

**Vysoká škola báňská – Technická univerzita Ostrava  
Fakulta elektrotechniky a informatiky  
Katedra kybernetiky a biomedicínského inženýrství**

**Aplikace zpracování biomedicínských signálů na základě Wavelet transformace**

**Application of biomedical signal processing based on Wavelet transformation**

**2020**

**Petr Bílek**

VŠB - Technická univerzita Ostrava  
Fakulta elektrotechniky a informatiky  
Katedra kybernetiky a biomedicínského inženýrství

## Zadání bakalářské práce

Student: **Petr Bílek**  
Studijní program: B2649 Elektrotechnika  
Studijní obor: 3901R039 Biomedicínský technik  
Téma: Aplikace zpracování biomedicínských obrazů na základě  
Wavelet transformace  
Application of Biomedical Image Processing  
based on Wavelet Transformation

Jazyk vypracování: čeština

### Zásady pro vypracování:

1. Nastudování základů filtrace digitálního obrazu.
2. Nastudování principů 1D Wavelet transformace.
3. Nastudování principů 2D Wavelet transformace.
4. Analýza charakteristických typů šumu v medicínských obrazech.
5. Tvorba testovací báze vybraných medicínských obrazů.
6. Design a implementace filtrační procedury pro filtraci obrazu.
7. Testování a vyhodnocení procedury na reálných obrazových datech.
8. Vyhodnocení výsledků práce.

### Seznam doporučené odborné literatury:

- [1] JENSEN, Arne a Anders LA COUR-HARBO. *Ripples in mathematics: the discrete wavelet transform*. Berlin: Springer, 2001. ISBN 3-540-41662-5.  
[2] JAN, Jiří. *Medical image processing, reconstruction and restoration: concepts and methods*. Boca Raton: Taylor & Francis, 2006. Signal processing and communications, 25. ISBN 0-8247-5849-8.  
[3] ADDISON, Paul S. *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*. New York: Taylor & Francis, 2002. ISBN 0-7503-0692-0.

Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí bakalářské práce: **Ing. Jan Kubíček, Ph.D.**

Datum zadání: 01.09.2019

Datum odevzdání: 30.04.2020

doc. Ing. Jiří Koziorek, Ph.D.  
vedoucí katedry



prof. Ing. Pávek Brandštetter, CSc.  
děkan fakulty

## Prohlášení studenta

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

V Ostravě dne: 6. května 2020

  
.....  
podpis studenta

## Poděkování

Děkuji panu Ing. Janu Kubíčkoví, Ph.D., za rady a ochotu při tvorbě této bakalářské práce. Dále bych rád poděkoval panu Ing. Vilímkovi za pomoc a rady ohledně samotné realizace práce. Závěrem chci poděkovat také mé rodině za podporu během studia.

## **Abstrakt**

Tématem této práce je WT (wavelet transform) filtrování rozdílných šumů z obrazů CT, MRI, retinálních skenů a segmentace filtrovaných obrazových dat pořízených pomocí CT a MRI. Obrazový šum je aditivní složka, která může v obraze překrývat důležité informace, což může vést ke špatné diagnóze. Cílem práce je otestování několika zástupců z několika rodin (druhů) vlnek, několika úrovní rozkladu obrazu a následné zpracování a analyzování výsledků. Čtvrtina práce je věnována teorii, která poskytuje stručné informace ohledně problematiky obrazové filtrace. Praktická část je rozdělena do dvou celků, z nichž první se věnuje zpracování a analýze výsledků, které vzešly z filtrování obrazových dat různými typy vlnek s tím, že konečným výsledkem této praktické části jsou typy vlnek a rozklad, které jsou v rámci testovaných vlnek pro daný druh dat nejefektivnější, ale vybrány jsou i vlnky neefektivní. Druhá praktická část se věnuje efektivitě Otsu segmentace po obrazové WT filtraci. Cílem je otestovat, kterou vlnkou a rozkladem je vhodné filtrovat konkrétní typ šumu, aby byla segmentace co nejlepší. K hodnocení kvality filtrace/segmentace je využito vybraných objektivních hodnotících metod.

## **Klíčová slova**

Vlnková transformace; Gaussovský šum; šum Salt&Pepper; šum Speckle; diskrétní vlnková transformace; hodnocení kvality obrazové filtrace; filtrace MRI obrazu; filtrace CT obrazu; filtrace retinálních skenů

## **Abstract**

The topic of this bachelor thesis is WT (wavelet transform) filtering of different noise from CT images, MRI images, retinal scans and segmentation of filtered image data acquired by CT and MRI. Image noise is an additive component that can obscure important information in an image, which can lead to misdiagnosis. The aim of the work is to test several representatives of several families (types) of wavelets, several levels of image decomposition and subsequent processing and analysing the results. A one quarter of the thesis is devoted to a theory that provides brief information about image filtering. The practical part is divided into two parts. The first is devoted to the processing and analysis of results, which arose from filtering image data by different types of wavelets. The final results of this practical part are wavelet types and decomposition that are best for specific data type, but the worst wavelets are also selected. The second practical part deals with the efficiency of Otsu segmentation after image WT filtering. The goal is to test which wavelet and decomposition level is appropriate to filter a particular type of noise in order to perform the best segmentation. Selected objective evaluation methods are used to evaluate the quality of filtration/segmentation.

## **Key words**

Wavelet transform; Gaussian noise; Salt&Pepper noise; Speckle noise; discrete wavelet transform; image filter quality evaluation; MRI image filtering; CT image filtering; Retinal scan image filtering

# Obsah

Seznam použitých symbolů a zkratk .....	8
Seznam obrázků a tabulek.....	10
Úvod.....	13
1 Definice obrazu a jeho parametry .....	14
1.1 Motivace pro filtraci a zpracování obrazu.....	14
1.2 Definice obrazového signálu.....	14
1.3 Vlastnosti obrazu.....	15
2 Zpracování obrazu.....	17
2.1.1 Obnovení kvality obrazu .....	17
2.1.2 Analýza obrazu.....	17
2.1.3 Skládání obrazu .....	17
2.1.4 Vylepšování kvality obrazu.....	17
2.1.5 Komprese obrazu.....	17
2.2 Průběh zpracování obrazu .....	18
2.2.1 Snímání obrazu.....	18
2.2.2 Digitalizace.....	18
2.2.3 Předzpracování obrazu .....	18
2.2.4 Segmentace.....	18
2.2.5 Popis objektů .....	19
2.2.6 Klasifikace.....	19
3 Filtrace obrazu a analýza šumu .....	20
3.1 2D konvoluce .....	20
3.1.1 Lineární filtrace .....	21
3.1.2 Nelineární filtrace.....	23
3.1.3 Typy šumů v medicínských obrazech .....	23
3.2 Hodnocení kvality obrazu .....	27
3.2.1 Subjektivní hodnocení kvality obrazu .....	27
3.2.2 Objektivní hodnocení kvality obrazu .....	27
4 1D a 2D Wavelet transformace .....	30
4.1 Wavelet (vlnka).....	30
4.2 Diskrétní wavelet transformace (DWT).....	31
4.3 1D DWT .....	32
4.3.1 Prahování.....	33
4.4 2D DWT.....	33
5 Praktická část I. – Filtrace obrazových dat pomocí WT .....	35
5.1 Výsledky pro dataset CT .....	36
5.1.1 Gaussovský šum.....	37

