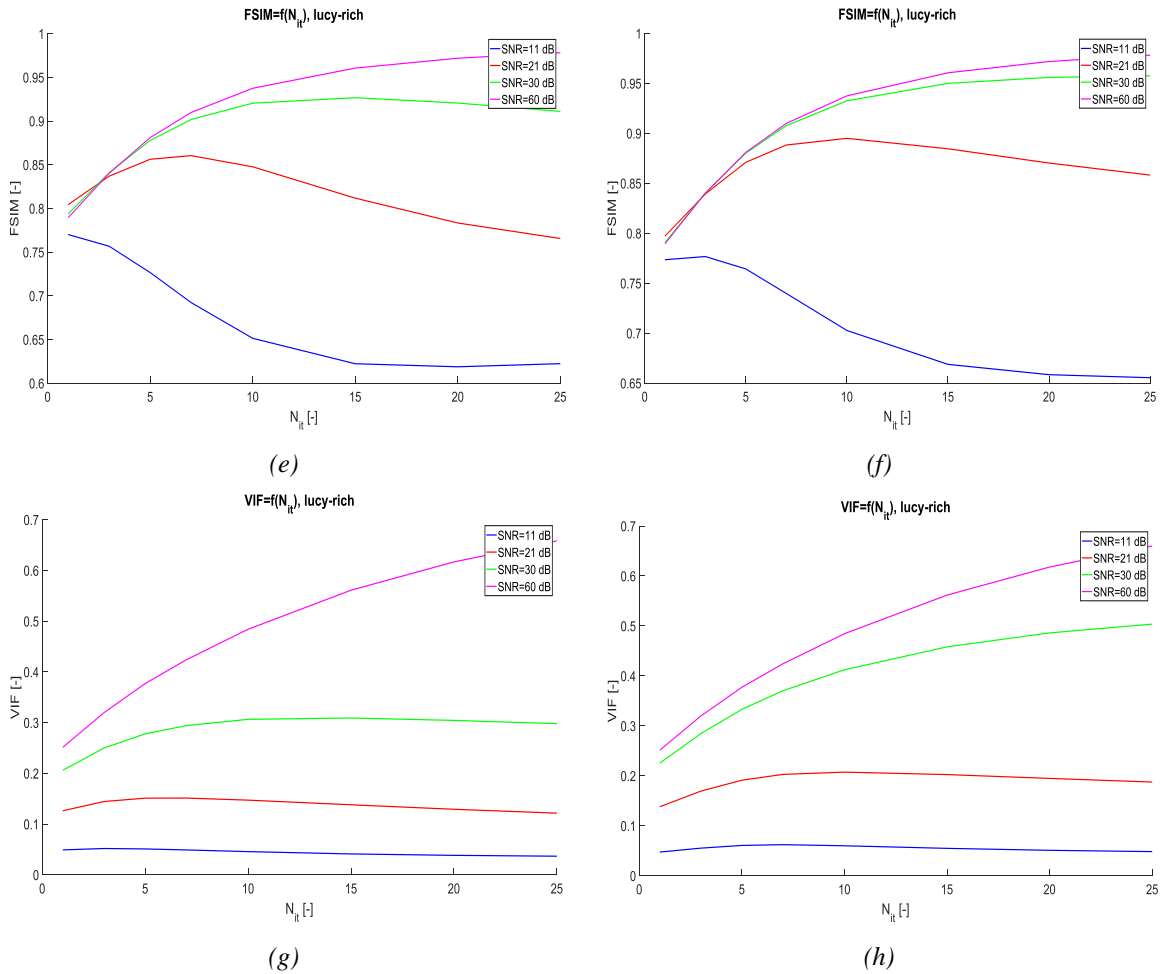


Obr. 29 Závislost RMSE, MS-SSIM, FSIM a VIF na SNR u Lucy-Richardsonova algoritmu, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum

Jak z výše uvedených grafů (Obr. 29) můžeme vidět, vliv impulzního šumu na rekonstrukci je menší než vliv gaussovského šumu. Lze dobře vidět, že pro jednu křivku daného  $N_{it}$  dochází k většímu nárůstu kvality (u charakteristik, které mají tuto tendenci) už při nižších hodnotách SNR v případě impulzního šumu. Tento rozdíl se pohybuje v rozmezí 6 – 10 dB. Můžeme také pozorovat vliv počtu iterací, ale na tuto závislost se podíváme detailněji na dalších obrázcích.








Obr. 30 Závislost RMSE, MS-SSIM, FSIM a VIF na počtu iterací u Lucy-Richardsonova algoritmu, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum

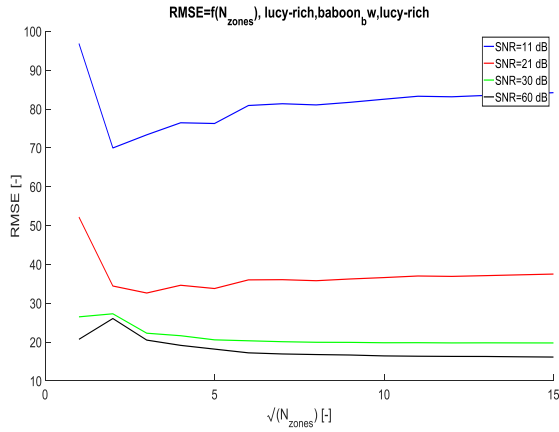
Jak můžeme vidět na výše uvedených obrázcích (Obr. 30), kvalita rekonstrukce Lucy-Richardsonovým algoritmem závisí na počtu provedených iterací. Zpravidla platí, že při vyšším počtu iterací je přesnost a kvalita rekonstrukce vyšší. To platí pro obrázky s velmi nízkým šumem, jak také můžeme vidět z grafů. Pokud je obrázek zašuměný, při větším počtu iterací se kvalita zhoršuje. Příčinou je princip celého algoritmu, který vlastně vytváří takové shluky světlých a tmavých bodů. Tím pádem při velkém šumu se tento šum zesílí. Tento jev demonstrují následující obrázky (Obr. 31).

Pro celkovou kvalitu by bylo možné provést předzpracování obrazu použitím filtrace k potlačení šumu. Například mediánový filtr je efektivní pro potlačení impulzního šumu. Problémem tohoto předzpracování je však přidání dalšího zkreslení – rozostření, které by pak způsobilo nižší kvalitu rekonstrukce, zejména detailů, tedy ztrátu žádoucích vyšších prostorových kmitočtů, což nám v některých případech vadí více než samotný šum (dokážeme přes šum vnímat pro nás důležité detaily, které by se jinak rozmazaly). S předzpracováním obrazu bychom pak hodnotili nejen účinnost samotného algoritmu, ale i filtrace potlačující šum.




Obr. 31 Ukázka zesílení šumu, (a) zkraslený obrázek s impulzním šumem,  $SNR=30$  dB, (b) rekonstruovaný obrázek s imp. šumem, (c) zkraslený obrázek s gaussovským šumem,  $SNR=21$  dB, (d) rekonstruovaný obrázek s gaus. šumem


Na obrázcích Obr. 31 (a), (b) můžeme vidět vliv Lucy-Richardsonova algoritmu na impulzní šum. Lze vidět, že se z původního „zrnka pepře“ vytvoří větší shluk černých bodů. Na obrázcích Obr. 31 (c), (d) pak vidíme vliv na gaussovský šum. Dále se podíváme na závislost na počtu oblastí.




(a)




(b)




(c)




(d)



(e)

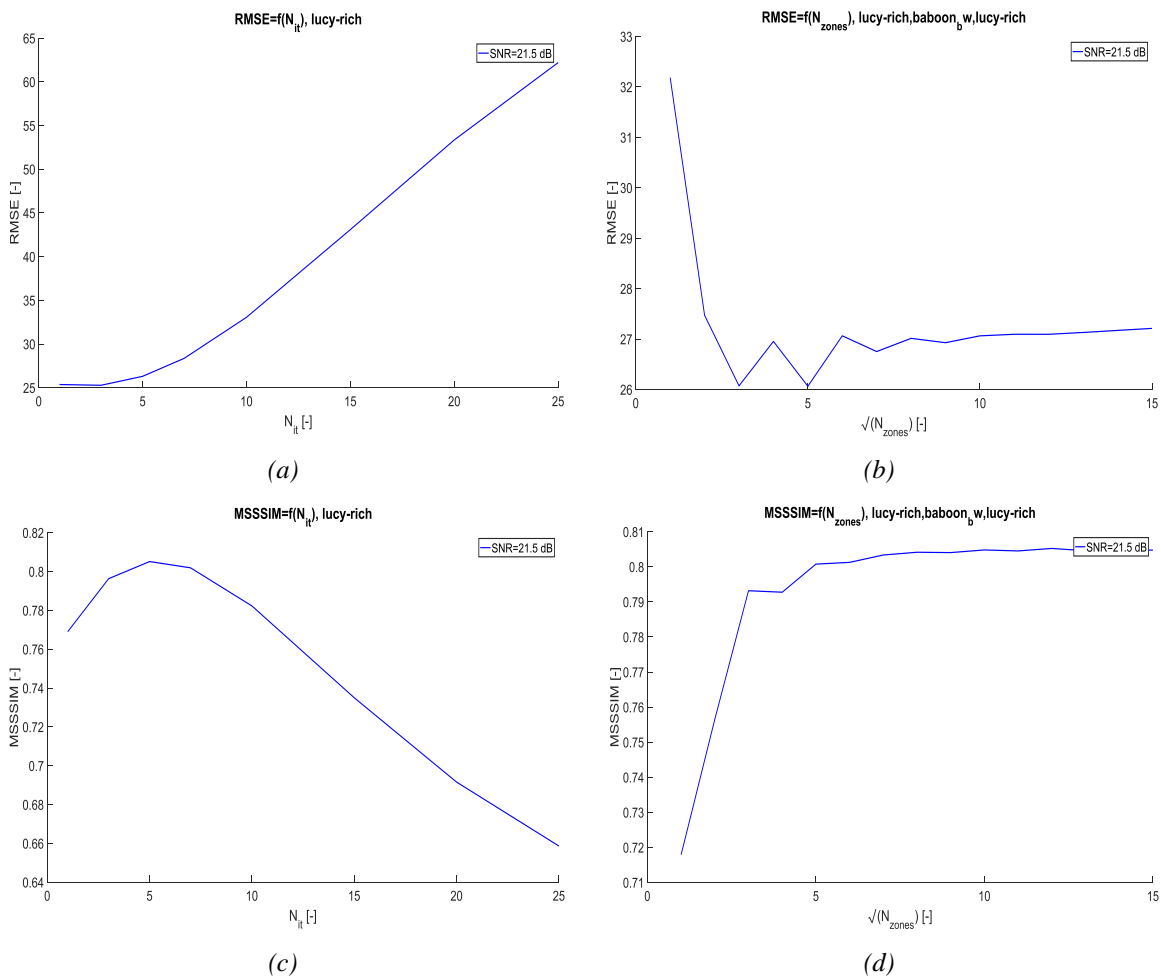


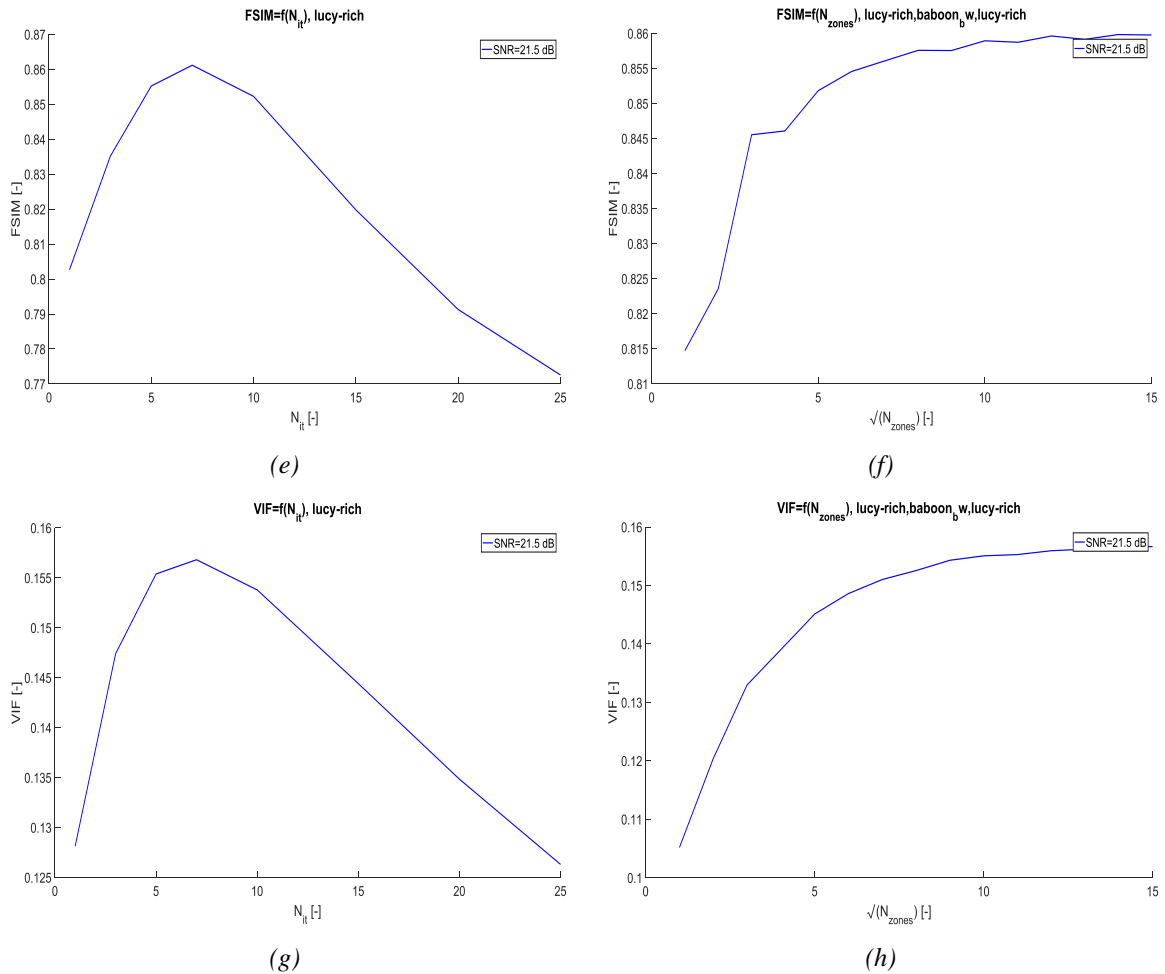
(f)



Obr. 32 Závislost RMSE, MS-SSIM, FSIM a VIF na počtu oblastí u Lucy-Richardsonova algoritmu, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum

Opět si můžeme všimnout efektu potlačení šumu pro  $N_z = 4$ , který je v tomto případě výraznější, než u Wienerovy filtrace. To je způsobeno zesílením šumu (viz Obr. 31) a tím pádem může dojít k většímu potlačení rozmazáním díky nepřesné rekonstrukci. Výsledky pro šum s Poissonovým rozdělením uvidíme v následujících grafech (Obr. 33).






Obr. 33 Závislost RMSE, MS-SSIM, FSIM a VIF pro Lucy-Richardsonův algoritmus, (a), (c), (e), (g) na počtu iterací (b), (d), (f), (h) na počtu oblastí, obrázek s šumem s Poissonovým rozdělením

Rovněž u Lucy-Richardsonova algoritmu vidíme, že rekonstrukce obrázku s šumem s Poissonovým rozdělením dosahuje lepších parametrů, než rekonstrukce obrázku s gaussovským šumem, ale obrázek s impulzním šumem lze rekonstruovat kvalitněji.


## 7.4 Kepstrální dekonvoluce

Při kepstrální dekonvoluci nepoužíváme žádný specifický parametr, budeme tedy porovnávat kvalitu pouze podle počtu oblastí a podle vstupního poměru SNR.


## 7 Analýza výsledků simulace




(a)




(b)




(c)




(d)



(e)




(f)




Obr. 34 Závislost RMSE, MS-SSIM, FSIM a VIF na SNR u keprální dekonvoluce, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum

Kepstrální dekonvoluce neumí potlačit aditivní šum, hodnoty pro  $SNR \leq 30$  dB jsou zpravidla velmi špatné. Pokud se podíváme na rozdíl mezi gaussovským šumem a impulzním šumem, impulzní šum má na kvalitu rekonstrukce podstatně menší vliv. Celková kvalita rekonstrukce je však nižší, hlavním důvodem je neschopnost potlačení geometrického zkreslení. To je zapříčiněno posunem středu PSF při degradaci. Kepstrální dekonvoluce však informaci o posunu ztrácí při Fourierově transformaci PSF a tím pádem nemůže při takovémto zkreslení provést správnou rekonstrukci. Tento jev lze pozorovat na následujícím obrázku.