5.1.2	Závěr pro dataset CT – Gaussovský šum .....	41
5.1.3	Šum Salt&Pepper .....	42
5.1.4	Závěr pro dataset CT – Salt&Pepper šum .....	46
5.1.5	Šum Speckle .....	47
5.1.6	Závěr pro dataset CT – Speckle šum .....	51
5.2	Výsledky pro dataset MRI.....	52
5.2.1	Gaussovský šum .....	53
5.2.2	Závěr pro dataset MRI – Gaussovský šum.....	57
5.2.3	Šum Salt&Pepper .....	58
5.2.4	Závěr pro dataset MRI – Šum Salt&pepper .....	62
5.2.5	Šum speckle.....	63
5.2.6	Závěr pro dataset MRI – Šum Speckle.....	67
5.3	Výsledky pro dataset RS .....	68
5.3.1	Gaussovský šum .....	69
5.3.2	Závěr pro dataset RS – Gaussovský šum.....	73
5.3.3	Šum Salt&Pepper .....	74
5.3.4	Závěr pro dataset RS – Salt&Pepper šum .....	78
5.3.5	Šum Speckle .....	79
5.3.6	Závěr pro dataset RS – Speckle šum .....	83
5.4	Závěrečné hodnocení praktické části I. ....	84
6	Praktická část II. – Efektivita segmentace snímků filtrovaných pomocí WT .....	85
6.1	Segmentace obrazu.....	85
6.1.1	Otsu prahování .....	86
6.2	Výsledky pro dataset CT .....	88
6.2.1	Gaussovský šum .....	88
6.2.2	Závěr pro efektivitu segmentace – Gaussovský šum.....	89
6.2.3	Šum Salt&Pepper .....	90
6.2.4	Závěr pro efektivitu segmentace – Šum Salt&Pepper.....	90
6.3	Výsledky pro dataset MRI.....	92
6.3.1	Gaussovský šum .....	92
6.3.2	Závěr pro efektivitu segmentace – Gaussovský šum.....	92
6.3.3	Šum Salt&Pepper .....	94
6.3.4	Závěr pro efektivitu segmentace – Šum Salt&Pepper.....	94
6.4	Závěrečné hodnocení praktické části II.....	96
7	Diskuze.....	97
8	Závěr .....	98
8.1	Tabulka k závěru: Výsledky I. praktické části .....	99
8.2	Tabulka k závěru: Výsledky II. praktické části .....	99
9	Literatura a použité zdroje: .....	100
	Seznam příloh.....	102

## Seznam použitých symbolů a zkratek

$G_{LL}$	Aproximační koeficient
$A_p$	Aproximační složka
$S(i, j)$	Bodové hodnocení daného obrazu
$M$	Celkový počet respondentů
$CT$	Computer Tomograph (Počítačová tomografie)
$T_m(n)$	Definice měkkého prahování
$l_d(k)$	Definice nízkofrekvenčního filtru
$S_{xy}$	Definice středu okna
$T_h(n)$	Definice tvrdého prahování
$h_d(k)$	Definice vysokofrekvenčního filtru
$D_p$	Detailní složka
$G_{HH}$	Diagonální detail
$a$	Dilatační parametr
DWT	Diskrétní wavelet transformace
$2D$	Dvoudimenzionální (Dvojezměrný prostor)
$D_r$	Dynamický rozsah jasu pixelů
EKG	Elektrokardiograf
$g(x, y)$	Filtrovaný obraz
GAE	Geometric average error (průměrná geometrická odchylka)
$G_{LH}$	Horizontální detail
$h(x, y)$	Impulzní odezva
IDWT	Inverzní diskretní wavelet transformace
$I$	Jas
$k$	Konstanta
$m$	Konstanta
$K$	Kontrast
$\sigma_f^2$	Lokální rozptyl
$MRI$	Magnetic resonance imaging (Magnetická rezonance)
$\psi$	Mateřský wavelet
$MOS$	Mean Opinion Score (střední hodnota názoru)
$MSE$	Mean squared error (střední kvadratická chyba)



$\hat{F}(x, y)$	Obraz obnovený filtrací
$f(x, y)$	Obrazová 2D funkce
$\phi$	Otcovský wavelet
$j$	Označení daného obrazu
PSNR	Peak signal to noise ratio (poměr nejvyššího výkonu signálu a šumu)
$\hat{f}(x, y)$	Pixel obnovený filtrací
$P(z)$	Pravděpodobnost výskytu určitého stupně šedé
$p_{i,j}$	Původní obraz
$RGB$	Red Green Blue barevný model
$f_{i,j}$	Referenční obraz
$I$	Respondent
$RMSE$	Root mean squared error (střední kvadratická odchylka)
S/N	Signal to noise ratio (poměr signál-šum)
$z, m$	Střední hodnoty dané funkce
$b$	Translační parametr
$3D$	Trojdimenzionální (Trojrozměrný prostor)
$p$	Úroveň dekompozice
$G_{HL}$	Vertikální detail
$g(x, y)$	Výstupní obraz
WT	Wavelet transformace (vlnková transformace)

## Seznam obrázků a tabulek

Obrázek 1: Ekvalizace histogramu .....	16
Obrázek 2: Ilustrační příklady segmentace v biomedicině.....	19
Obrázek 3: Filtrace Gaussova šumu Gaussovým filtrem .....	22
Obrázek 4: Filtrace šumu Sůl a pepř mediánovým filtrem .....	23
Obrázek 5: Originální obraz a obraz degradovaný Gaussovým šumem .....	24
Obrázek 6: Originální obraz a obraz degradovaný šumem Poisson .....	24
Obrázek 7: Originální obraz a obraz degradovaný šumem Speckle .....	25
Obrázek 8: Příklad centrálního pixelu zasaženého šumem typu Salt&Pepper.....	26
Obrázek 9: Originální obraz a obraz degradovaný šumem Salt&Pepper .....	26
Obrázek 10: Wavelety typu Daubechies 8 a Daubechies 16.....	30
Obrázek 11: Znárodnění Shannonových waveletů dekompozičních úrovních. ....	31
Obrázek 12: Dekompozice EKG signálu s detekcí nespojitosti .....	32
Obrázek 13: Princip filtrování obrazu pomocí DWT .....	34
Obrázek 14: Stupně hustoty Gaussova šumu 0.02, 0.2 a 0.4, rozptyl 0.01 .....	36
Obrázek 15: Stupně hustoty Salt&Pepper šumu 0.001, 0.02 a 0.04.....	36
Obrázek 16: Stupně hustoty šumu Speckle 0.02, 0.2 a 0.4 .....	36
Obrázek 17: Porovnání výsledných hodnot nejlepších vlnek pro Gaussovský šum .....	37
Obrázek 18: Porovnání výsledných hodnot nejméně vhodných vlnek pro Gaussovský šum. ....	39
Obrázek 19: Porovnání výsledných hodnot nejvhodnějších vlnek pro šum Salt&Pepper. ....	42
Obrázek 20: Porovnání výsledných hodnot nejméně vhodných vlnek pro šum Salt&Pepper .....	44
Obrázek 21: Porovnání výsledných hodnot nejvhodnějších vlnek pro šum Speckle.....	47
Obrázek 22: Porovnání výsledných hodnot nejméně vhodných vlnek pro šum Speckle.....	49
Obrázek 23: Stupně hustoty Gaussova šumu 0.01, 0.1 a 0.2, rozptyl 0.01 .....	52
Obrázek 24: Stupně hustoty Salt&Pepper šumu 0.005, 0.05, 0,1 .....	52
Obrázek 25: Stupně hustoty šumu Speckle 0.01, 0.1, 0.2 .....	52
Obrázek 26: Porovnání výsledných hodnot nejvhodnějších vlnek pro Gaussovský šum .....	53
Obrázek 27: Porovnání výsledných hodnot nejméně vhodných vlnek pro Gaussovský šum .....	55
Obrázek 28: Porovnání výsledných hodnot nejvhodnějších vlnek pro šum Salt&Pepper .....	58
Obrázek 29: Porovnání výsledných hodnot nejméně vhodných vlnek pro šum Salt&Pepper .....	60
Obrázek 30: Porovnání výsledných hodnot nejvhodnějších vlnek napříč rodinami pro šum Speckle...63	
Obrázek 31: Porovnání výsledných hodnot nejméně vhodných vlnek pro šum Speckle.....	65
Obrázek 32: Stupně hustoty Gaussova šumu 0.001, 0.01, 0.02, rozptyl 0.1 .....	68
Obrázek 33: Stupně hustoty Salt&Pepper šumu 0.005, 0.05, 0.1 .....	68
Obrázek 34: Stupně hustoty šumu Speckle 0.01, 0.1, 0.2 .....	68
Obrázek 35: Porovnání výsledných hodnot nejvhodnějších vlnek pro Gaussovský šum .....	69
Obrázek 36: Porovnání výsledných hodnot nejméně vhodných vlnek pro Gaussovský šum .....	71
Obrázek 37: Porovnání výsledných hodnot nejvhodnějších vlnek pro šum Salt&Pepper .....	74
Obrázek 38: Porovnání výsledných hodnot nejméně vhodných vlnek pro šum Salt&Pepper .....	76
Obrázek 39: Porovnání výsledných hodnot nejvhodnějších vlnek pro šum Speckle.....	79
Obrázek 40: Porovnání výsledných hodnot nejméně vhodných vlnek pro šum Speckle.....	81