(c)




(d)

Obr. 35 Ukázka chyby při rekonstrukci geometrického zreslení (a), (b) Wienerova filtrace a RMSE mapa, (c), (d) keprstrální dekonvoluce a RMSE mapa

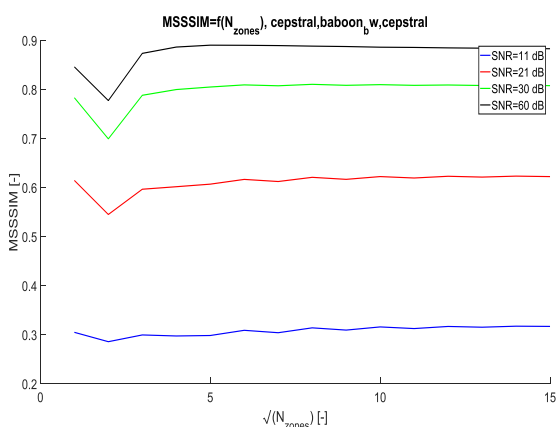
Na RMSE mapě pro keprstrální dekonvoluci vidíme, že směrem ke krajům se zvyšuje RMSE na hranách. V konkrétním obrázku zejména v oblastech kolem oken. Dále se podíváme na závislost na počtu použitých oblastí.




(a)



(b)

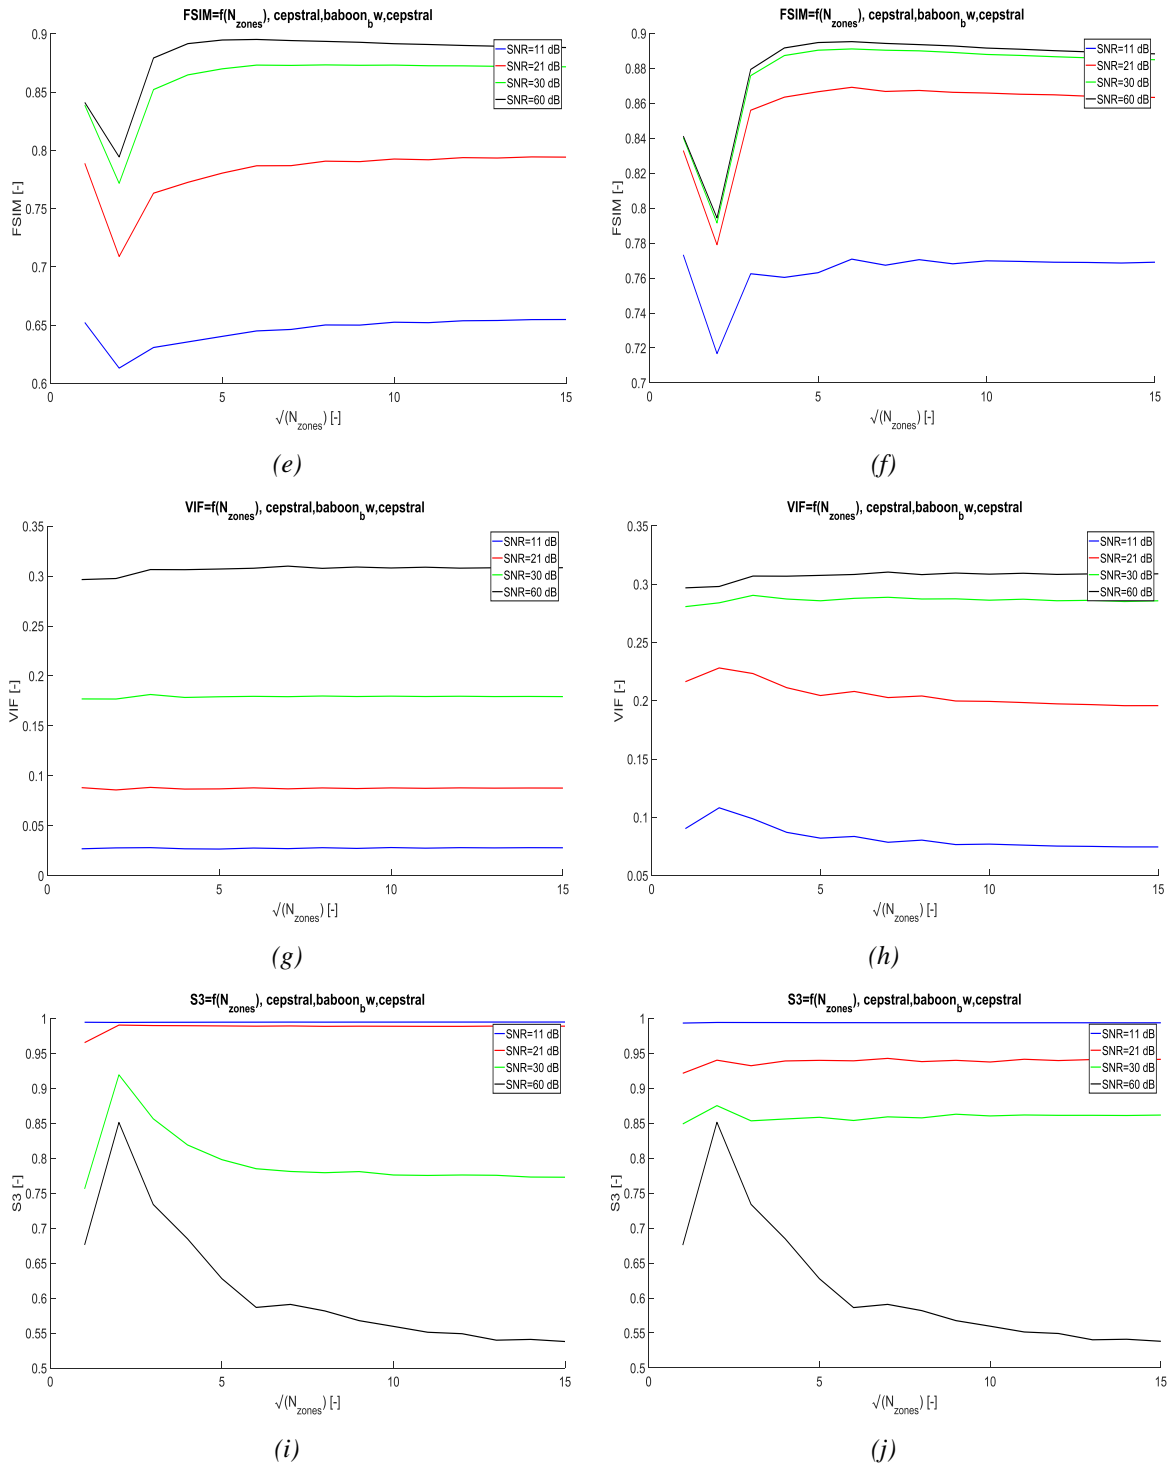


(c)



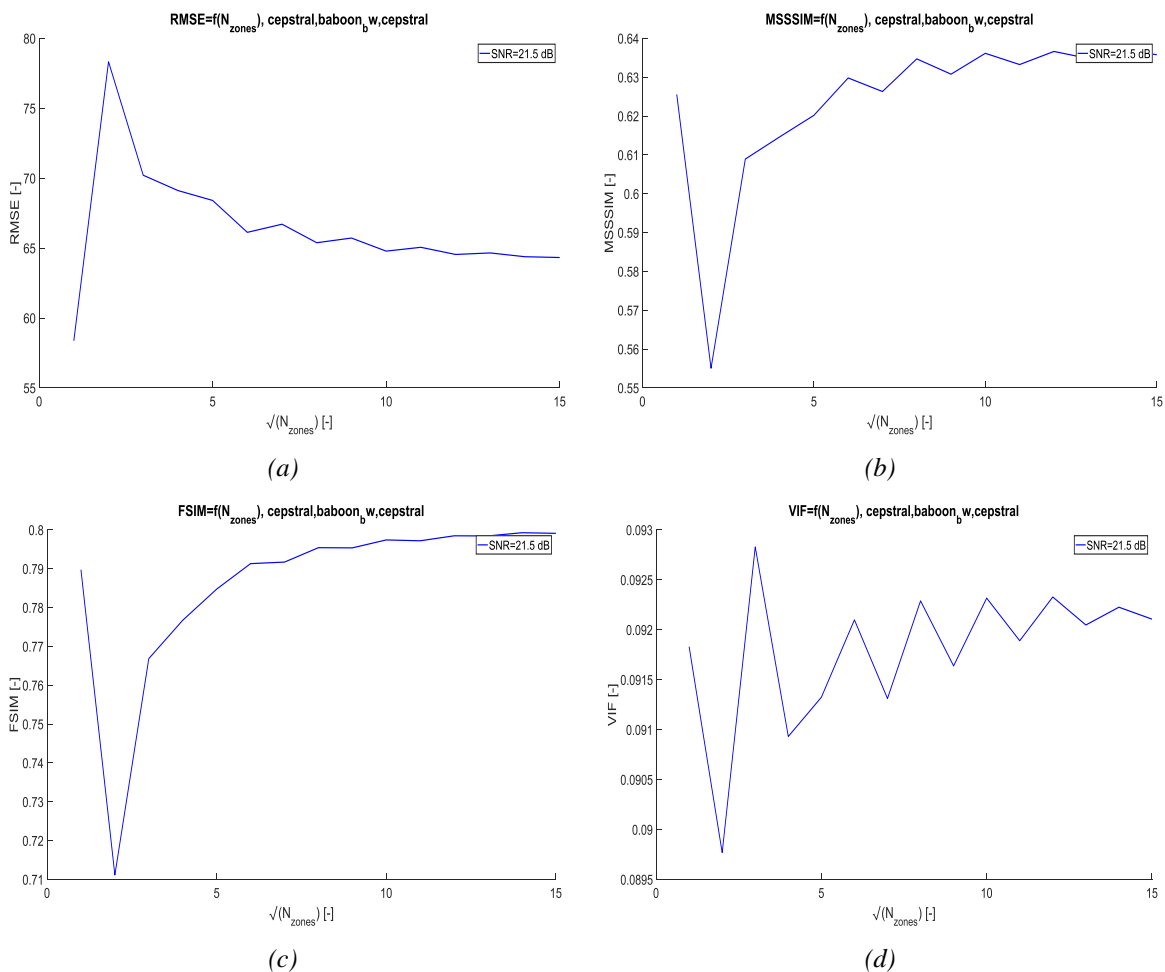
(d)





Obr. 36 Závislost RMSE, MS-SSIM, FSIM, VIF a S3 na počtu oblastí u keprální dekonvoluce, (a), (c), (e), (g), (i) pro gaussovský bílý šum, (b), (d), (f), (h), (j) pro impulzní šum

U keprální dekonvoluce nemáme jako u Wienerovy filtrace jev, kdy při počtu oblastí  $2 \times 2$  došlo k potlačení šumu. Pro obrázky s vysokým poměrem SNR ale dochází k přestření, což je reflektováno jako silný pokles v kvalitě. Metrika  $S_3$  naopak tento nárůst hodnotí kladně, subjektivní vjem je ale spíše negativní.



Obr. 37 Závislost RMSE, PSNR, SSIM, MS-SSIM, FSIM, VIF a S3 na počtu oblastí pro keprální dekonvoluci


Tab. 3 Hodnoty pro šum s Poissonovým rozdělením při keprální dekonvoluci

Keprální dekonvoluce, šum s Poissonovým rozdělením, SNR = 21,5 dB						
RMSE	PSNR	SSIM	MSSSIM	FSIM	VIF	S3
64,32609	3,964177	0,420091	0,635802	0,799106	0,092106	0,989263


Podobně jako u ostatních metrik, šum s Poissonovým rozdělením má podobný vliv jako gaussovský šum. U keprální dekonvoluce, která nepoužívá speciální potlačení šumu, si můžeme všimnout, že impulzní šum mnohem méně ovlivňuje obrázek a tím pádem i výslednou kvalitu rekonstrukce touto metodou.

## 7.5 Porovnání všech algoritmů


Po prozkoumání vlastností jednotlivých algoritmů porovnáme všechny algoritmy s optimálním nastavením přímo vůči sobě. Začneme se závislostí na SNR.




(a)




(b)




(c)




(d)



(e)




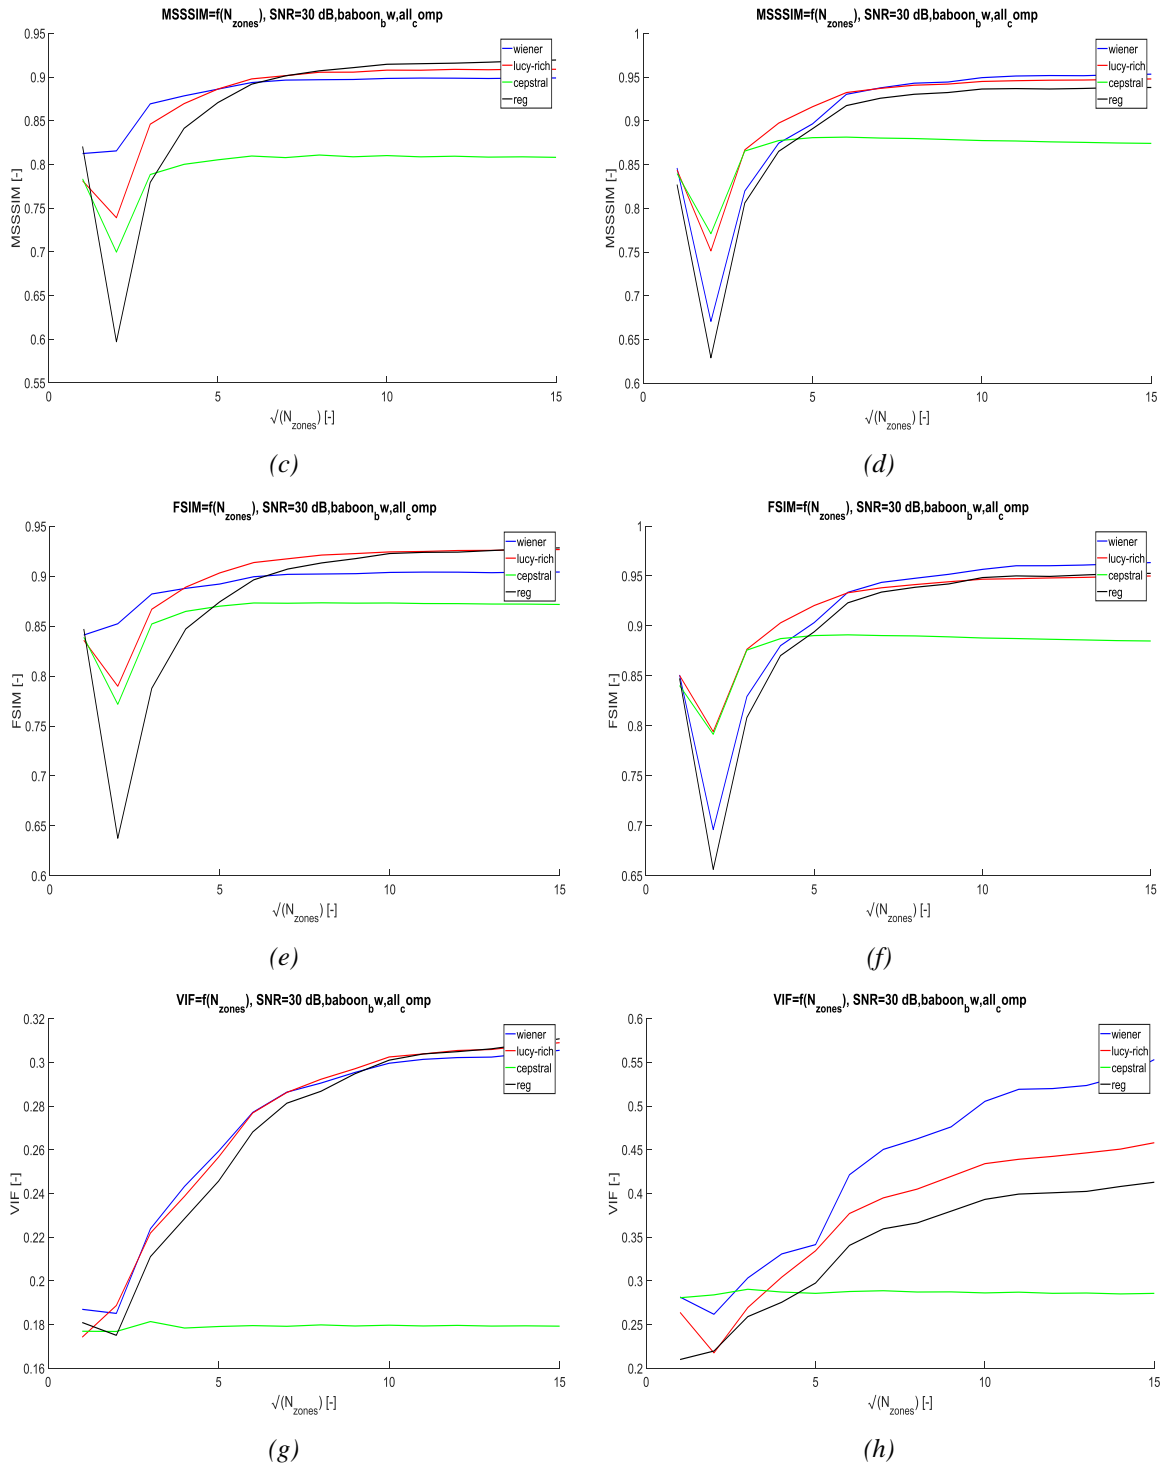
(f)



Obr. 38 Závislost RMSE, MS-SSIM, FSIM a VIF na SNR pro porovnání všech algoritmů, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum

Z grafů (Obr. 38) můžeme vidět, že nejlépe si vede rekonstrukce s regularizovaným filtrem a Wienerova filtrace. Důvodem je schopnost potlačení aditivního šumu těmito algoritmy. Lucy-Richardsonův algoritmus, který byl použit s počtem iterací  $N_{it} = 15$ , dosahuje svých nejlepších výsledků pro  $SNR = 30 \text{ dB}$ . V tomto bodě jsou výsledky podobné prvním dvěma algoritmům. Pro horší poměr odstupů signálu od šumu by bylo vhodnější použít menší počet iterací, pro lepší poměr naopak více iterací. Dále se podíváme na závislost na počtu použitých oblastí.