Obrázek 41: Grafické zobrazení výsledků korelace a MSE mezi ideálním výstupem segmentace a obrazy segmentovanými po aplikaci WT filtrace.....	88
Obrázek 42: Zobrazení výsledku ideální segmentace a výsledků segmentace po filtrování různými vlnkami při nejvyšším stupni zašumění .....	89
Obrázek 43: Grafické zobrazení výsledků korelace a MSE mezi ideálním výstupem segmentace a obrazy segmentovanými po aplikaci WT filtrace.....	90
Obrázek 44: Zobrazení výsledku ideální segmentace a výsledků segmentace po filtrování různými vlnkami při nejvyšším stupni zašumění .....	91
Obrázek 45: Grafické zobrazení výsledků korelace a MSE mezi ideálním výstupem segmentace a obrazy segmentovanými po aplikaci WT filtrace.....	92
Obrázek 46: Zobrazení výsledku ideální segmentace a výsledků segmentace po filtrování různými vlnkami při nejvyšším stupni zašumění .....	93
Obrázek 47: Grafické zobrazení výsledků korelace a MSE mezi ideálním výstupem segmentace a obrazy segmentovanými po aplikaci WT filtrace.....	94
Obrázek 48: Zobrazení výsledku ideální segmentace a výsledků segmentace po filtrování různými vlnkami při nejvyšším stupni zašumění .....	95

## Seznam Tabulek

Tabulka 1: Hodnoty hodnotících metod znázorňující nejvhodnější vlnku pro Gaussovský šum .....	37
Tabulka 2: Hodnoty hodnotících metod znázorňující nejméně vhodnou vlnku pro Gaussovský šum ..	39
Tabulka 3: Hodnoty hodnotících metod znázorňující nejvhodnější vlnku pro šum Salt&Pepper .....	42
Tabulka 4: Hodnoty hodnotících metod znázorňující nejméně vhodnou vlnku pro šum Salt&Pepper ..	44
Tabulka 5: Hodnoty hodnotících metod znázorňující nejvhodnější vlnku pro šum Speckle .....	47
Tabulka 6: Hodnoty hodnotících metod znázorňující nejméně vhodnou vlnku pro šum Speckle .....	49
Tabulka 7: Hodnoty hodnotících metod znázorňující nejvhodnější vlnku pro Gaussovský šum .....	53
Tabulka 8: Hodnoty hodnotících metod znázorňující nejméně vhodnou vlnku pro Gaussovský šum ..	55
Tabulka 9: Hodnoty hodnotících metod znázorňující nejvhodnější vlnku šum Salt&Pepper.....	58
Tabulka 10: Hodnoty hodnotících metod znázorňující nejméně vhodnou vlnku pro šum Salt&Pepper ..	60
Tabulka 11: Hodnoty hodnotících metod znázorňující nejvhodnější vlnku pro šum Speckle .....	63
Tabulka 12: Hodnoty hodnotících metod znázorňující nejméně vhodnou vlnku pro šum Speckle .....	65
Tabulka 13: Hodnoty hodnotících metod znázorňující nejvhodnější vlnku pro Gaussovský šum .....	69
Tabulka 14: Hodnoty hodnotících metod znázorňující nejméně vhodnou vlnku pro Gaussovský šum ..	71
Tabulka 15: Hodnoty hodnotících metod znázorňující nejvhodnější vlnku pro šum Salt&Pepper .....	74
Tabulka 16: Hodnoty hodnotících metod znázorňující nejméně vlnku pro šum Salt&Pepper .....	76
Tabulka 17: Hodnoty hodnotících metod znázorňující nejvhodnější vlnku pro šum Speckle .....	79
Tabulka 18: Hodnoty hodnotících metod znázorňující nejméně vhodnou vlnku pro šum Speckle .....	81
Tabulka 19: Hodnoty korelace a MSE s hodnotami nejefektivnější vlnky, MRI – Gauss. šum .....	88
Tabulka 20: Hodnoty korelace a MSE s hodnotami nejefektivnější vlnky, MRI – šum Salt&Pepper...	90
Tabulka 21: Hodnoty korelace a MSE s hodnotami nejefektivnější vlnky, CT - Gauss. šum .....	92
Tabulka 22: Hodnoty korelace a MSE s hodnotami nejefektivnější vlnky, CT - šum Salt&Pepper.....	94

# Úvod

Filtrování medicínských dat je v dnešní době nedílnou součástí klinické praxe. Existuje celá řada faktorů, kvůli kterým dochází v medicínských obrazových materiálech k degradaci kvality. Těmto defektům nebývá možné nebo prakticky jednoduché předcházet a tak musí být potlačovány nejrůznějšími metodami, neboť mohou lékaři znesnadnit nebo znemožnit určení správné diagnózy. Nejčastěji jsou těmito defekty různé typy šumu pocházející z různých zdrojů. Šum lze filtrovat celou řadou obrazových filtrů, které však často negativně ovlivňují i kvalitu objektů v obraze, zejména ostrost hran.

Cílem práce je aplikace šumových generátorů na soubor klinických obrazových dat a jejich následná filtrace pomocí WT (vlnkové transformace). Smyslem tohoto je co nejhodnější nastavení parametrů filtrace, aby bylo dosaženo co nejuspokojivějších výsledků. Výsledky jsou analyzovány použitím metod pro hodnocení kvality obrazu.

V první kapitole práce jsou popsány obrazové matice, jakožto definice obrazu. Dále jsou v této kapitole popsány základní vlastnosti, kterými obraz disponuje. Druhá kapitola obsahuje stručné informace týkající se obecných základů zpracování obrazu. Třetí kapitola je věnována naznačení principu obrazové filtrace a jsou zde popsány vybrané typy filtrů a signálových šumů. Do této kapitoly jsou zařazeny i metody, pomocí kterých je hodnocena kvalita obrazu. Čtvrtá kapitola je věnována výhradně wavelet transformaci (WT). Jsou zde základní informace týkající se waveletu, diskretní wavelet transformaci (DWT), 1D DWT a 2D DWT včetně vysvětlení principu filtrace obrazu použitím WT.