Obr. 39 Závislost RMSE, MS-SSIM, FSIM a VIF na počtu oblastí pro porovnání všech algoritmů, (a), (c), (e), (g) pro gaussovský bílý šum, (b), (d), (f), (h) pro impulzní šum

Jak vidíme z obrázků (Obr. 39), gaussovský šum má větší vliv na kvalitu obrázku než impulzní šum. Je to dáno tím, že ovlivňuje všechny body v obraze, zatímco impulzní šum má vliv jen na některé body (ty, které vlastně přepíše na určenou hodnotu). To se projevuje hlavně u Wienerovy filtrace, která dokáže rekonstruovat obrázek s impulzním šumem téměř dokonale, problémem je pak oblast bodu se šumem, která je naopak hodně zkruslená. I přesto je však Wienerova filtrace hodnocena u většiny metrik nejlépe, s největším rozdílem u metriky VIF, která

právě oceňuje hlavně přesnou rekonstrukci. Naopak metrikám RMSE a PSNR nejvíce vadí zkreslení šumem, proto je hodnocení těchto metrik špatné. Zajímavostí je i téměř konstantní kvalita u keprální dekonvoluce, která je způsobena opět ztrátou informace o posunu PSF vůči středu Fourierovou transformací.

Tab. 4 Tabulka porovnání závislosti na SNR za pomoci metriky Bjontegaardové

Bjontegaard SNR		Gaussovský šum				Impulzní šum			
		wiener	lucy-rich	cepstral	reg	wiener	lucy-rich	cepstral	reg
RMSE	wiener	0	10,40297	43,16594	-4,10651	0	2,616093	14,22881	-7,2905
	lucy-rich	-10,403	0	32,76297	-14,5095	-2,61609	0	11,61272	-9,90659
	cepstral	-43,1659	-32,763	0	-47,2724	-14,2288	-11,6127	0	-21,5193
	reg	4,106506	14,50948	47,27245	0	7,290495	9,906588	21,5193	0
PSNR	wiener	0	-1,93207	-5,906	1,020	0	0,944	-2,290	3,180
	lucy-rich	1,932072	0	-3,974	2,952	-0,944	0	-3,234	2,236
	cepstral	5,906272	3,9742	0	6,926	2,290	3,234	0	5,470
	reg	-1,01973	-2,9518	-6,926	0	-3,180	-2,236	-5,470	0
SSIM	wiener	0	-0,06699	-0,215	0,033	0	-0,012	-0,027	0,021
	lucy-rich	0,066991	0	-0,14763	0,100084	0,012	0	-0,015	0,033
	cepstral	0,214616	0,147625	0	0,24771	0,027	0,015	0	0,048
	reg	-0,03309	-0,10008	-0,24771	0	-0,02149	-0,03344	-0,04812	0
MSSSIM	wiener	0	-0,05514	-0,21056	0,014269	0	-0,00946	-0,03897	0,012073
	lucy-rich	0,055141	0	-0,15542	0,069411	0,009461	0	-0,0295	0,021534
	cepstral	0,210565	0,155423	0	0,224834	0,038965	0,029504	0	0,051038
	reg	-0,01427	-0,06941	-0,22483	0	-0,01207	-0,02153	-0,05104	0
FSIM	wiener	0	-0,01227	-0,07798	-0,01094	0	-0,00939	-0,03319	-0,02523
	lucy-rich	0,012274	0	-0,06571	0,001333	0,009395	0	-0,02379	-0,01584
	cepstral	0,077982	0,065708	0	0,06704	0,033187	0,023792	0	0,007955
	reg	0,010941	-0,00133	-0,06704	0	0,025232	0,015837	-0,00795	0
VIF	wiener	0	-0,01067	-0,10756	0,003274	0	-0,02822	-0,10786	-0,03336
	lucy-rich	0,010668	0	-0,0969	0,013942	0,028223	0	-0,07964	-0,00513
	cepstral	0,107564	0,096896	0	0,110837	0,107863	0,07964	0	0,074508
	reg	-0,00327	-0,01394	-0,11084	0	0,033355	0,005132	-0,07451	0
S3	wiener	0	0,214586	0,248112	-0,21213	0	-0,06039	-0,05245	-0,43501
	lucy-rich	-0,21459	0	0,033526	-0,42672	0,060393	0	0,007941	-0,37462
	cepstral	-0,24811	-0,03353	0	-0,46024	0,052452	-0,00794	0	-0,38256
	reg	0,21213	0,426716	0,460242	0	0,435015	0,374622	0,382563	0

V tabulce Tab. 4 vidíme porovnání rekonstrukce všech algoritmů v závislosti na SNR mezi sebou pomocí metriky Bjontegaardové, která byla aplikována na křivky z obrázku Obr. 38. Ve sloupcích jsou algoritmy označené zeleně a v řádcích oranžově. Barva buňky označuje, který ze dvou algoritmů je lepší, hodnota uvnitř buňky pak říká, o kolik (v hodnotě dané metriky). Lze tedy

vidět, že rekonstrukce s regularizovaným filtrem a Wienerova filtrace vítězí v drtivé většině srovnání.

Tab. 5 Tabulka porovnání závislosti na počtu oblastí za pomoci metriky Bjontegaardové

Bjontegaard NZ		Gaussovský šum				Impulzní šum				Poissonův šum			
		wnr	l-r	ceps	reg	wnr	l-r	ceps	reg	wnr	l-r	ceps	reg
RMSE	wnr	0,000	12,805	14,035	5,842	0,000	-4,096	-4,240	-2,434	0,000	1,223	42,291	5,415
	l-r	-12,805	0,000	1,230	-6,963	4,096	0,000	-0,145	1,662	-1,223	0,000	41,067	4,192
	ceps	-14,035	-1,230	0,000	-8,193	4,240	0,145	0,000	1,806	-42,291	-41,068	0,000	-36,876
	reg	-5,842	6,963	8,193	0,000	2,434	-1,662	-1,806	0,000	-5,415	-4,192	36,876	0,000
PSNR	wnr	0,000	-4,245	-4,580	-1,606	0,000	1,514	0,937	1,109	0,000	-0,408	-5,980	-1,173
	l-r	4,245	0,000	-0,335	2,638	-1,514	0,000	-0,577	-0,405	0,408	0,000	-5,572	-0,766
	ceps	4,580	0,335	0,000	2,974	-0,937	0,577	0,000	0,172	5,980	5,572	0,000	4,807
	reg	1,606	-2,638	-2,974	0,000	-1,109	0,405	-0,172	0,000	1,173	0,766	-4,807	0,000
SSIM	wnr	0,000	-0,108	-0,103	-0,057	0,000	0,004	0,011	-0,025	0,000	-0,002	-0,228	-0,046
	l-r	0,108	0,000	0,005	0,051	-0,004	0,000	0,007	-0,029	0,002	0,000	-0,226	-0,044
	ceps	0,103	-0,005	0,000	0,045	-0,011	-0,007	0,000	-0,036	0,228	0,226	0,000	0,182
	reg	0,057	-0,051	-0,045	0,000	0,025	0,029	0,036	0,000	0,046	0,044	-0,182	0,000
MSSSIM	wnr	0,000	-0,081	-0,084	-0,057	0,000	0,001	0,003	-0,018	0,000	-0,005	-0,176	-0,060
	l-r	0,081	0,000	-0,003	0,024	-0,001	0,000	0,002	-0,020	0,005	0,000	-0,172	-0,055
	ceps	0,084	0,003	0,000	0,026	-0,003	-0,002	0,000	-0,021	0,176	0,172	0,000	0,116
	reg	0,057	-0,024	-0,027	0,000	0,018	0,019	0,021	0,000	0,060	0,055	-0,116	0,000
FSIM	wnr	0,000	-0,057	-0,035	-0,058	0,000	-0,001	0,003	-0,017	0,000	0,021	-0,051	-0,047
	l-r	0,057	0,000	0,022	-0,001	0,001	0,000	0,005	-0,015	-0,021	0,000	-0,071	-0,068
	ceps	0,035	-0,022	0,000	-0,023	-0,003	-0,005	0,000	-0,020	0,051	0,071	0,000	0,003
	reg	0,058	0,001	0,023	0,000	0,017	0,015	0,020	0,000	0,047	0,068	-0,003	0,000
VIF	wnr	0,000	-0,015	-0,062	-0,008	0,000	-0,022	-0,074	-0,069	0,000	-0,001	-0,046	-0,005
	l-r	0,015	0,000	-0,046	0,008	0,022	0,000	-0,052	-0,047	0,001	0,000	-0,044	-0,004
	ceps	0,062	0,046	0,000	0,054	0,074	0,052	0,000	0,005	0,046	0,044	0,000	0,041
	reg	0,008	-0,008	-0,054	0,000	0,069	0,047	-0,005	0,000	0,005	0,004	-0,041	0,000
S3	wnr	0,000	0,435	0,387	0,074	0,000	-0,059	-0,115	-0,218	0,000	0,169	0,534	0,025
	l-r	-0,435	0,000	-0,048	-0,361	0,059	0,000	-0,056	-0,159	-0,169	0,000	0,365	-0,143
	ceps	-0,387	0,048	0,000	-0,313	0,115	0,056	0,000	-0,103	-0,534	-0,365	0,000	-0,508
	reg	-0,074	0,361	0,313	0,000	0,218	0,159	0,103	0,000	-0,025	0,143	0,508	0,000

V tabulce Tab. 5 srovnáváme algoritmy dle závislosti na počtu oblastí (viz Obr. 39) a na rozdíl od tabulky Tab. 4 zde máme možnost srovnávat, jak si algoritmy poradily se šumem s Poissonovým rozdělením. Pro gaussovský šum a impulzní šum opět dominuje zejména Wienerova filtrace. U šumu s Poissonovým rozdělením se však na druhé místo dostává Lucy-Richardsonův algoritmus. K dalšímu porovnání můžeme využít také dobu výpočtu rekonstrukce z následující tabulky (Tab. 6).

Tab. 6 Výpočetní náročnost algoritmů

<b>baboon.tif, gaussovský šum SNR = 30 dB, <math>N_z = 225</math></b>	<b>t [s]</b>
Wienerova filtrace	4,1577
Regularizovaný filtr	6,4587
Kepstrální dekonvoluce	0,5059
Lucy-Richardsonův algoritmus, $N_{it} = 10$	13,2571
Lucy-Richardsonův algoritmus, $N_{it} = 30$	33,1719

Z tabulky Tab. 6 vidíme, že nejrychlejším algoritmem je kepstrální dekonvoluce. Díky Fourierově transformaci a následně převedení do kepstrální domény, kde konvoluce přechází na sčítání, je dosaženo, v porovnání s jinými metodami, opravdu krátké doby výpočtu. Naopak nejpomalejší je Lucy-Richardsonův algoritmus, kde navíc ještě závisí rychlost výpočtu na zvoleném počtu iterací. Je potřeba zdůraznit, že použité algoritmy i samotná metoda SVOLA nebyly optimalizovány pro rychlost výpočtu. Nicméně podmínky pro všechny algoritmy byly stejné, proto můžeme v konečném srovnání brát ohled i na tento parametr.



## 8 Závěr

Byla úspěšně implementována simulace lineárního prostorově variantního zobrazovacího systému s využitím Zernikových polynomů ke generování bodových rozptylových funkcí a metodou SVOLA pro prostorově variantní konvoluci i dekonvoluci. Pro samotnou rekonstrukci obrázků pak byly použity čtyři zmiňované algoritmy, tedy Wienerova filtrace, rekonstrukce s regularizovaným filtrem, Lucy-Richardsonův algoritmus a keprální dekonvoluce. Testovací obrázek byl zkeslený prostorově variantní PSF s  $15 \times 15$  oblastmi. Po přidání gaussovského, impulzního či Poissonova aditivního šumu pak byl rekonstruován s několika proměnnými parametry. Výsledný obraz pak byl zhodnocen objektivními metrikami s plnou referencí RMSE, PSNR, SSIM, MSSSIM, FSIM, VIF a metrikou bez reference  $S_3$ . Výsledky byly prezentovány na obrázku *baboon.tif*, nicméně výsledky na ostatních obrázcích korespondují.

Z výsledků můžeme říci, že impulzní šum má menší vliv na kvalitu rekonstrukce než gaussovský šum se stejným poměrem SNR. Šum s Poissonovým rozdělením pak má podobný vliv jako šum gaussovský, ve většině případů byl obrázek s Poissonovým šumem rekonstruován nepatrně lépe (např. rozdílem 0,01 u metrik s měřítkem 0 až 1). Dále je jednoznačným výsledkem kvalita prostorově variantní rekonstrukce oproti prostorově invariantní. Největší rozdíl je při potlačení geometrického zkeslení, které prostorově invariantní rekonstrukce nedokáže opravit.

Tento problém má i keprální rekonstrukce. U ní je ale neschopnost odstranění geometrického zkeslení způsobena ztrátou informace o posunu PSF při Fourierově transformaci, která je nutná při převodu z obrazové domény do keprální domény. Nevýhodou keprální dekonvoluce je také absence potlačení aditivního šumu, naopak při silnému šumu dochází k jeho zesílení.

Lucy-Richardsonův algoritmus má podobný problém se zesilováním šumu, lze jej ale regulovat snížením počtu iterací. Důsledkem tohoto kroku je ale horší rekonstrukce obrazu. Lucy-Richardsonův algoritmus funguje výborně pro obrázky s velmi nízkým šumem, pro vysokou kvalitu je ale potřeba větší počet iterací, což se odráží na dlouhé době výpočtu. Na rozdíl od Lucy-Richardsonova algoritmu má rychlejší dobu výpočtu

Wienerova filtrace i rekonstrukce regularizovaným filtrem. Oba tyto algoritmy jsou velmi podobné, dosahují téměř srovnatelných výsledků, zejména pro obrázky s minimálním šumem, kdy se z nich prakticky stává inverzní filtrace. Rozdíl přichází při nižším poměru SNR v obrázku, kdy se oba algoritmy odlišují způsobem potlačení aditivního šumu. Dle metrik FSIM či VIF je o trochu lepší Wienerova filtrace, dle RMSE či SSIM zase rekonstrukce s regularizovaným filtrem. V tomto případě je nutné brát v potaz, právě rozdílné potlačení šumu. U Wienerovy filtrace dochází ke ztmavení celého obrázku a tím k poklesu kontrastu, u rekonstrukce s regularizovaným filtrem

dochází k rozmazání. Z tohoto hlediska bych dal přednost spíše Wienerově filtraci, jelikož dokáže lépe rekonstruovat detaily, i když to je za cenu snížení kontrastu.

Dostáváme se k hodnocení použitelnosti jednotlivých metrik. Na první pohled můžeme říci, že metrika  $S_3$  není vhodná k určování kvality rekonstrukce, jelikož měří ostrost obrázku na základě frekvenčního spektra. Pokud je obrázek pouze šum, dostane nejvyšší známku 1. RMSE či PSNR jsou základní objektivní metriky a jejich výsledky jsou dobře použitelné. Metrika VIF využívá vlnkovou transformaci a její výsledky se mohou mírně lišit od ostatních metrik. Porovnává vizuální informaci v obrázku a za tímto účelem dokáže ignorovat některé artefakty. Tato metrika funguje skvěle, pokud nás právě zajímá hlavně vizuální informace. Pokud chceme hodnotit celkový vjem obrázku, je vhodná metrika SSIM, či její upravené verze MSSSIM nebo FSIM. Pro komplexní zhodnocení kvality by samozřejmě bylo ideální použití několika metrik zároveň. K ověření účinnosti metrik by bylo nutné provést časově i logisticky náročné subjektivní hodnocení kvality se skupinou pozorovatelů.

Právě subjektivní hodnocení kvality by tady mohlo být jedním z možných pokračování práce. Vedle subjektivního hodnocení může být pokračováním i rozšíření o další metody rekonstrukce obrazu, vylepšení stávajících metod (např. regularizovaný filtr se směrovými operátory) či rozšíření na barevné snímky. Také by bylo možné optimalizovat skripty k efektivnějšímu výpočtu a rozšíření na video. Na závěr například proměření vybraného objektivu a přesné modelování za pomoci Zernikových polynomů.