Pátá a šestá kapitola obsahují praktickou část práce. V páté kapitole je vyhodnocována efektivita WT filtrace na třech různých sadách (datasetech) dat. Tyto datasety zahrnují CT skeny, MRI snímky a retinální skeny. Výsledky vzešlé z WT filtrace šumů aplikovaných na konkrétní datasety jsou analyzovány a výsledkem této analýzy jsou konkrétní vlnky, které jsou pro konkrétní data nejefektivnější, ale také jsou výsledkem vlnky s nejnižší efektivitou. Šestá kapitola je věnována hodnocení efektivitě WT při segmentaci obrazu. Data jsou uměle zašuměna, jsou filtrována pomocí WT a následně jsou výstupní data segmentována pomocí Otsu metody. Výsledek této segmentace je porovnávám s výsledky segmentace, které vznikly aplikací Otsu metody na originální data.

# 1 Definice obrazu a jeho parametry

## 1.1 Motivace pro filtraci a zpracování obrazu

V moderní digitální době se filtrace a zpracování obrazu provádí zejména tehdy, pokud je třeba dojít k jednomu z následujících cílů. Jedním z důvodů je zlepšení vlastností obrazu tak, aby z něj bylo možné vyčíst co nejvíce informací. Druhou často využívanou oblastí aplikace zpracování obrazu je optimalizování vlastností dat pro uložení, pro přenos a pro následné zpracování autonomními počítačovými systémy či algoritmy.

V medicíně nachází zpracovávání obrazových dat široké uplatnění zejména v diagnostice, kdy data, která prošla zpracováním, jsou upravena tak, aby byly například patrné i struktury, které by mohly být bez úpravy obtížně postřehnutelné. Použitím určitých algoritmů lze docílit detekce různých patologických jevů. Medicínské snímky jsou během samotného pořízení a následnému přenosu vystaveny zkreslování vlivem šumu, který je tedy vhodné vyfiltrovat pomocí různých metod.

## 1.2 Definice obrazového signálu

Obraz není nic jiného než projekce 3D obrazu do 2D dimenze. Matematicky lze obraz popsat jako vícerozměrnou funkci, jež je definována počtem proměnných a jejich počet závisí na dimenzi, v které je funkce definována. Funkce definována v 2D se popisuje jako [11, 13, 15]:

$$f = (x, y) \quad (1.2.1)$$

Kde  $x$  a  $y$  jsou prostorové souřadnice a  $f$  je jas v bodě, na který odkazují  $x$  a  $y$ .

Digitální obraz může být reprezentován jako vícerozměrná matice. Pokud se jedná o monochromatický obraz, je matice dvourozměrná a pokud se jedná o obraz barevný (RGB), je trojrozměrná. Popis obrazu pomocí matice vypadá následovně [11, 13, 15]:

$$f(g, h) = \begin{pmatrix} f(1, 1) & f(1, 2) & \dots & f(1, h-1) \\ f(2, 1) & f(2, 2) & \dots & f(2, h-1) \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ f(g-1, 1) & f(g-1, 2) & \dots & f(g-1, h-1) \end{pmatrix} \quad (1.2.2)$$

Pokud má obrazová funkce spojitý rozsah hodnot, který zastupuje jas a prostorové souřadnice, hovoříme o analogovém obrazu. Pokud je počet  $x$ ,  $y$  finitní, jedná se o digitální signál. Digitální obraz tedy obsahuje konečný počet prvků a každý z těchto prvků má přiřazeno konkrétní umístění a konkrétní hodnotu. Tyto prvky jsou nejčastěji nazývány pixely. Aby bylo možné provádět zpracovávání obrazu, je třeba nejdříve převést analogový signál na digitální procesem zvaným digitalizace.

### 1.3 Vlastnosti obrazu

Digitální obraz je charakterizován následujícími údaji. Jedná se o jas, bitovou hloubku, rozlišení a dynamický rozsah, kontrast.

#### Jas

je údaj popisující svítivost. Jedná se o intenzitu světla, která vychází z obrazovky. U RGB se hodnota jasu spočítá jako aritmetický průměr hodnot R, G a B, tedy [11, 13, 15]:

$$I = \frac{R + G + B}{3} \quad (1.3.1)$$

nebo jako:

$$I = 0,299R + 0,587G + 0,114B \quad (1.3.2)$$

#### Bitová hloubka

obrazu neboli barevná hloubka, popisuje nejvyšší možné množství úrovní jasu. Je to počet bitů, které pixel zabírá v paměti. Při hloubce 1 bit ( $2^1$ ) je počet jasových úrovní roven 2, což odpovídá pouze černé a bílé. Při hloubce 8 ( $2^8$ ) bitů je počet úrovní 255 atd. [11, 13, 15].

#### Rozlišení

je matice pixelů, která je zobrazována na obrazovce. Udává se číselně jako šířka a výška obrazu [11, 13, 15].

#### Dynamický rozsah

lze vyjádřit jako poměr nejtmaššího a nejsvětějšího pixelu. DR je vyjádřitelný pomocí dB následující rovnicí [11, 13, 15]:

$$D_r = 20 \cdot \log \frac{J_{max}}{J_{min}} \quad (1.3.3)$$

kde  $D_r$  značí dynamický rozsah,  $J_{max}$  a  $J_{min}$  značí maximální a minimální hodnotu jasu.

#### Kontrast


je rozdíl v barvě a jasu pixelu v porovnání s jiným pixelem. Počítá se jako [11, 13, 15].

$$K = \frac{I_1 - I_2}{I_1 + I_2} \quad (1.3.4)$$

kde  $K$  je kontrast a  $I_1$  a  $I_2$  jsou hodnoty jasu pixelů.

## Histogram

Na rozdíl od předchozích parametrů nedefinuje vlastnosti obrazu, ale slouží k vyjádření zastoupení četností intenzit jasu v digitálním obraze. Jedná se o graf, kde rozsah hodnot na vodorovné ose popisuje kontrast obrazu. Pokud jsou hodnoty posunuty k pravému okraji, je obraz přesvětlený, neboli tzv. přeexponovaný, naopak pokud jsou hodnoty blíže nule vlevo, je obraz podexponovaný, tmavý. Ideální zastoupení četnosti hodnot jasu je pro běžné užití tedy přibližně uprostřed. Tím, že svou šířkou histogram popisuje kontrast, jeho roztáhnutím lze kontrast zvýšit. Nedojde ke změně počtu jasových úrovní, ale dojde k tomu, že některé pixely získají jinou hodnotu jasu. Jedná se o tzv. ekvalizaci histogramu. Ekvalizaci histogramu je vhodné použít, pokud chceme například v obraze s vysokým kontrastem nalézt prvky, jejichž kontrast je nízký [13, 15].



Obrázek 1: Ekvalizace histogramu [2]

Jak lze vidět na Obr. 1, v originálním obrázku bylo vlivem ekvalizace docíleno zvýšení kontrastu.