## 9 Literatura

- [1] R. C. Gonzalez, R. E. Woods: *Digital Image Processing*, Pearson, 2002.
- [2] J. L. Starck, E. Pantin and F. Murtagh: *Deconvolution in Astronomy: A Review*, Publications of the Astronomical Society of the Pacific, 114:1051-1069, 2002 October
- [3] M. Hirsch, S. Sra, B. Scholkopf, and S. Harmeling: *Efficient filter flow for space-variant multiframe blind deconvolution*, in *Proc. IEEE Conf. CVPR*, Jun. 2010, pp. 607–614.
- [4] L. Denis, E. Thiebaut, and F. Soulez: *Fast model of space-variant blurring and its application to deconvolution in astronomy*, in *Proc. 18th IEEE ICIP*, 2011, pp. 2817–2820.
- [5] C. Alard: *Image Subtraction Using a Space-Varying Kernel*, *Astron. Astroph. Sup.*, 144, pp. 363-370, 2000.
- [6] J. Wei, C. A. Bouman, and J. P. Allebach: *Fast space-varying convolution using matrix source coding with applications to camera stray light reduction*, *IEEE Transactions on Image Processing*, vol. 23, no. 5, May 2014.
- [7] M. Tallón, J. Mateos, S. D. Babacan, R. Molina, and A. K. Katsaggelos: *Image prior combination in space-variant blur deconvolution for the dual exposure problem*, 7th International Symposium on Image and Signal Processing and Analysis (ISPA 2011).
- [8] T. R. Lauer: *Deconvolution with a spatially-variant PSF*, *Proc. SPIE 4847*, Astronomical Data Analysis II, 167 (December 1, 2002).
- [9] J. G. Nagy, D. P. O’Leary: *Restoring Images Degraded by Spatially Variant Blur*, *SIAM J. Sci. Comp.*, vol. 19, pp. 1063, 1998.
- [10] W. H. Richardson: *Bayesian-based iterative method of image restoration*, *J. Opt. Soc. Amer.*, vol. 62, no. 1, pp. 55–59, 1972.
- [11] L. B. Lucy: *An iterative technique for the rectification of observed distributions*, *Astron. J.*, vol. 79, pp. 745+, 1974.
- [12] Maja Temerinac-Ott: *Tile-based Lucy-Richardson Deconvolution Modeling a Spatially-Varying PSF for Fast Multiview Fusion of Microscopical Images*, University of Freiburg, 2010, [cit. 2016-12-10], dostupné na: <http://lmb.informatik.uni-freiburg.de/Publications/2010/Tem10a/LucyRichardsonDeconvolution.pdf>
- [13] H. Asai, Y. Oyamade, J. Pilet and H. Saito: *Cepstral analysis based blind deconvolution for motion blur*, *IEEE International Conference on Image Processing (ICIP)*, pp. 1153-1156 (2010).
- [14] M. Rerabek and P. Pata: *Modeling of the widefield space variant security systems*, 2008 42nd Annual IEEE International Carnahan Conference on Security Technology, Prague, 2008, pp. 121-125.
- [15] J. C. Wyant and K. Creath: *Basic wavefront aberration theory for optical metrology*. *Applied Optics and Optical Engineering*, vol. 11, no. s 29, 1992

- [16] Z. Wang, A. C. Bovik, H. R. Sheikh and E. P. Simoncelli: *Image quality assessment: From error visibility to structural similarity*, *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600-612, Apr. 2004, [cit. 2016-10-10], dostupné na: <http://www.cns.nyu.edu/~lcv/ssim/>
- [17] P. Y. Maeda: *Zernike polynomials and their use in describing wavefront aberrations of the human eye*. Stanford University, 2003, [cit. 2016-10-10], dostupné na: <ftp://ftp.bioeng.auckland.ac.nz/jtur044/references/introductory/zernike-wavefront-aberrations.pdf>
- [18] M. Řeřábek: *Simulation and Optimization of Special Optical Imaging Systems*, Doctoral Thesis, CTU in Prague, 2012
- [19] A. S. Carasso: *APEX blind deconvolution of color Hubble space telescope imagery and other astronomical data*, *Optical Engineering* 45(10), 107004 (October 2006), [cit. 2016-10-10], dostupné na: [http://www.stsci.edu/~mutchler/documents/ACS\\_APEX\\_NIST.pdf](http://www.stsci.edu/~mutchler/documents/ACS_APEX_NIST.pdf)
- [20] J. N. Caron: *Application of SeDDaRA Blind Deconvolution for Efficient Improvement of Confocal Microscopy Images*, Quarktet Tech Note, 2011, [cit. 2016-10-10], dostupné na: <http://www.quarktet.com/pdfs/Quarktet-ConfocalMicroscopy.pdf>
- [21] Sang Hwa Lee, Nam Ik Cho and Jong-Il Park: *Directional regularisation for constrained iterative image restoration*, in *Electronics Letters*, vol. 39, no. 23, pp. 1642-3-, 13 Nov. 2003.
- [22] Kodak Lossless True Color Image Suite – sada testovacích obrázků, [cit. 2016-12-10], dostupné na: <http://r0k.us/graphics/kodak/>
- [23] Lin Zhang, Lei Zhang, X. Mou and D. Zhang: *FSIM: A Feature Similarity Index for Image Quality Assessment*, *IEEE Trans. Image Processing*, vol. 20, no. 8, pp. 2378-2386, 2011, [cit. 2016-12-10], dostupné na: <http://www4.comp.polyu.edu.hk/~cslzhang/IQA/FSIM/FSIM.htm>
- [24] Z. Wang, E. P. Simoncelli and A. C. Bovik: *Multiscale structural similarity for image quality assessment*, *The Thirty-Seventh Asilomar Conference on Signals, Systems & Computers, 2003*, 2003, pp. 1398-1402 Vol.2.
- [25] Evaluation of Multiscale-SSIM (MS-SSIM), Lin Zhang, Dept. Computing, The Hong Kong Polytechnic University – skript MS-SSIM ke stažení, [cit. 2016-12-10], dostupné na: [http://sse.tongji.edu.cn/linzhang/IQA/Evaluation\\_MS\\_SSIM/eva-MS-SSIM.htm](http://sse.tongji.edu.cn/linzhang/IQA/Evaluation_MS_SSIM/eva-MS-SSIM.htm)
- [26] H. R. Sheikh and A. C. Bovik: *Image information and visual quality*, in *IEEE Transactions on Image Processing*, vol. 15, no. 2, pp. 430-444, Feb. 2006.
- [27] C. T. Vu and D. M. Chandler: *S3: A Spectral and Spatial Sharpness Measure*, *2009 First International Conference on Advances in Multimedia*, Colmar, 2009, pp. 37-43.
- [28] J. Novovičová: *Pravděpodobnost a matematická statistika*, Skripta ČVUT, 1999, [cit. 2017-01-01], dostupné na: <http://euler.fd.cvut.cz/publikace/files/skripta3.pdf>

- 
- [29] G. Bjontegaard: *Calculation of Average PSNR Differences between RD-Curves*, Document VCEG-M33, 2001.
- [30] Frits Zernike – Biographical. *Nobelprize.org*. Nobel Media AB 2014. [cit. 2017-01-03], [http://www.nobelprize.org/nobel\\_prizes/physics/laureates/1953/zernike-bio.html](http://www.nobelprize.org/nobel_prizes/physics/laureates/1953/zernike-bio.html)
- [31] S. Matyunin: Bjontegaard metric calculation (BD – PSNR) – skript metriky Bjontegaardové ke stažení, [cit. 2017-01-05], dostupné na: <https://www.mathworks.com/matlabcentral/fileexchange/41749-bjontegaard-metric-calculation--bd-psnr-/content/bjontegaard2.m>
- [32] C. T. Vu, T. D. Phan and D. M. Chandler:  $S_3$ : A Spectral and Spatial Measure of Local Perceived Sharpness in Natural Images – Online Supplement, [cit. 2017-01-05], dostupné na: <http://vision.eng.shizuoka.ac.jp/s3/>
- [33] Laboratory for Image and Video Engineering – The University of Texas at Austin, sada skriptů pro výpočet VIF ke stažení, [cit. 2017-01-05], dostupné na: <http://live.ece.utexas.edu/research/quality/>

# 10 Přílohy

## 10.1 Příloha A - Obsah datového nosiče

Na přiloženém datovém nosiči najdeme:

- Text práce ve formátu PDF
- Použité skripty a funkce pro MATLAB
  - Skript *psf\_generation.m* pro generování PSF
  - Skript *blurring.m* pro zkreslení obrázku
  - Skript *noising.m* pro zašumění obrázku
  - Skript *debl\_snr.m* pro rekonstrukci v závislosti na SNR
  - Skript *debl\_par.m* pro rekonstrukci v závislosti na parametru algoritmu
  - Skript *debl\_var\_zones.m* pro rekonstrukci v závislosti na počtu oblastí
  - Skript *time\_measurement.m* pro měření doby výpočtu rekonstrukce
  - Funkce *sv\_conv2\_grid.m* pro prostorově variantní konvoluci
  - Funkce *sv\_deconv2\_grid.m* pro prostorově variantní rekonstrukci
  - Balíček funkcí k výpočtu metriky SSIM
  - Balíček funkcí k výpočtu metriky MS-SSIM
  - Balíček funkcí k výpočtu metriky FSIM
  - Balíček funkcí k výpočtu metriky VIF
  - Balíček funkcí k výpočtu metriky  $S_3$
  - Balíček funkcí k výpočtu metriky Bjontegaardové
- Testovací obrázky
- Soubor *tabulky.pdf* obsahující zbývající tabulky ke grafům z kapitoly 7

## 10.2 Příloha B – Tabulky hodnot ke grafům z kapitoly 7.5

Tab. 7 Hodnoty závislosti RMSE na SNR pro porovnání všech algoritmů

RMSE SNR [dB]	Gaussovský šum				Impulzní šum			
	wiener	lucy-rich	cepstral	reg	wiener	lucy-rich	cepstral	reg
5	58,67	81,69	121,14	49,08	52,27	78,12	98,85	34,72
7	51,90	70,81	117,02	44,99	46,29	63,92	85,40	29,99
9	46,03	63,08	112,66	34,90	44,05	55,36	74,55	44,95
11	41,20	57,77	107,45	37,15	41,44	46,76	62,32	36,06
13	37,08	52,71	101,31	34,25	39,11	39,87	52,10	30,19
15	33,60	47,98	94,25	32,23	37,02	34,55	43,95	27,04
17	30,48	41,89	84,10	24,09	34,49	30,18	37,26	24,79
19	28,05	37,56	75,03	23,45	33,24	27,52	33,45	26,84
21	26,06	33,42	65,47	22,69	30,74	24,46	29,57	24,58
23	24,40	29,72	56,20	21,91	28,75	22,08	27,15	22,86
25	23,15	27,33	49,35	22,16	25,74	19,85	25,19	21,36
30	20,03	20,61	33,03	18,68	20,76	16,87	23,21	18,17
35	17,59	16,78	26,13	16,21	15,06	14,94	22,48	14,92
45	13,26	13,29	22,62	11,62	12,24	12,93	22,21	9,60
60	8,39	11,01	22,19	8,64	16,25	10,98	22,17	8,51

Tab. 8 Hodnoty závislosti RMSE na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB

RMSE Nz	Gaussovský šum				Impulzní šum				Poissonův šum			
	wnr	l-r	ceps	reg	wnr	l-r	ceps	reg	wnr	l-r	ceps	reg
1	28,36	45,38	58,89	24,94	26,41	26,19	29,28	25,10	28,22	32,18	58,37	24,92
2	27,02	31,61	79,09	41,63	36,68	29,02	35,65	47,79	26,74	27,47	78,33	48,64
3	26,05	29,69	71,23	28,77	33,44	25,69	29,86	33,16	25,77	26,07	70,21	33,3
4	26,06	31,60	70,17	25,53	31,67	25,26	29,60	29,60	25,89	26,95	69,12	29,01
5	25,74	30,58	69,43	24,23	32,46	25,06	29,61	27,51	25,48	26,06	68,41	27,27
6	25,96	32,43	67,20	23,75	30,28	24,27	29,17	26,43	25,8	27,06	66,13	26,35
7	25,80	32,29	67,77	23,42	30,62	24,39	29,52	26,09	25,61	26,75	66,71	25,89
8	25,98	32,27	66,57	23,22	30,02	24,20	29,20	25,59	25,83	27,01	65,38	25,51
9	25,91	32,54	66,85	23,11	30,77	24,46	29,48	25,13	25,74	26,93	65,72	25,35
10	25,99	32,78	65,95	22,94	30,29	24,20	29,31	24,82	25,85	27,06	64,78	25,07
11	25,96	33,06	66,18	22,92	30,64	24,43	29,53	24,89	25,81	27,09	65,06	24,98
12	26,02	32,98	65,71	22,86	30,60	24,28	29,43	25,04	25,87	27,09	64,55	24,93
13	26,03	33,15	65,79	22,80	30,81	24,51	29,55	24,82	25,87	27,13	64,65	24,86
14	26,06	33,29	65,54	22,75	30,69	24,38	29,53	24,63	25,91	27,17	64,38	24,83
15	26,06	33,42	65,47	22,69	30,74	24,46	29,57	24,58	25,91	27,21	64,33	24,76

Tab. 9 Hodnoty závislosti PSNR na SNR pro porovnání všech algoritmů

PSNR	Gaussovský šum				Impulzní šum			
	SNR [dB]	wiener	lucy-rich	cepstral	reg	wiener	lucy-rich	cepstral
5	4,35	3,12	2,11	5,20	4,88	3,26	2,58	7,34
7	4,91	3,60	2,18	5,67	5,51	3,99	2,99	8,50
9	5,54	4,04	2,26	7,31	5,79	4,61	3,42	5,67
11	6,19	4,41	2,37	6,86	6,15	5,45	4,09	7,07
13	6,88	4,84	2,52	7,45	6,52	6,40	4,89	8,45
15	7,59	5,31	2,71	7,91	6,89	7,38	5,80	9,43
17	8,37	6,09	3,03	10,59	7,39	8,45	6,84	10,29
19	9,09	6,79	3,40	10,87	7,67	9,27	7,62	9,50
21	9,79	7,63	3,89	11,24	8,30	10,42	8,62	10,37
23	10,45	8,58	4,54	11,64	8,87	11,55	9,39	11,15
25	11,01	9,33	5,17	11,50	9,91	12,85	10,12	11,94
30	12,73	12,37	7,72	13,65	12,28	15,12	10,98	14,04
35	14,49	15,20	9,76	15,73	16,94	17,07	11,34	17,09
45	19,23	19,19	11,27	21,95	20,83	19,72	11,48	26,56
60	30,39	23,17	11,49	29,52	15,69	23,23	11,50	29,97

Tab. 10 Hodnoty závislosti PSNR na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB

PSNR	Gaussovský šum				Impulzní šum				Poissonův šum			
	Nz	wnr	l-r	ceps	reg	wnr	l-r	ceps	reg	wnr	l-r	ceps
1	8,99	5,62	4,33	10,23	9,66	9,74	8,71	10,16	9,04	7,92	4,37	10,23
2	9,44	8,07	3,22	6,12	6,95	8,79	7,15	5,34	9,54	9,28	3,26	5,24
3	9,79	8,59	3,58	8,86	7,63	9,93	8,54	7,69	9,9	9,78	3,63	7,66
4	9,79	8,07	3,63	9,99	8,05	10,09	8,62	8,62	9,85	9,46	3,69	8,79
5	9,91	8,34	3,67	10,52	7,86	10,18	8,61	9,27	10,01	9,78	3,73	9,35
6	9,82	7,86	3,79	10,73	8,42	10,51	8,74	9,65	9,88	9,42	3,86	9,68
7	9,88	7,90	3,76	10,89	8,33	10,46	8,64	9,77	9,96	9,53	3,82	9,85
8	9,81	7,90	3,83	10,98	8,49	10,54	8,73	9,97	9,87	9,44	3,9	10
9	9,84	7,84	3,81	11,03	8,29	10,43	8,65	10,15	9,91	9,47	3,88	10,06
10	9,81	7,78	3,87	11,12	8,42	10,54	8,70	10,27	9,87	9,42	3,94	10,17
11	9,82	7,71	3,85	11,12	8,32	10,44	8,63	10,24	9,88	9,41	3,92	10,21
12	9,80	7,73	3,88	11,16	8,33	10,50	8,67	10,19	9,86	9,41	3,95	10,23
13	9,80	7,69	3,88	11,19	8,28	10,40	8,63	10,27	9,86	9,4	3,94	10,26
14	9,79	7,66	3,89	11,21	8,31	10,46	8,64	10,35	9,84	9,38	3,96	10,27
15	9,79	7,63	3,89	11,24	8,30	10,42	8,62	10,37	9,84	9,37	3,96	10,3