## 2 Zpracování obrazu

Tříd operací, využívaných při zpracování digitálního obrazu k transformaci vstupního obrazu na obraz výstupní a který co nejlépe vyhovuje pozorovateli, existuje několik. Podle prací [5] a [6] je jich rozlišováno pět. Těchto pět tříd zahrnují vylepšování kvality obrazu, obnovení kvality obrazu, analýzu obrazu, kompresi obrazu a skládání obrazů. [4]

### 2.1.1 Obnovení kvality obrazu

Smyslem této operace je zvýšení kvality obrazu, který obsahuje různá zkreslení nebo jiné prvky, které jeho kvalitu degradují. K těmto degradacím často dochází při přenosu obrazových dat. Příkladem takové degradace je rozmazání obrazu, kdy použitím vhodného filtru může být docíleno ostření obrazu. [4]

### 2.1.2 Analýza obrazu

Tato třída digitálního postprocessingu umožňuje různá statistická měření a náhled do vlastností obrazu. Dále tato třída zahrnuje segmentaci obrazu a klasifikaci objektů. Segmentace a klasifikace se využívá k odizolování a zvýraznění objektu, který je pro pozorovatele nějakým způsobem zajímavý. Dále na základě výsledků segmentace jsou z obrazu vytažena data, která charakterizují daný objekt a poté je těch dat využito k zařazení objektů do určitých nadefinovaných kategorií. [4]

### 2.1.3 Skládání obrazu

Pomocí této třídy dochází k vytváření obrazu složením jiných obrazu, nebo pomocí specifických dat. Těchto metod se využívá, je-li pořízení obrazu fyzikálně nemožné nebo by bylo velice složité. Příkladem těchto operací jsou různé rekonstrukční techniky, na kterých stojí například produkce CT nebo MRI obrazů. Také se využívají u 3D vizualizačních technik, které jsou založeny na počítačové grafice. Složením několika obrazů zachycujících průtok kontrastní látky cévami mozku ve venózní a arteriální fázi lze docílit zobrazení celého cévního systému v mozku, což by bylo jinak fyzikálně nemožné. [4]

### 2.1.4 Vylepšování kvality obrazu

Cílem této metody je vytvoření výstupního obrazu, který je pro pozorovatele co nejvíce vypovídající. Tato metoda manipuluje s charakteristikami obrazu, jakými jsou například kontrast, jas, ostrost hran v obrazu, frekvenční filtrování a filtrování šumu. [4]

### 2.1.5 Komprese obrazu

Smyslem komprese je zredukováná velikosti obrazu, aby došlo ke snížení času potřebného k jeho přenosu a také k ušetření místa v uložení. Existují dva typy komprese, z nichž jeden je bezztrátový, po kterém nedochází po dekompresi k žádným změnám v obraze, tedy komprimovaný a dekomprimovaný obraz jsou naprosto totožné. Druhým typem je komprese ztrátová, při které dochází po dekompresi ke ztrátám některých informací. Této komprese se využívá, pokud není nutné zachování co nejlepší kvality obrazu. [4]

## 2.2 Průběh zpracování obrazu

Zpracování obrazu bývá rozděleno do několika kroků. Ne všechny z těchto kroků musí být vždy vykonány.

### 2.2.1 Snímání obrazu

je logicky prvním krokem, který je potřebný k tomu, abychom mohli s obrazem dále pracovat. Jedná se o operaci, kdy je vstupní fyzikální veličina převedena na elektrický signál, se kterým lze dále pracovat pomocí počítačové techniky. Může se jednat klasicky o jas nebo různé složky elektromagnetického záření, ale také o mechanické vlnění, kterým je například ultrazvuk [13].

### 2.2.2 Digitalizace


je proces, kdy je analogový signál transformován na signál digitální. Digitální obraz se z analogového získává vzorkováním vstupního signálu do matice a ke vzorkům je na základě jejich jasu přiřazena jejich kvantová hodnota. Během digitalizace musí být dodržen Kotělnikovův teorém, což znamená, že nejmenší detail v obrazu musí být alespoň dvojnásobný oproti intervalu vzorkování. Při nedodržení tohoto pravidla by došlo k undersamplingu vstupního signálu, což vede ke vzniku chyb. Nejdůležitější částí digitalizace je zvolení vhodného rozlišení, protože příliš malé rozlišení způsobí ztrátu dat, na základě které dojde ke ztrátě obrazových detailů. Naopak příliš vysoké rozlišení negativně ovlivní výpočetní dobu. Další velice důležitou součástí digitalizace je vzorkovací mřížka, do které se udávají hodnoty odpovídající stupňům šedi jednotlivých pixelů [13].

### 2.2.3 Předzpracování obrazu


je proces, který se snaží napravit možné zkreslení, ke kterému došlo při snímání. Korekce zkreslení je možná, pokud je možné zkreslení charakterizovat. Nejtypičtější metody předzpracování zahrnují filtraci obrazu, ostření, manipulaci s jasnem nebo geometrickou transformaci [13].

### 2.2.4 Segmentace

Proces segmentace je popsán v kapitole 6.1, kde na základní teorii ohledně segmentace navazuje také praktická část zabývající se zkoumáním efektivity segmentace po provedení wavelet transformace na zašuměných obrazových datech[13].



(a) Segmentace CT snímku břišní dutiny



(b) Segmentace MRI snímku aorty a cév hlavy

Obrázek 2: Ilustrační příklady segmentace v medicíně

### 2.2.5 Popis objektů

Dalším důležitým krokem zpracování obrazu je popsání obrazu, nebo objektů, které vznikly při segmentaci. Je možné popsat vztahy mezi objekty a jejich vlastnosti, což je přístup kvalitativní, nebo kvantitativně popsat numericky vlastnosti objektů [13].

### 2.2.6 Klasifikace

Její princip často znamená zařazení objektů vstupního obrazu do nadefinovaných skupin. Popis objektů je velice důležitý, neboť dva základní principy klasifikace využívají buďto příznaků, které jsou určeny číselnou charakteristikou objektů, jedná se o rozpoznání příznakové, nebo využívá kvalitativní popis objektů, což je rozpoznání strukturální. Příznakové i strukturální rozpoznání jsou tedy dvě základní skupiny sloužící ke klasifikaci objektů [13].

## 3 Filtrace obrazu a analýza šumu

### 3.1 2D konvoluce

Jedná se o matematickou metodu užívanou při zpracování obrazu. Jde o operaci dvou funkcí. První funkcí je funkce, kterou zpracováváme a funkcí druhou je transformační funkce neboli tzv. konvoluční maska. U diskrétní konvoluce se jedná o matici hodnot. Maska se postupně posouvá po obraze a násobí hodnoty pixelů, které překrývá, svými koeficienty. Po sečtení všech těchto součinů je získána hodnota jasu pixelu ve výstupním obrazu [11, 12, 13].

Konvoluce obrazu je dána vztahem:

$$g(x, y) = h(x, y) \cdot f(x, y) \quad (3.1.1)$$

Kde  $h(x, y)$  je transformační funkce,  $f(x, y)$  je transformovaná funkce a  $g(x, y)$  je výsledný obraz.

Diskrétní konvoluce 2D obrazu je dána vztahem:

$$f(x, y) * h(x, y) = \sum_{i=-k}^k \left( \sum_{j=-k}^k f(x-i, y-j) \cdot h(i, j) \right) \quad (3.1.2)$$

Volba transformační funkce ovlivňuje výslednou změnu obrazu. Aplikováním konvoluce na celý obraz dojde k jeho rozostření, jehož míra je přímo úměrná velikosti konvoluční masky.

Konvoluce se uplatňuje u řady operací. Správnou volbou konvolučního jádra lze nadefinovat obrazové filtry, které slouží k vyhlazování nebo ostření obrazu [11, 12, 13].

## Druhy filtrace a charakteristiky šumu v biomedicině

Šum v obrazových materiálech je způsoben řadou zdrojů, které zahrnují přenos obrazu a vliv prostředí, který generuje Gaussovský šum, Poisson šum a šum Salt&Pepper. Metody filtrace těchto šumů se staly důležitou součástí medicínských obrazových aplikací. Nejčastěji používané filtry jsou mediánový filtr, Gaussovský filtr, Wienerův filtr, z nichž každý se nejlépe hodí pro jiný typ šumu.