Tab. 11 Hodnoty závislosti SSIM na SNR pro porovnání všech algoritmů

SSIM	Gaussovský šum				Impulzní šum			
	SNR [dB]	wiener	lucy-rich	cepstral	reg	wiener	lucy-rich	cepstral
5	0,26	0,14	0,07	0,30	0,22	0,14	0,20	0,31
7	0,32	0,19	0,09	0,36	0,27	0,21	0,27	0,39
9	0,37	0,25	0,10	0,43	0,30	0,27	0,33	0,31
11	0,41	0,28	0,13	0,43	0,36	0,35	0,40	0,40
13	0,45	0,33	0,16	0,47	0,43	0,44	0,48	0,50
15	0,50	0,39	0,21	0,52	0,51	0,52	0,55	0,55
17	0,55	0,46	0,27	0,61	0,59	0,60	0,62	0,61
19	0,60	0,52	0,33	0,66	0,65	0,66	0,67	0,63
21	0,64	0,59	0,40	0,69	0,73	0,73	0,72	0,68
23	0,68	0,65	0,48	0,73	0,78	0,79	0,75	0,74
25	0,71	0,69	0,53	0,74	0,83	0,83	0,78	0,78
30	0,80	0,82	0,69	0,84	0,91	0,89	0,81	0,88
35	0,86	0,89	0,77	0,89	0,96	0,93	0,82	0,94
45	0,94	0,95	0,81	0,95	0,97	0,95	0,82	0,97
60	0,98	0,97	0,82	0,97	0,94	0,97	0,82	0,97

Tab. 12 Hodnoty závislosti SSIM na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB

SSIM	Gaussovský šum				Impulzní šum				Poissonův šum			
	Nz	wnr	l-r	ceps	reg	wnr	l-r	ceps	reg	wnr	l-r	ceps
1	0,57	0,43	0,39	0,59	0,70	0,65	0,70	0,60	0,57	0,53	0,41	0,6
2	0,59	0,57	0,33	0,44	0,56	0,63	0,65	0,41	0,6	0,61	0,35	0,38
3	0,62	0,60	0,37	0,61	0,64	0,68	0,73	0,58	0,63	0,64	0,39	0,55
4	0,62	0,59	0,38	0,65	0,67	0,70	0,73	0,62	0,63	0,63	0,39	0,61
5	0,63	0,59	0,38	0,67	0,67	0,70	0,73	0,65	0,63	0,63	0,4	0,64
6	0,64	0,60	0,39	0,68	0,72	0,72	0,74	0,67	0,64	0,63	0,41	0,66
7	0,64	0,59	0,39	0,68	0,72	0,72	0,73	0,67	0,64	0,64	0,41	0,66
8	0,64	0,60	0,40	0,69	0,73	0,73	0,73	0,67	0,64	0,64	0,42	0,67
9	0,64	0,59	0,40	0,69	0,72	0,73	0,73	0,68	0,64	0,64	0,41	0,67
10	0,64	0,59	0,40	0,69	0,73	0,73	0,73	0,68	0,64	0,64	0,42	0,67
11	0,64	0,59	0,40	0,69	0,73	0,73	0,73	0,68	0,64	0,64	0,42	0,67
12	0,64	0,59	0,40	0,69	0,73	0,73	0,72	0,68	0,64	0,64	0,42	0,67
13	0,64	0,59	0,40	0,69	0,72	0,73	0,72	0,68	0,64	0,64	0,42	0,67
14	0,64	0,59	0,40	0,69	0,73	0,73	0,72	0,68	0,64	0,64	0,42	0,67
15	0,64	0,59	0,40	0,69	0,73	0,73	0,72	0,68	0,64	0,64	0,42	0,67

Tab. 13 Hodnoty závislosti MSSSIM na SNR pro porovnání všech algoritmů

MSSSIM	Gaussovský šum				Impulzní šum			
	SNR [dB]	wiener	lucy-rich	cepstral	reg	wiener	lucy-rich	cepstral
5	0,47	0,35	0,21	0,48	0,42	0,34	0,42	0,49
7	0,54	0,42	0,24	0,55	0,49	0,44	0,48	0,58
9	0,59	0,49	0,27	0,62	0,53	0,51	0,53	0,51
11	0,63	0,53	0,32	0,63	0,59	0,59	0,59	0,61
13	0,67	0,58	0,37	0,67	0,66	0,67	0,64	0,69
15	0,71	0,63	0,43	0,71	0,72	0,73	0,70	0,74
17	0,74	0,68	0,50	0,79	0,78	0,78	0,75	0,78
19	0,78	0,73	0,56	0,81	0,82	0,82	0,79	0,79
21	0,80	0,77	0,62	0,84	0,86	0,86	0,82	0,83
23	0,83	0,81	0,68	0,86	0,89	0,89	0,84	0,86
25	0,85	0,84	0,72	0,87	0,92	0,92	0,86	0,89
30	0,90	0,91	0,81	0,92	0,95	0,95	0,87	0,94
35	0,93	0,95	0,85	0,95	0,98	0,96	0,88	0,97
45	0,97	0,97	0,88	0,98	0,98	0,98	0,88	0,99
60	0,99	0,99	0,88	0,99	0,97	0,99	0,88	0,99

Tab. 14 Hodnoty závislosti MSSSIM na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB

MSSSIM	Gaussovský šum				Impulzní šum				Poissonův šum			
	Nz	wnr	l-r	ceps	reg	wnr	l-r	ceps	reg	wnr	l-r	ceps
1	0,74	0,65	0,61	0,76	0,81	0,79	0,80	0,76	0,74	0,72	0,63	0,76
2	0,76	0,71	0,55	0,57	0,69	0,74	0,73	0,55	0,76	0,76	0,56	0,53
3	0,79	0,76	0,60	0,74	0,79	0,82	0,82	0,71	0,79	0,79	0,61	0,7
4	0,79	0,77	0,60	0,79	0,82	0,83	0,82	0,77	0,8	0,79	0,61	0,76
5	0,80	0,77	0,61	0,81	0,82	0,84	0,82	0,80	0,8	0,8	0,62	0,79
6	0,80	0,78	0,62	0,82	0,85	0,86	0,83	0,81	0,8	0,8	0,63	0,81
7	0,80	0,78	0,61	0,83	0,85	0,86	0,82	0,82	0,81	0,8	0,63	0,81
8	0,80	0,78	0,62	0,83	0,86	0,86	0,82	0,82	0,81	0,8	0,63	0,82
9	0,80	0,78	0,62	0,83	0,85	0,86	0,82	0,82	0,81	0,8	0,63	0,82
10	0,80	0,78	0,62	0,83	0,86	0,86	0,82	0,82	0,81	0,8	0,64	0,82
11	0,80	0,78	0,62	0,83	0,86	0,86	0,82	0,82	0,81	0,8	0,63	0,82
12	0,80	0,78	0,62	0,84	0,86	0,86	0,82	0,82	0,81	0,81	0,64	0,82
13	0,80	0,78	0,62	0,84	0,86	0,86	0,82	0,83	0,81	0,8	0,63	0,82
14	0,80	0,78	0,62	0,84	0,86	0,86	0,82	0,83	0,81	0,81	0,64	0,82
15	0,80	0,77	0,62	0,84	0,86	0,86	0,82	0,83	0,81	0,8	0,64	0,82

Tab. 15 Hodnoty závislosti FSIM na SNR pro porovnání všech algoritmů

FSIM	Gaussovský šum				Impulzní šum			
	SNR [dB]	wiener	lucy-rich	cepstral	reg	wiener	lucy-rich	cepstral
5	0,71	0,65	0,61	0,63	0,71	0,66	0,70	0,70
7	0,73	0,69	0,62	0,66	0,73	0,70	0,72	0,70
9	0,75	0,71	0,63	0,73	0,74	0,73	0,74	0,64
11	0,76	0,73	0,65	0,71	0,77	0,76	0,77	0,71
13	0,77	0,75	0,67	0,74	0,80	0,80	0,79	0,77
15	0,79	0,77	0,70	0,76	0,83	0,83	0,82	0,81
17	0,80	0,80	0,74	0,84	0,85	0,85	0,84	0,83
19	0,82	0,83	0,77	0,86	0,87	0,87	0,85	0,84
21	0,84	0,85	0,79	0,87	0,90	0,89	0,86	0,86
23	0,85	0,87	0,82	0,89	0,92	0,91	0,87	0,89
25	0,87	0,88	0,84	0,88	0,94	0,93	0,88	0,91
30	0,90	0,93	0,87	0,93	0,96	0,95	0,88	0,95
35	0,93	0,95	0,88	0,95	0,98	0,96	0,89	0,97
45	0,97	0,97	0,89	0,97	0,98	0,97	0,89	0,98
60	0,99	0,98	0,89	0,98	0,96	0,98	0,89	0,98

Tab. 16 Hodnoty závislosti FSIM na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB

FSIM	Gaussovský šum				Impulzní šum				Poissonův šum			
	Nz	wnr	l-r	ceps	reg	wnr	l-r	ceps	reg	wnr	l-r	ceps
1	0,81	0,78	0,79	0,82	0,84	0,83	0,83	0,82	0,81	0,81	0,79	0,82
2	0,79	0,80	0,71	0,66	0,77	0,81	0,78	0,63	0,8	0,82	0,71	0,61
3	0,82	0,83	0,76	0,80	0,84	0,86	0,86	0,76	0,82	0,85	0,77	0,74
4	0,82	0,84	0,77	0,84	0,86	0,87	0,86	0,81	0,82	0,85	0,78	0,8
5	0,83	0,84	0,78	0,86	0,87	0,88	0,87	0,83	0,83	0,85	0,78	0,82
6	0,83	0,85	0,79	0,86	0,89	0,89	0,87	0,85	0,83	0,85	0,79	0,83
7	0,83	0,85	0,79	0,86	0,89	0,89	0,87	0,85	0,84	0,86	0,79	0,84
8	0,83	0,85	0,79	0,87	0,89	0,89	0,87	0,85	0,84	0,86	0,8	0,85
9	0,83	0,85	0,79	0,87	0,89	0,89	0,87	0,86	0,84	0,86	0,8	0,85
10	0,84	0,85	0,79	0,87	0,90	0,89	0,87	0,86	0,84	0,86	0,8	0,85
11	0,84	0,85	0,79	0,87	0,90	0,89	0,87	0,86	0,84	0,86	0,8	0,85
12	0,84	0,85	0,79	0,87	0,90	0,89	0,86	0,86	0,84	0,86	0,8	0,85
13	0,84	0,85	0,79	0,87	0,90	0,89	0,86	0,86	0,84	0,86	0,8	0,85
14	0,84	0,85	0,79	0,87	0,90	0,90	0,86	0,86	0,84	0,86	0,8	0,85
15	0,84	0,85	0,79	0,87	0,90	0,89	0,86	0,86	0,84	0,86	0,8	0,85

Tab. 17 Hodnoty závislosti VIF na SNR pro porovnání všech algoritmů

VIF	Gaussovský šum				Impulzní šum			
SNR [dB]	wiener	lucy-rich	cepstral	reg	wiener	lucy-rich	cepstral	reg
5	0,03	0,02	0,02	0,03	0,02	0,02	0,04	0,03
7	0,04	0,03	0,02	0,04	0,03	0,03	0,05	0,03
9	0,05	0,04	0,02	0,05	0,04	0,04	0,06	0,04
11	0,06	0,05	0,03	0,06	0,06	0,06	0,07	0,06
13	0,07	0,06	0,03	0,07	0,08	0,08	0,09	0,07
15	0,09	0,08	0,04	0,09	0,11	0,11	0,12	0,09
17	0,11	0,10	0,06	0,10	0,15	0,13	0,14	0,11
19	0,13	0,12	0,07	0,13	0,19	0,16	0,17	0,13
21	0,16	0,15	0,09	0,15	0,24	0,21	0,20	0,16
23	0,18	0,18	0,11	0,18	0,29	0,26	0,22	0,20
25	0,21	0,20	0,12	0,21	0,38	0,33	0,25	0,24
30	0,31	0,31	0,18	0,31	0,55	0,46	0,29	0,41
35	0,41	0,42	0,23	0,42	0,68	0,55	0,30	0,57
45	0,60	0,59	0,29	0,62	0,72	0,63	0,31	0,73
60	0,76	0,69	0,31	0,74	0,70	0,69	0,31	0,75

Tab. 18 Hodnoty závislosti VIF na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB

VIF	Gaussovský šum				Impulzní šum				Poissonův šum			
Nz	wnr	l-r	ceps	reg	wnr	l-r	ceps	reg	wnr	l-r	ceps	reg
1	0,11	0,09	0,09	0,10	0,20	0,16	0,22	0,11	0,11	0,11	0,09	0,11
2	0,11	0,12	0,09	0,11	0,14	0,14	0,23	0,11	0,11	0,12	0,09	0,11
3	0,13	0,13	0,09	0,12	0,16	0,16	0,22	0,13	0,13	0,13	0,09	0,12
4	0,14	0,13	0,09	0,13	0,18	0,17	0,21	0,13	0,14	0,14	0,09	0,13
5	0,15	0,14	0,09	0,14	0,19	0,18	0,20	0,14	0,15	0,15	0,09	0,14
6	0,15	0,14	0,09	0,14	0,22	0,20	0,21	0,15	0,15	0,15	0,09	0,15
7	0,15	0,14	0,09	0,15	0,23	0,20	0,20	0,16	0,16	0,15	0,09	0,15
8	0,15	0,15	0,09	0,15	0,23	0,20	0,20	0,16	0,16	0,15	0,09	0,16
9	0,15	0,15	0,09	0,15	0,23	0,20	0,20	0,16	0,16	0,15	0,09	0,16
10	0,16	0,15	0,09	0,15	0,23	0,21	0,20	0,16	0,16	0,16	0,09	0,16
11	0,16	0,15	0,09	0,15	0,24	0,21	0,20	0,16	0,16	0,16	0,09	0,16
12	0,16	0,15	0,09	0,15	0,23	0,21	0,20	0,16	0,16	0,16	0,09	0,16
13	0,16	0,15	0,09	0,15	0,24	0,21	0,20	0,16	0,16	0,16	0,09	0,16
14	0,16	0,15	0,09	0,15	0,24	0,21	0,20	0,16	0,16	0,16	0,09	0,16
15	0,16	0,15	0,09	0,15	0,24	0,21	0,20	0,16	0,16	0,16	0,09	0,16

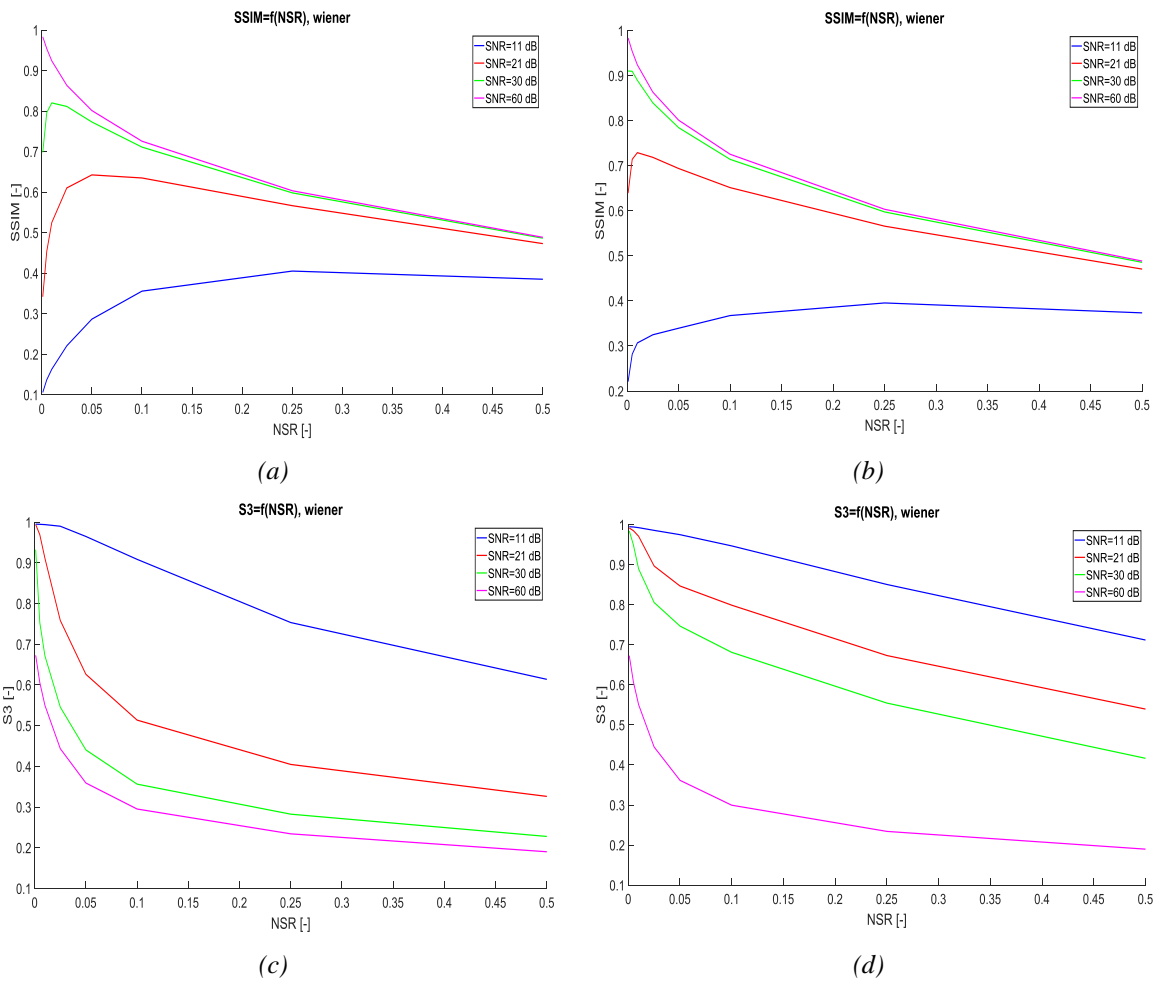
Tab. 19 Hodnoty závislosti S3 na SNR pro porovnání všech algoritmů