Důležitou vlastností dobrého modelu filtrace je odstranění šumu z obrazu a zároveň co nejmenší zásah do kvality hran v obraze. Existují dva typy filtrace, které se k filtrování šumu využívají. Jedná se o lineární a nelineární filtraci. Lineární modely filtrace se používají, protože jsou rychlé, ale jejich hlavní nevýhodou je snižování ostrosti hran [11, 12, 13].

U lineárního i nelineárního filtrování se využívá konvoluce, kdy je hodnota každého pixelu přepočítána předem definovaným vztahem [11, 12, 13].

### 3.1.1 Lineární filtrace

U lineární filtrace je výstupní hodnotou obrazu lineární kombinace části obrazu pod konvoluční maskou a filtru typu dolní nebo horní propust. Vlastností charakterizující filtr typu dolní propust je, že součet jeho koeficientů je vždy roven 1, zatímco u filtru typu horní propust je součet vždy 0. Dolnoproputných lineárních filtrů se využívá při filtrování šumu z obrazu, ale jejich nevýhodou je nežádoucí rozostřování hran, kterým dochází ke zhoršování kvality obrazu.

### Wienerův filtr

Cílem Wienerova filtru je odfiltrování šumu, který je v signálu. Tato filtrační technika je založena na statistice. Typické filtry jsou navrženy na odezvu určité frekvence a Wienerův filtr je toho dobrým příkladem. Pro užití této metody je nutné znát spektrální vlastnosti původního signálu a spektrální vlastnosti šumu v obraze. Wienerova filtrace je technika, která se snaží provést rekonstrukci požadovaného signálu ještě předtím, než byl zasažen aditivními složkami [11, 19].

Filtrování pomocí Wienerova filtru je dáno vztahem:

$$\hat{F}(x, y) = \bar{g} + \frac{\sigma_f^2}{\sigma_f^2 + \sigma_n^2} \cdot (g(x, y) - \bar{g}) \quad (3.1.1.1)$$

Kde  $\hat{F}(x, y)$  je odhad obrazu bez šumu,  $h(x, y)$  impulzní odezva a  $\sigma_f^2$  je lokální rozptyl

## Průměrová filtrace

je jednou z nejběžnějších metod filtrování šumu. Je to speciální případ Gaussova filtru, který je však založen na normální Gaussovské distribuci. Jejím principem je snižování rozdílu intenzit jasu pixelů tím, že ke každému pixelu výstupního obrazu je přiřazena hodnota jasu, která odpovídá průměru jasu sousedních pixelů pixelu v původním obraze.

Matematická definice vypadá následovně:

$$\hat{f}(x, y) = \frac{1}{mn} \cdot \sum_{(s,t) \in S_{xy}} g(s, t)$$

Kde  $\hat{f}(x, y)$  je hodnota obnoveného pixelu, který má souřadnice  $(x, y)$ .  $S_{xy}$  je definice středu okna o rozměrech  $m \cdot n$ .  $g(x, y)$  je zašuměný obraz. Hodnota nových obnovených pixelů je tedy vypočítána z oblasti pixelů, které jsou definovány obdélníkovým oknem o rozměrech  $m \cdot n$  [11, 18].

## Gaussovský filtr


Oproti průměrovému filtru je Gaussovský filtr rozšířený o Gaussovo rozložení pravděpodobnosti. Středový bod masky, nebo jeho okolí, má tak oproti dalším bodům v masce vyšší váhu. Použitím tohoto filtru dochází k potlačení šumu, ale také detailů v obraze.

Jeho matematická definice vypadá následovně:

$$G(x, y) = \frac{1}{2\pi\sigma^2} \cdot e^{-\frac{x^2+y^2}{2\sigma^2}}$$

Kde  $\sigma^2$  je rozptyl,  $(x, y)$  jsou souřadnice pixelu v obrazové matici a  $G(x, y)$  je filtrovaný obraz.

Příklad tohoto šumu v biomedicínských obrazech je vyobrazen na Obr. 3.




Obrázek 3: Filtrace Gaussova šumu Gaussovým filtrem [3]

### 3.1.2 Nelineární filtrace

Na rozdíl od lineární filtrace není výstupem nelineárního filtru hodnota odvozená jako lineární kombinace hodnot vstupního obrazu, ale na základě jiného algoritmu je vybrána hodnota z okolí bodu. Výhodou nelineárních filtrů je, že potlačují šum a oproti lineárním filtrům jsou šetrnější k hranám obrazu.

#### Mediánový filtr

Pomocí okna o lichém počtu pixelů jsou seřazeny hodnoty jednotlivých pixelů do posloupnosti od nejnižší po nejvyšší a následně je z těchto hodnot vybrán medián, který je dosazen za hodnotu výstupního pixelu. Pokud má okno sudý počet prvků, jsou prostřední dvě hodnoty aritmeticky zprůměrovány a dosazeny. Příklad mediánové filtrace zachycuje Obr. 4 [11, 13].



Obrázek 4: Filtrace šumu Salt&Pepper mediánovým filtrem [3]

### 3.1.3 Typy šumů v medicínských obrazech

Obrazový šum je zcela náhodnou a informačně prázdnou odchylkou, která vzniká při pořízení obrazu. Způsobuje zhoršení kvality obrazu a tím může dojít ke komplikacím při pozorování snímku, nebo k úplnému znemožnění stanovení diagnózy zejména pokud je obraz málo kontrastní a hodnoty šumu jsou vysoké. Vlastnosti šumu jsou závislé na jeho původu. Pro šумы různých vlastností je třeba vybrat co nejvhodnější filtr, aby nedošlo k nadbytečným a nežádoucím změnám v obraze [11, 12].

#### Gaussovský šum

Je to nejčastěji vyskytující se aditivní šum. Je charakteristický normálním rozložením pravděpodobnosti, které je charakterizováno Gaussovou křivkou. Negativně ovlivňuje stupnici šedi digitálního obrazu. Zasahuje všechny pixely v obraze. Původcem Gaussova šumu jsou přírodní zdroje, například tepelná vibrace atomů [11, 12].

Lze jej popsat takto:

$$P(z) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot e^{-\frac{(z-m)^2}{2\sigma^2}} \quad (3.1.3.1)$$

Kde  $P(z)$  je pravděpodobnost výskytu hodnoty stupně šedi  $z$ ,  $m$  značí střední hodnotu dané funkce a směrodatnou odchylku šumu značí  $\sigma$ .


Příklad tohoto šumu v biomedicínských obrazech je vyobrazen na Obr. 5.



Obrázek 5: Originální obraz a obraz degradovaný Gaussovým šumem [3]

### Poisson šum

Na první pohled je to šum, který se podobá Gaussovu šumu. Na rozdíl od Gaussova šumu je intenzita šumových pixelů odvozena od intenzity pixelů v původním obraze a nejsou zasaženy všechny pixely. Příklad tohoto šumu v biomedicínských obrazech je vyobrazen na Obr. 6 [11, 12].



Obrázek 6: Originální obraz a obraz degradovaný šumem Poisson [3]



## Speckle šum

Jedná se o šum zvyšující průměrnou hodnotu úrovně šedé v obraze. Nejedná se o náhodný šum, ale je ovlivněn snímačem nebo vlastnostmi tkáně. Zejména v ultrazvukové diagnostice se jedná o velký problém, neboť šumem mohou být pohlceny některé anatomické oblasti.