S3	Gaussovský šum				Impulzní šum			
	wiener	lucy-rich	cepstral	reg	wiener	lucy-rich	cepstral	reg
5	0,75	0,99	1,00	0,70	0,89	0,99	1,00	0,20
7	0,76	0,98	0,99	0,60	0,95	0,99	1,00	0,16
9	0,74	0,96	0,99	0,32	0,95	0,98	1,00	0,64
11	0,73	0,95	1,00	0,40	0,96	0,96	0,99	0,43
13	0,69	0,93	0,99	0,36	0,96	0,95	0,99	0,47
15	0,66	0,92	0,99	0,43	0,96	0,93	0,99	0,38
17	0,61	0,89	0,99	0,05	0,96	0,90	0,98	0,25
19	0,56	0,86	0,99	0,07	0,97	0,90	0,97	0,65
21	0,53	0,84	0,99	0,13	0,98	0,89	0,94	0,54
23	0,51	0,81	0,97	0,17	0,98	0,88	0,91	0,64
25	0,51	0,79	0,95	0,38	0,98	0,87	0,89	0,45
30	0,51	0,74	0,77	0,45	0,98	0,84	0,86	0,74
35	0,54	0,70	0,65	0,61	0,98	0,80	0,83	0,87
45	0,61	0,68	0,55	0,68	0,95	0,72	0,62	0,79
60	0,67	0,69	0,54	0,69	0,84	0,69	0,54	0,69


Tab. 20 Hodnoty závislosti S3 na počtu oblastí pro porovnání všech algoritmů pro SNR = 21 dB


S3	Gaussovský šum				Impulzní šum				Poissonův šum			
	wnr	l-r	ceps	reg	wnr	l-r	ceps	reg	wnr	l-r	ceps	reg
1	0,47	0,88	0,97	0,06	0,92	0,85	0,92	0,21	0,48	0,69	0,96	0,14
2	0,22	0,66	0,99	0,41	0,90	0,81	0,94	0,65	0,22	0,53	0,99	0,61
3	0,41	0,69	0,99	0,17	0,94	0,82	0,93	0,49	0,44	0,55	0,99	0,43
4	0,49	0,80	0,99	0,14	0,97	0,86	0,94	0,58	0,53	0,67	0,99	0,45
5	0,44	0,77	0,99	0,12	0,98	0,87	0,94	0,59	0,46	0,61	0,99	0,49
6	0,53	0,82	0,99	0,13	0,97	0,87	0,94	0,50	0,57	0,69	0,99	0,54
7	0,50	0,81	0,99	0,12	0,97	0,87	0,94	0,52	0,53	0,65	0,99	0,55
8	0,53	0,81	0,99	0,11	0,97	0,88	0,94	0,48	0,56	0,67	0,99	0,54
9	0,52	0,82	0,99	0,11	0,98	0,89	0,94	0,46	0,56	0,67	0,99	0,55
10	0,53	0,83	0,99	0,12	0,98	0,87	0,94	0,52	0,56	0,67	0,99	0,55
11	0,53	0,83	0,99	0,12	0,97	0,89	0,94	0,53	0,56	0,68	0,99	0,55
12	0,53	0,83	0,99	0,12	0,98	0,88	0,94	0,55	0,56	0,67	0,99	0,55
13	0,53	0,83	0,99	0,12	0,98	0,89	0,94	0,54	0,56	0,68	0,99	0,55
14	0,53	0,84	0,99	0,13	0,98	0,88	0,94	0,53	0,56	0,68	0,99	0,54
15	0,53	0,84	0,99	0,13	0,98	0,89	0,94	0,54	0,57	0,68	0,99	0,54

### 10.3 Příloha C – vynechané grafy metrik PSNR, SSIM a $S_3$

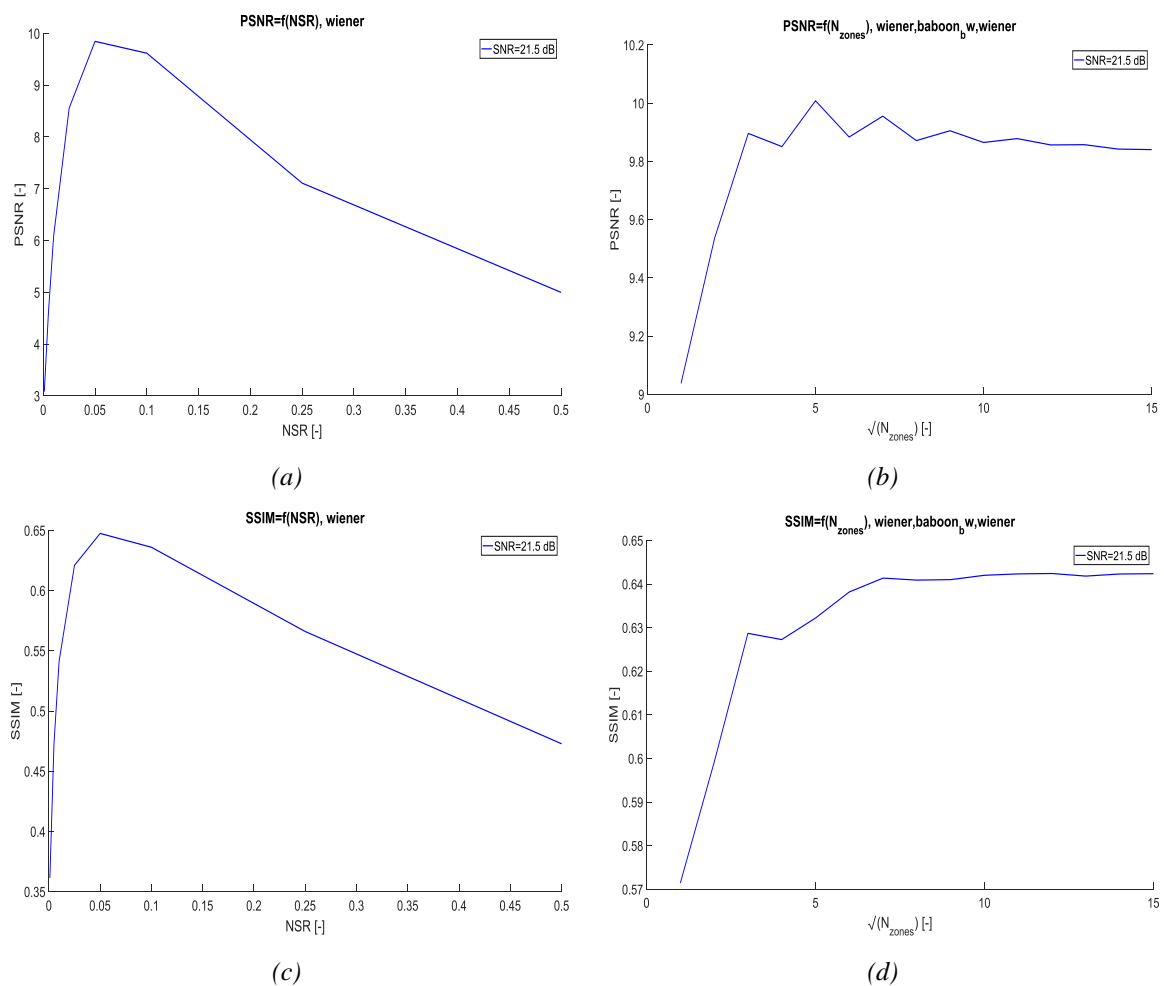


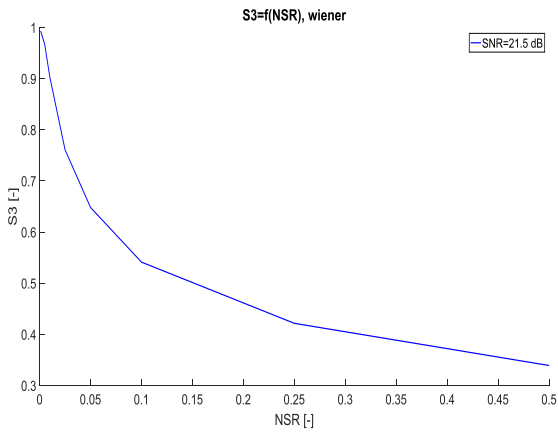
Obr. 40 Závislosti SSIM a  $S_3$  na poměru NSR pro Wienerovu filtraci, (a), (c) gaussovský bílý šum, (b), (d) impulzní šum






Obr. 41 Závislosti SSIM a  $S3$  na počtu oblastí pro Wienerovu filtraci, (a), (c) gaussovský bílý šum, (b), (d) impulzní šum






(e)




(f)


Obr. 42 Závislosti PSNR, SSIM a S3 (a), (c), (e) na poměru NSR, (b), (d), (f) na počtu oblastí pro Wienerovu filtraci a Poissonův šum




(a)



(b)




(c)




(d)






(e)




(f)


Obr. 43 Závislosti PSNR, SSIM a  $S_3$  na poměru SNR pro rekonstrukci s regularizovaným filtrem, (a), (c), (e) gaussianový bílý šum, (b), (d), (f) impulzní šum




(a)




(b)



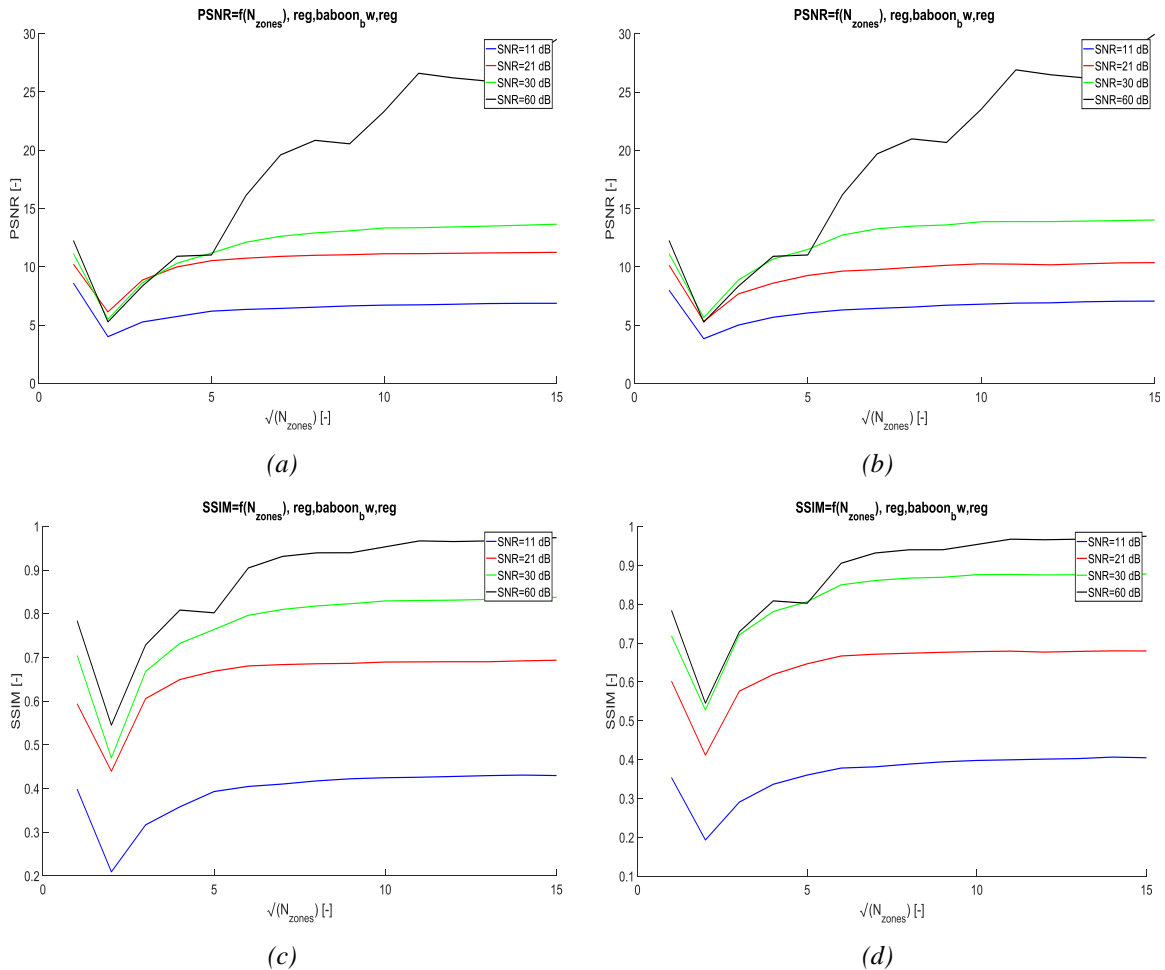
(c)



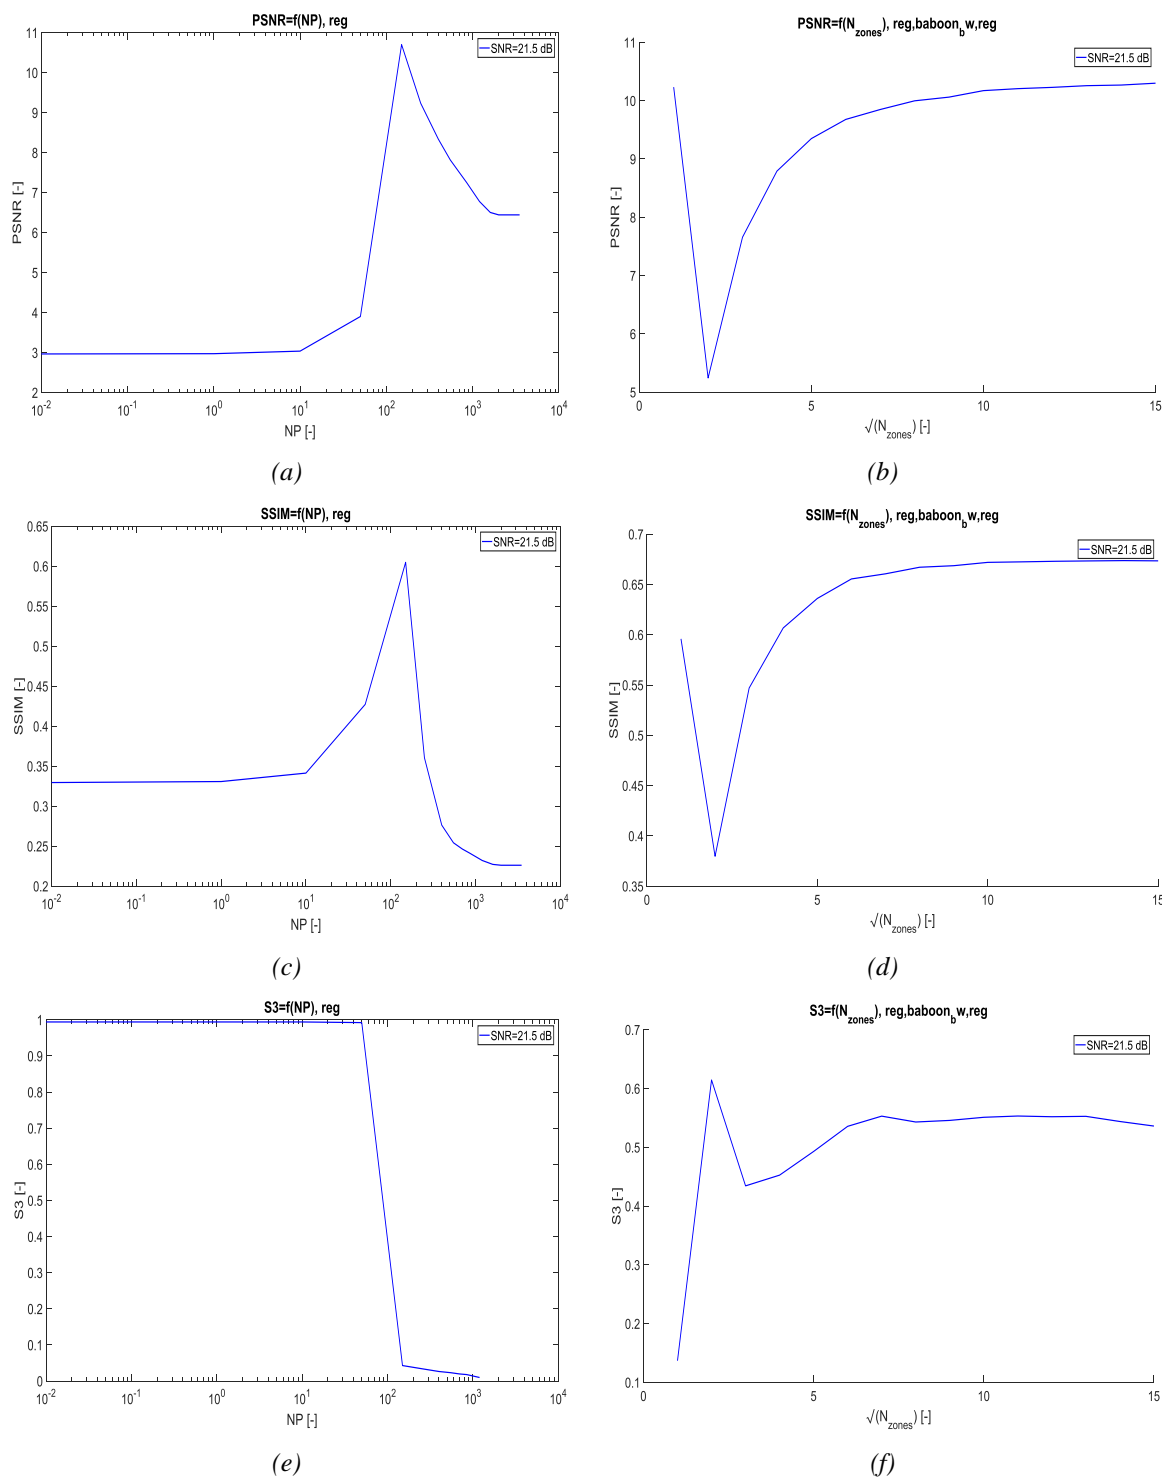
(d)



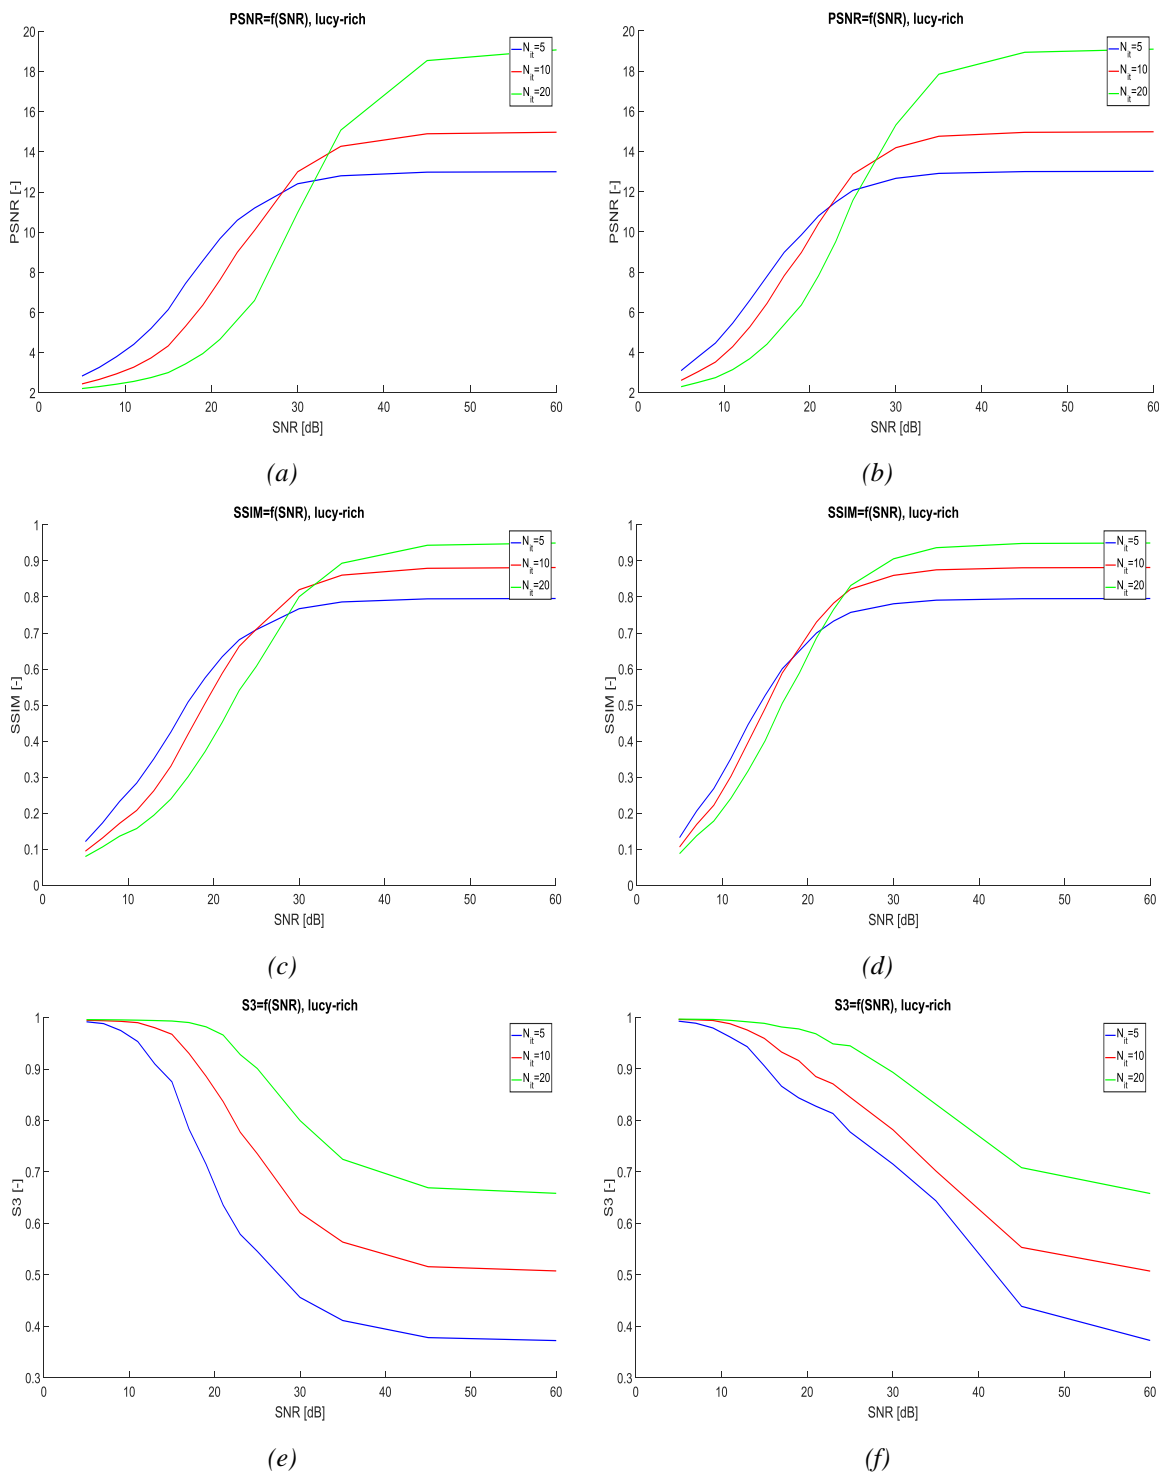
Obr. 44 Závislosti PSNR, SSIM a S3 na odhadu šumu NP pro rekonstrukci s regularizovaným filtrem, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum



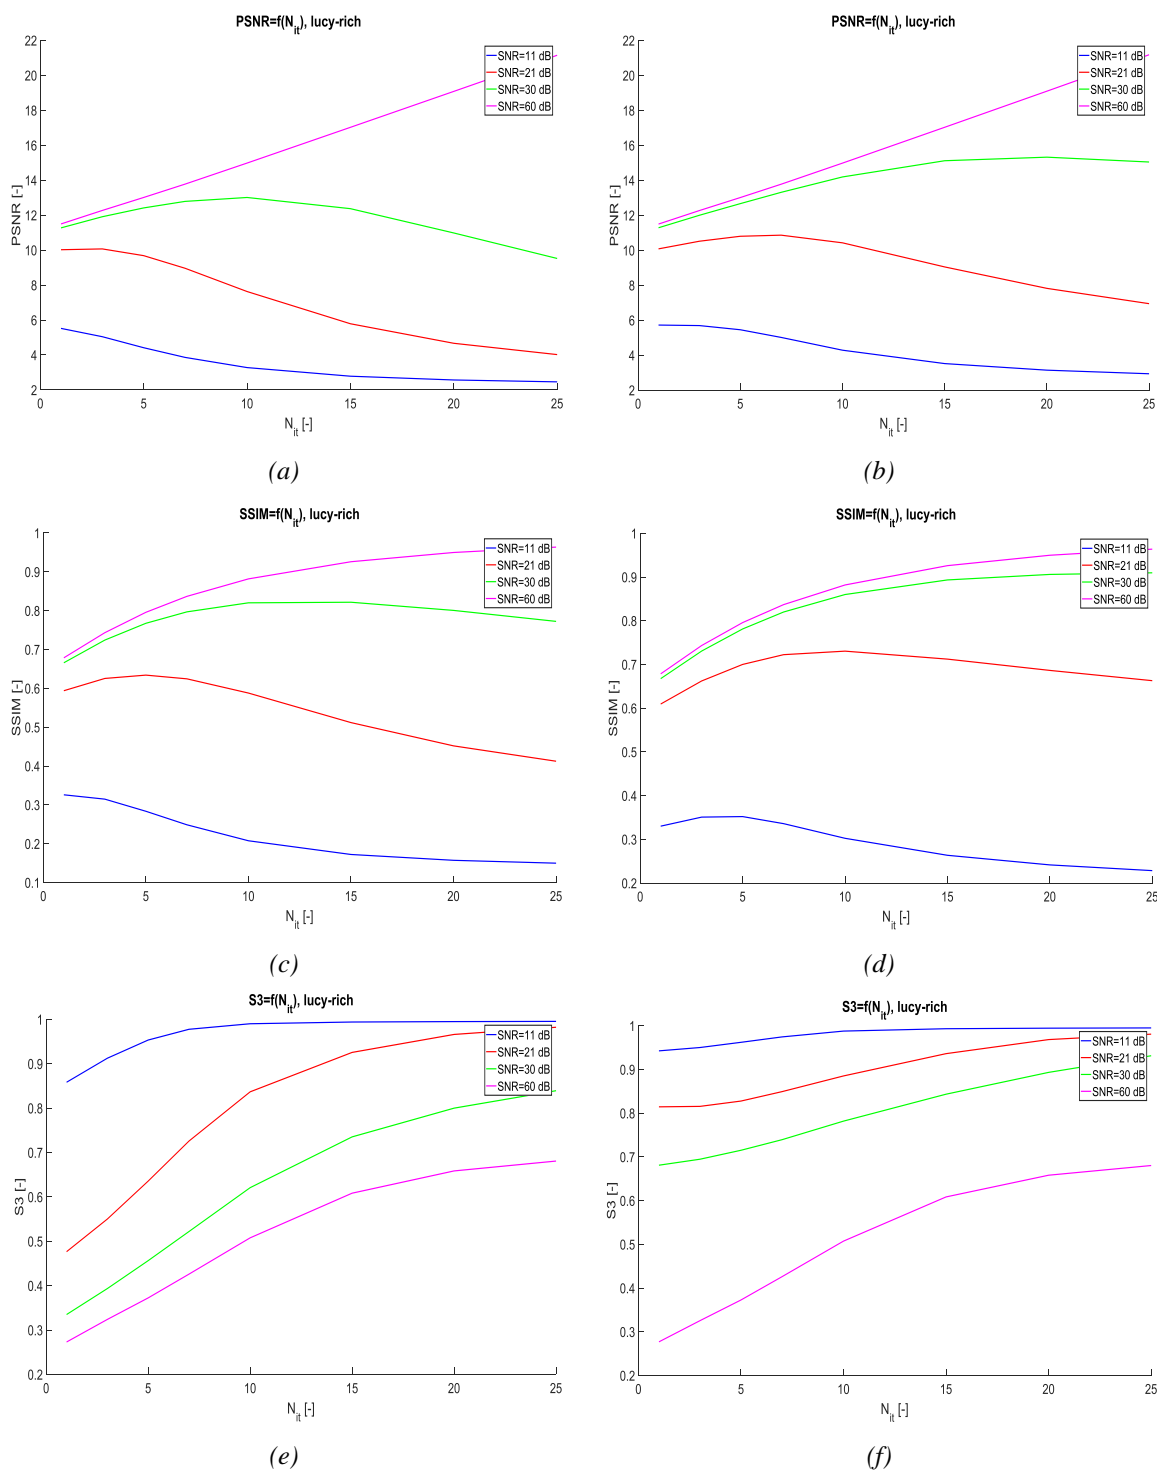
Obr. 45 Závislosti PSNR a SSIM na počtu oblastí pro rekonstrukci s regularizovaným filtrem, (a), (c) gaussovský bílý šum, (b), (d) impulzní šum



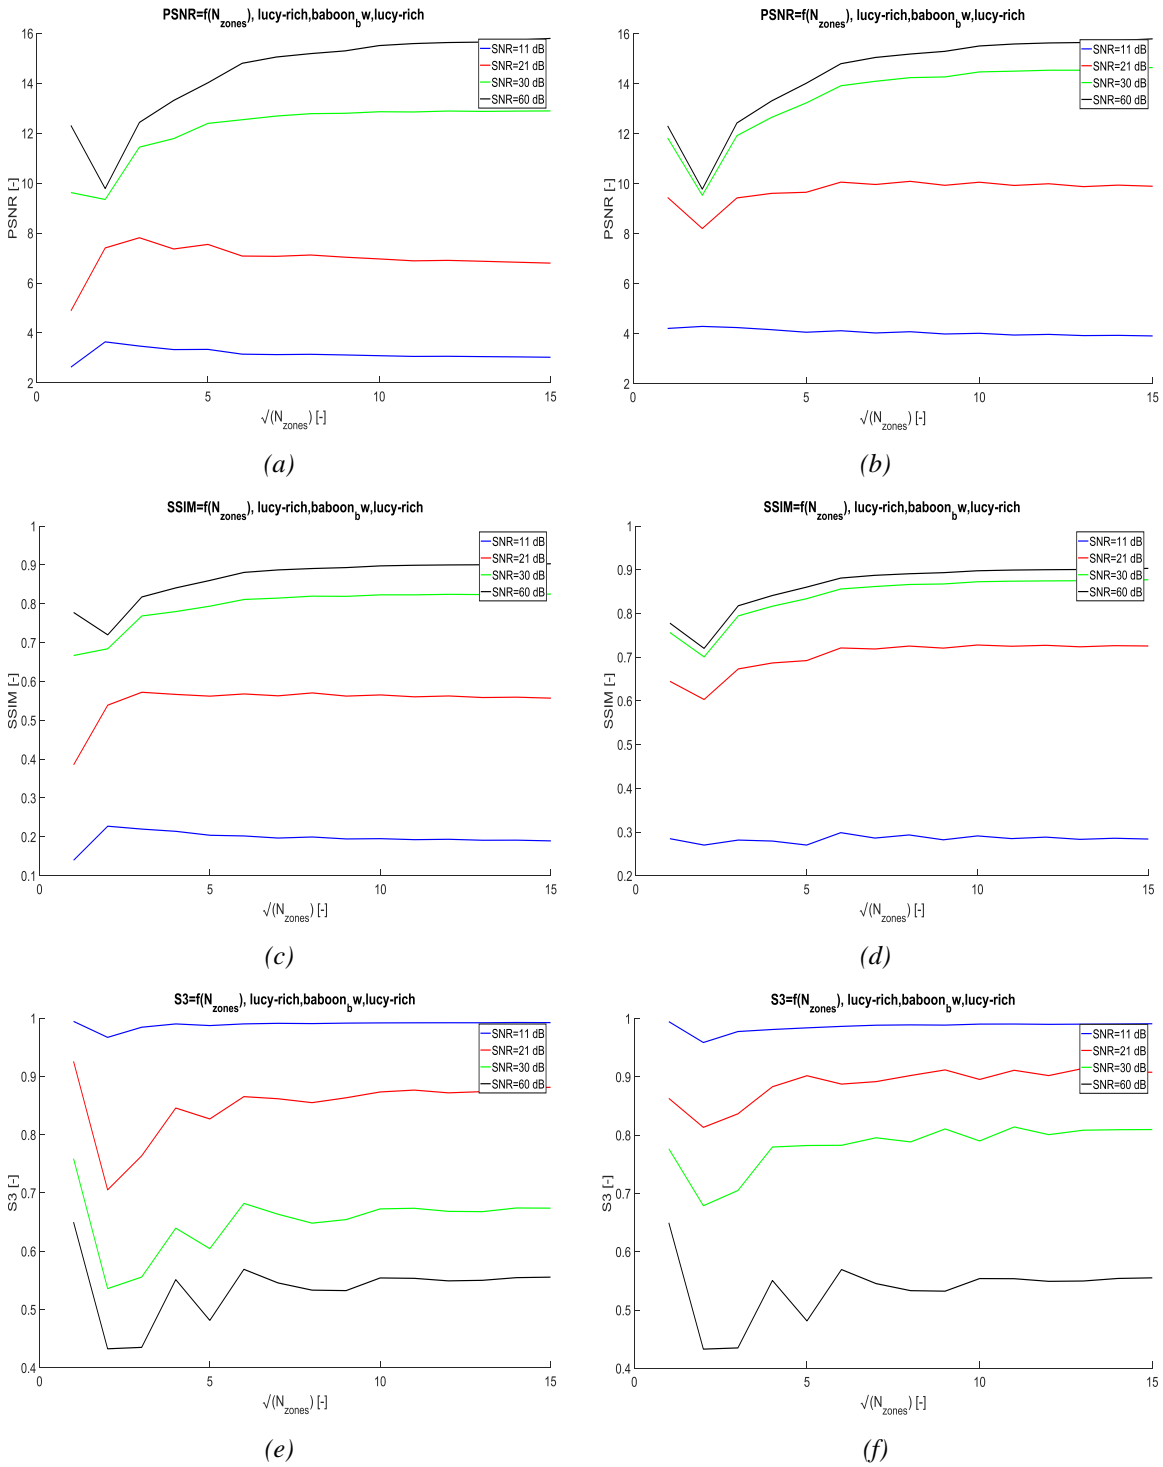
Obr. 46 Závislosti PSNR, SSIM a S3 (a), (c), (e) na odhadu šumu NP, (b), (d), (f) na počtu oblastí pro rekonstrukci s regularizovaným filtrem a Poissonův šum