Pokud UZV vlna narazí na částici, která stejná nebo menší než vlnová délka této vlny, dojde k částečné absorpci energie, která je poté částicí opět vyzařena ve formě vlnoploch. Interferencí těchto vlnoploch vznikají světlá a tmavá místa [11, 12].

Rozdělení pravděpodobnosti šumu typu Speckle vypadá následovně:

$$P(z) = \frac{z^{\alpha-1}}{(\alpha-1)! \cdot a^{\alpha}} \cdot e^{-\frac{z}{a}} \quad (3.1.3.2)$$

Kde  $P(z)$  je rozdělení pravděpodobnosti,  $z$  je zastoupení stupnice jasu a  $a^{\alpha}$  značí odchylku.

Příklad tohoto šumu v biomedicínských obrazech je vyobrazen na Obr. 7.



Obrázek 7: Originální obraz a obraz degradovaný šumem Speckle [3]

## Šum Salt&Pepper


Jedná se o tzv. impulzní šum, neboť se v obraze vyskytuje jen ve dvou intenzitách. Pixely jsou tímto šumem zasaženy buďto maximální nebo minimální hodnotou v závislosti na typu přenosu obrazu. Jeho definujícím parametrem je hustota (d). Pro 8 bitový přenos se jedná o intenzity 0 nebo 255. Obraz zasažený tímto typem šumu obsahuje světlé pixely v tmavých místech a tmavé pixely ve světlých místech. Velice dobře je filtrován pomocí mediánového filtru.

Příklad degradace obrazu tímto typem šumu je naznačen na Obr. 8, kdy je zasažena prostřední hodnota z obrazové matice. Tento bod se bude v obraze jevit jako černá tečka. V případě, že by byla původní centrální hodnota 50 a byla by nahrazena hodnotou 255, vypadal by tento bod jako bílá tečka. Projevy tohoto šumu na obraze tedy vypadají jako rozsypaná sůl a pepř [11, 12].

$$\begin{bmatrix} 231 & 215 & 134 \\ 106 & 246 & 59 \\ 21 & 85 & 49 \end{bmatrix} \rightarrow \begin{bmatrix} 231 & 215 & 134 \\ 106 & 0 & 59 \\ 21 & 85 & 49 \end{bmatrix}$$

Obrázek 8: Příklad centrálního pixelu zasaženého šumem typu Salt&Pepper

Příklad tohoto šumu v biomedicínských obrazech je vyobrazen na Obr. 9.



Obrázek 9: Originální obraz a obraz degradovaný šumem Salt&Pepper [3]

## 3.2 Hodnocení kvality obrazu

Kvalitu obrazu může ovlivnit celá řada faktorů, které zahrnují pořízení obrazu, přenos, zobrazení nebo komprimování. Rostoucí zájem o digitální technologie v oblastech, jako jsou právě lékařské zobrazování, biomedicínské systémy nebo monitoring, ukázal na potřebu mít k dispozici přesné hodnotící metody kvality obrazu. Přesné změření kvality obrazu je velmi důležité u mnoha obrazových aplikací [11, 12].

### 3.2.1 Subjektivní hodnocení kvality obrazu

Jedná se o metody pracující se subjektivním názorem odborníka na kvalitu obrazu. Hodnotí se zejména rozlišení, jas a kontrast, kvalita barev, úroveň šumu nebo ostrost hran. Subjektivní hodnocení je ovlivněno celou řadou faktorů, které mohou výsledek značně ovlivnit. Jedná se zejména o únavu, zkušenosti, ale také o rozdílnou citlivost vnímání, kdy jednomu pozorovateli může vadit něco, čeho si druhý pozorovatel ani nevšimne [11, 12].

**MOS** – Mean Opinion Score

je metoda zahrnující řadu dotazníků. Jejich výstupem je subjektivní číselné hodnocení. Ze souboru výsledků je získáno celkové hodnocení pomocí zprůměrování [11, 12].

Matematické vyjádření:

$$MOS(j) = \frac{1}{M} \sum_{i=1}^M S(i, j) \quad (3.3.1)$$

Kde  $S(i, j)$  je výsledné bodové ohodnocení obrazu  $j$  respondentem  $i$ .  $M$  je celkový počet respondentů, kteří daný obraz hodnotili.

### 3.2.2 Objektívni hodnocení kvality obrazu

Cílem je vytvoření matematických algoritmů, které jsou schopny přesně a automaticky hodnotit kvalitu obrazu. Výsledek by měl být v ideálním případě rovnat výsledku, kterého dosáhl zkušený odborník [11, 12].

**MSE** – Mean squared error

je průměrná kvadratická chyba mezi dvěma daty. Využívá se často, ale z důvodů nedostatečné korelace by se měl využívat společně s dalšími metodami. Výsledek bývá nezáporný a žádoucí je co nejnižší hodnota. [11, 12].

Matematické vyjádření:

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (p_{ij} - f_{ij})^2 \quad (3.3.2)$$

kde  $p_{ij}$  je původní obraz a  $f_{ij}$  je referenční obraz.

### RMSE – Root mean squared error

je obecně nejlepší aproximace standardní chyby. Matematicky se jedná o druhou odmocninu MSE. Výsledná hodnota je vždy nezáporná. Výsledek 0 by znamenal perfektní shodu dat. Čím menší je výsledná hodnota, tím je kvalita obrazu lepší [11, 12].

Matematické vyjádření:

$$RMSE = \sqrt{MSE} \quad (3.3.3)$$

### GAE – Geometric average error

je metoda porovnávající transformovaný obraz s původním obrazem. Opět platí, že pokud se jeho hodnota blíží nule, je transformovaný obraz kvalitní [11, 12].

Matematické vyjádření:

$$GAE = \prod_{i=1}^M \prod_{j=1}^N \sqrt{(p_{i,j} - f_{i,j})^{\frac{1}{MN}}} \quad (3.3.4)$$

kde  $p_{i,j}$  je původní obraz a  $f_{i,j}$  je referenční obraz.

### S/N – Signal to noise ratio

doslova se jedná o odstup signálu od šumu. Porovnává tedy úroveň šumu a signálu. Čím vyšší je úroveň signálu oproti úrovni šumu, tím je poměr vyšší, což ukazuje na to, že je šum méně rušivý a signál jej přebíjí. Poměr tedy chceme co nejvyšší [11, 12].

Matematické vyjádření:

$$SNR = 10 \log_{10} \cdot \frac{\sum_{i=1}^M \sum_{j=1}^N (p_{i,j}^2 - f_{i,j}^2)}{\sum_{i=1}^M \sum_{j=1}^N (p_{i,j} - f_{i,j})^2} \quad (3.3.5)$$

kde  $p_{i,j}$  je původní obraz a  $f_{i,j}$  je referenční obraz.

### PSNR – Peak signal to noise ratio

jde o poměr nejvyššího výkonu signálu a výkonu rušivého signálu. Vyjadřuje se pomocí logaritmického měřítka, neboť dynamický rozsah intenzity pixelů bývá velmi široký [11, 12].

Matematické vyjádření:

$$PSNR = 10 \log \cdot \frac{D^2}{MSE} \quad (3.3.6)$$

D značí dynamický rozsah intenzity pixelů.

### Quality index

je metoda vyhodnocující zkraslení na základě kombinace zkraslení jasu a kontrastu a ztráty korelace [11, 12].

$$Q = \frac{n_{xy}}{n_x n_y} \cdot \frac{2\bar{x}\bar{y}}{\bar{x}^2 + \bar{y}^2} \cdot \frac{2n_x n_y}{n_x^2 + n_y^2} \quad (3.3.7)$$

První člen je korelační koeficient mezi  $x$ ,  $y$ . Měří stupeň lineární korelace s dynamickým rozsahem mezi -1 a 1. Hodnota 1 je nejlepší možný výsledek.