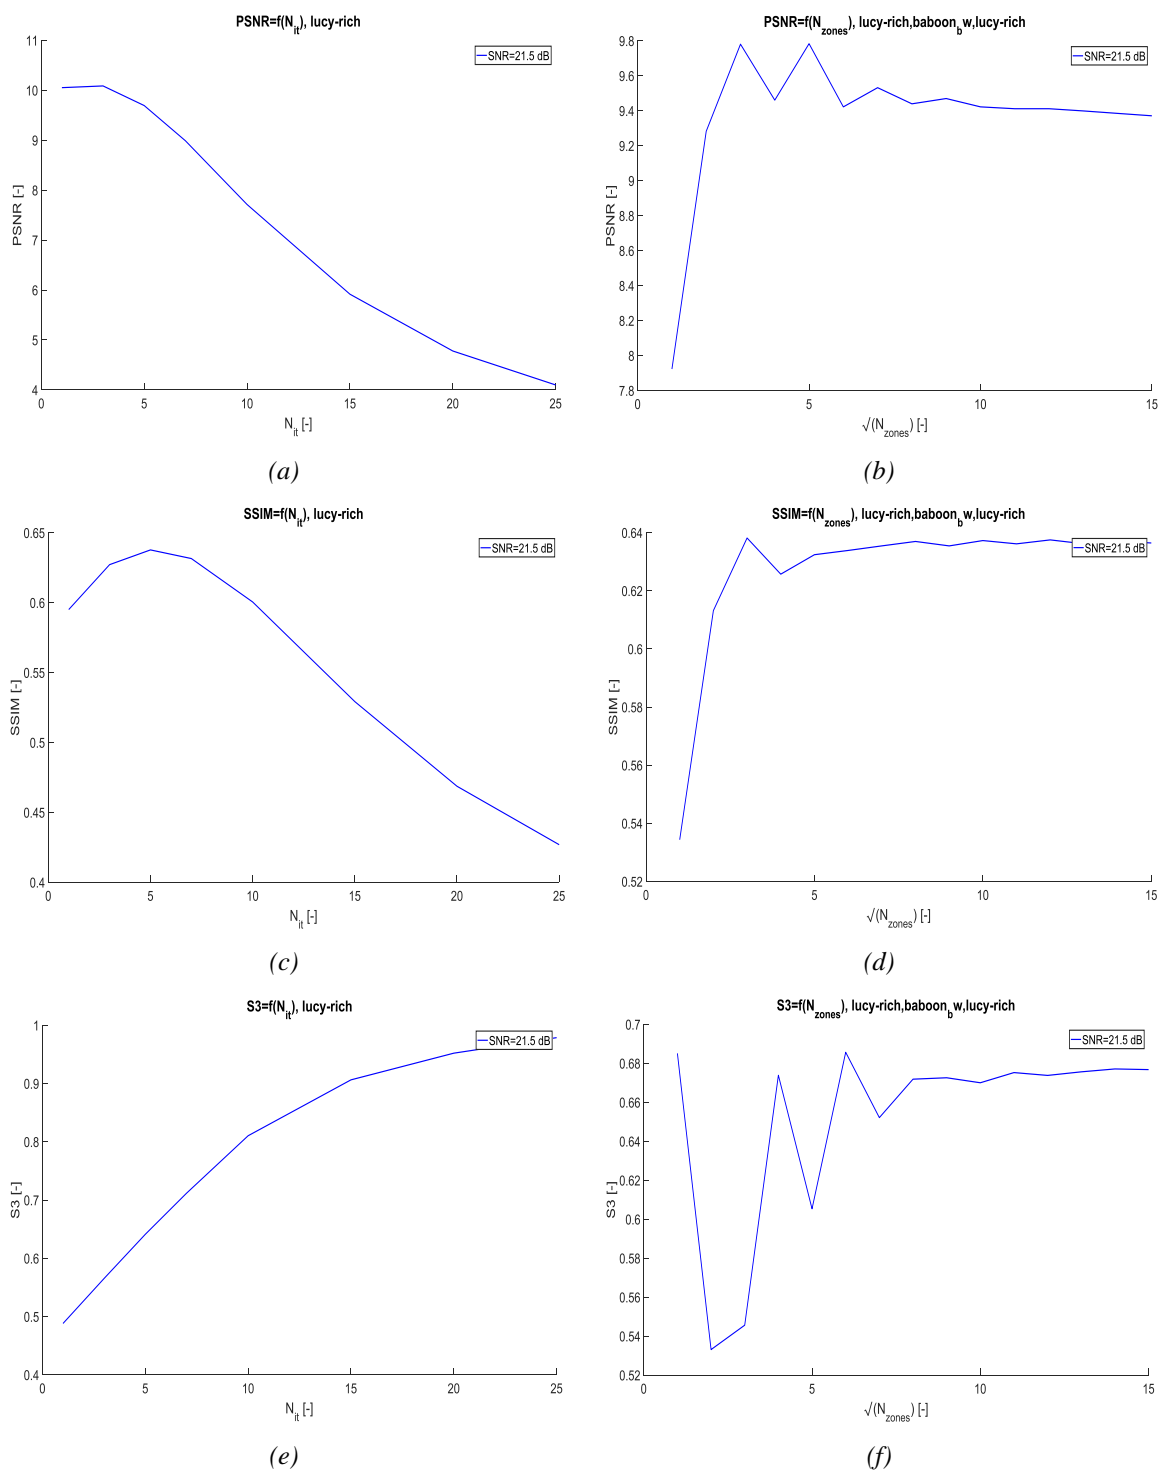
Obr. 47 Závislosti PSNR, SSIM a S3 na poměru SNR pro Lucy-Richardsonův algoritmus, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum



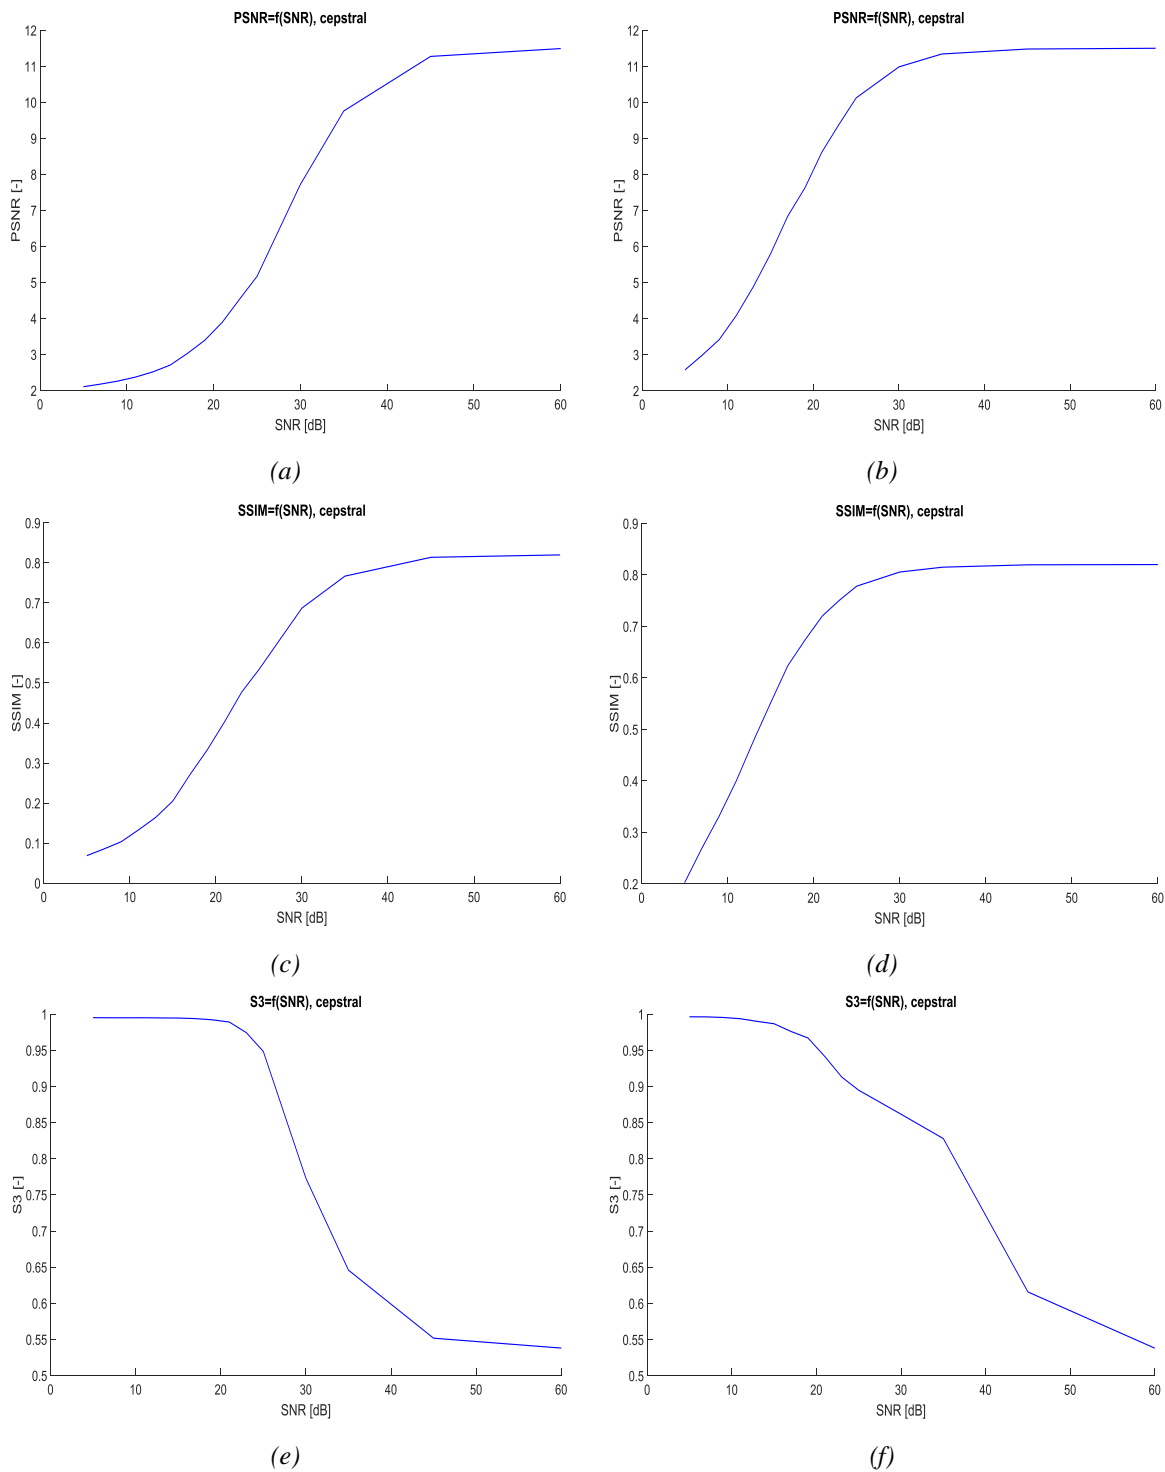
Obr. 48 Závislosti PSNR, SSIM a S3 na počtu iterací pro Lucy-Richardsonův algoritmus, (a), (c), (e) gaussianský bílý šum, (b), (d), (f) impulzní šum



Obr. 49 Závislosti PSNR, SSIM a S3 na počtu oblastí pro Lucy-Richardsonův algoritmus, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum

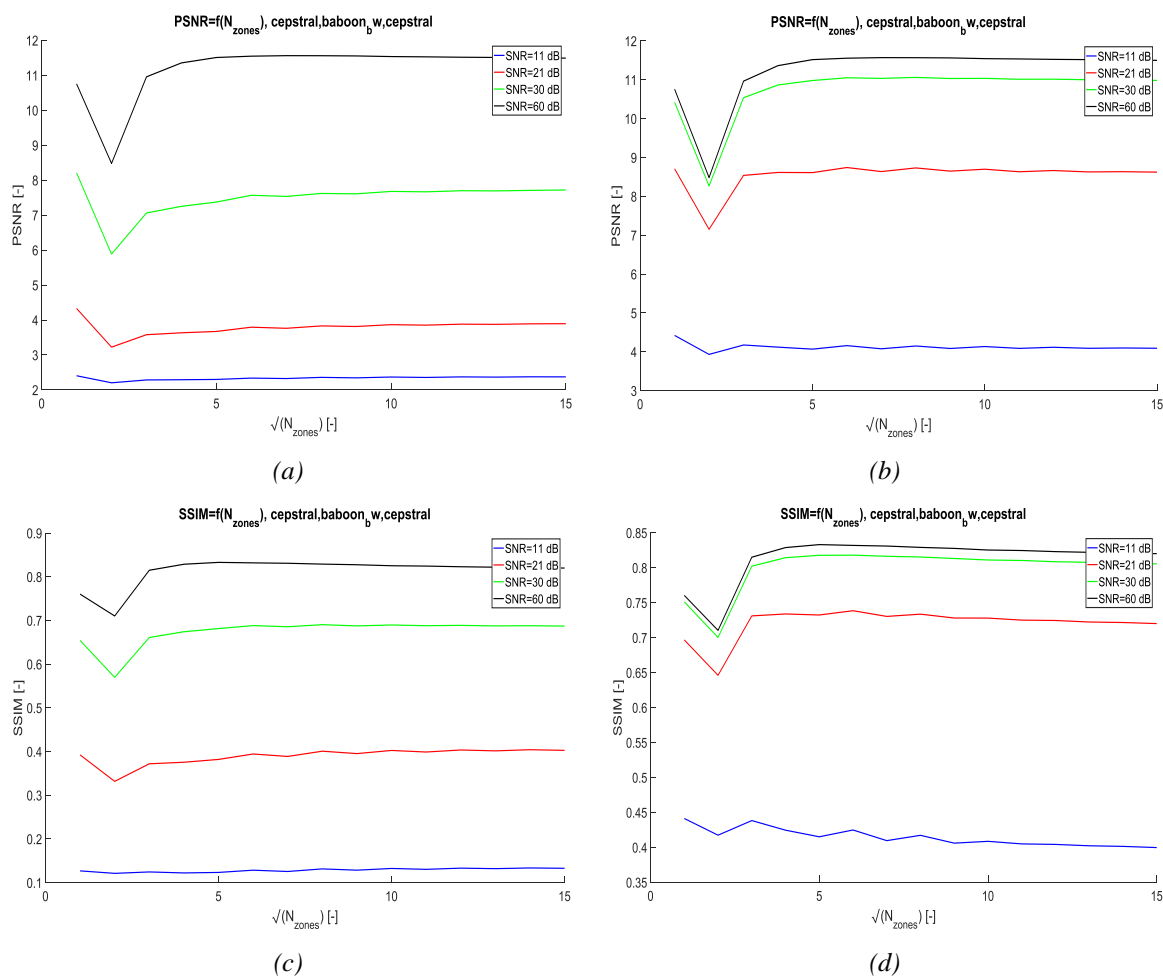


Obr. 50 Závislosti PSNR, SSIM a S3 (a), (c), (e) na počtu iterací, (b), (d), (f) na počtu oblastí pro Lucy-Richardsonův algoritmus a Poissonův šum





Obr. 51 Závislosti PSNR, SSIM a S3 na poměru SNR pro keprální dekonvoluci, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum






Obr. 52 Závislosti PSNR a SSIM na počtu oblastí pro keprální dekonvoluci, (a), (c) gaussovský bílý šum, (b), (d) impulzní šum






(c)


Obr. 53 Závislosti PSNR, SSIM a S3 na počtu oblastí pro keprální dekonvoluci a Poissonův šum




(a)




(b)




(c)




(d)



Obr. 54 Závislost PSNR, SSIM a  $S_3$  na SNR pro porovnání všech algoritmů, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum





Obr. 55 Závislost PSNR, SSIM a  $S_3$  na počtu oblastí pro porovnání všech algoritmů, (a), (c), (e) gaussovský bílý šum, (b), (d), (f) impulzní šum