Druhý člen má dynamický rozsah od 0 do 1 a porovnává střední hodnoty jasu  $x$  a  $y$ . Nejvyšší hodnota 1 je dosažena, pokud je aritmetický průměr  $x$  a  $y$  roven.

Třetí člen vyhodnocuje podobnost kontrastů opět s dynamickým rozsahem 0 až 1, kdy pro dosažení nejlepšího výsledku musí být kontrasty rovny.

## 4 1D a 2D Wavelet transformace

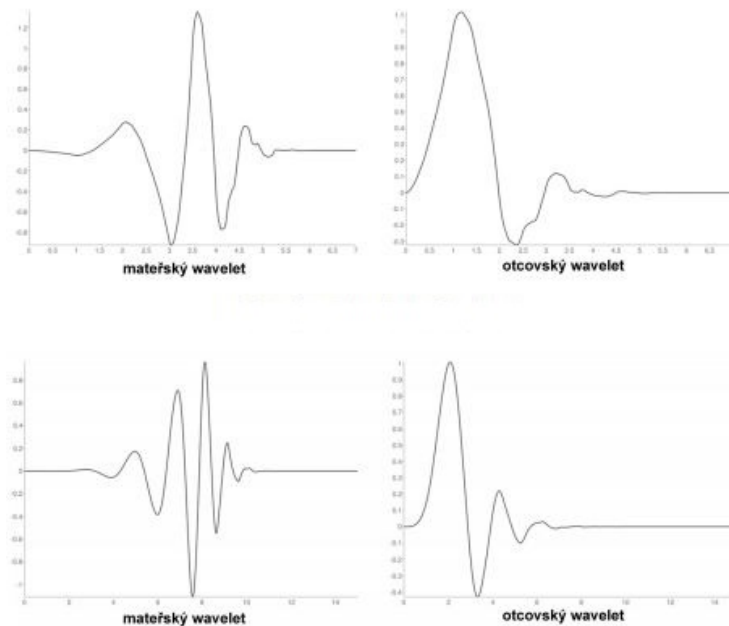
Vlnková transformace se stala rozšířeným matematickým prostředkem sloužícím ke zpracování a analýze obrazů nestacionárních signálů obecně. Je alternativní metodou k Fourierově transformaci, která se k analýze těchto signálů příliš nehodí, neboť neposkytuje údaje o časové lokalizaci jednotlivých složek spektra signálu. Zatímco FT využívá pro rozklad signálu sinových a kosinových funkcí, při WT je využíváno speciálních funkcí zvaných wavelety (vlnky) [7, 8, 9, 11].

### 4.1 Wavelet (vlnka)

Wavelet je funkce, jejíž tvar je možno zvolit podle charakteru signálu, který je předmětem analýzy, analyzovaného obrazu, nebo podle typu aplikace. Wavelety slouží k rozdělení složek signálu podle frekvence a tyto složky lze analyzovat s rozlišením, které je optimální vzhledem k jejich měřítku. Wavelet vypadá jako krátká funkce, která osciluje kolem místa daného jeho translací a která má konečnou energii. Dvěma důležitými pojmy jsou dilatace a translace. Dilatace je pojem označující změnu šířky waveletu podél časové osy a translace je jeho časový posun.

Smyslem celé WT je rozložení vstupního signálu na waveletové koeficienty, kterého je docíleno pomocí dvou funkcí. Těmito funkcemi jsou tzv. otcovský wavelet  $\phi$  a mateřský wavelet  $\psi$ , jejichž dilatací a translací vznikají dceřiné wavelety. Těmto dceřiným waveletům je posléze nastaveno měřítko a postupným posouváním po analyzovaném signálu jsou vypočítány koeficienty.

Waveletů existuje mnoho typů, mezi které patří například wavelety Haar, Symlets, Daubechies, Meyer, nebo Mexican hat, které se liší a každý z nich se lépe hodí pro jiný typ aplikace. Příklad waveletu je na Obr. 10: Wavelety typu Daubechies 8 (nahore) a Daubechies 16 (dole). Obr. 10 zobrazuje mateřskou i otcovskou vlnku, která slouží k charakteristice trendu funkce [7, 8, 9, 11].



Obrázek 10: Wavelety typu Daubechies 8 (nahore) a Daubechies 16 (dole).

Rovnice funkce, pro kterou platí zvolené dilatační a translační parametry, vypadá následovně [7]:

$$W_{m,k}(t) = \frac{1}{\sqrt{a}} w\left(\frac{t-b}{a}\right) = \frac{1}{\sqrt{2^m}} w(2^{-m} t - k) \quad (4.1.1)$$

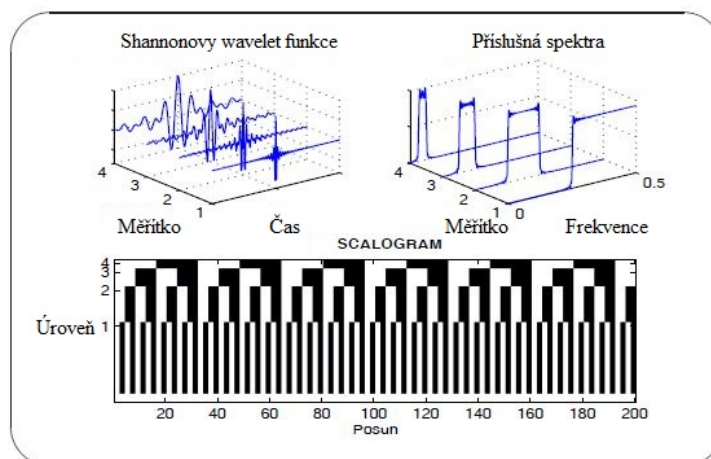
Kde  $a = 2^m$  je parametrem dilatace,  $b = k 2^m$  je parametrem translace,  $k$  a  $m$  jsou konstanty a  $w(t)$  je rovnice zvolené výchozí funkce.

### Scalogram

Koeficienty získané konvolucí waveletu a analyzované funkce jsou ukládány do tzv. scalogramu (vlnkové mapy), ve kterém koeficienty znázorňují míru podobnosti (korelace) mezi daným waveletem a analyzovaným signálem. Vodorovná osa scalogramu značí posun waveletu a svislá osa znázorňuje úroveň rozkladu o úrovni  $m$  v měřítku  $2^m$ . Platí, že analyzováním pomocí základní dilatované funkce dochází ke zhoršování časového rozlišení, ale u frekvenčního rozlišení dochází ke zlepšení. Tyto změny v rozlišení jsou pro wavelety charakteristické. Díky této vlastnosti lze analyzovat signál globálně i lokálně [7].

## 4.2 Diskrétní wavelet transformace (DWT)

Tím, že wavelet je funkcí o pásmově omezeném spektru, je vlastně WT filtrováním signálu pásmovou propustí. K detekci pomalých frekvenčních složek slouží měřítková funkce, tzv. scaling function. Jedná se tedy o filtr typu dolní propust (low-pass filter). Konvolucí signálu a waveletu jsou koeficienty získávány tak, že velká a dilatovaná měřítka waveletu odpovídají malým frekvencím a malá měřítka naopak odpovídají vysokým frekvencím. Velká měřítka tedy ze signálu vytahují aproximační složku, která popisuje hrubý tvar signálu, a malá měřítka naopak popisují detailní složku, tedy jemné detaily (vysoké frekvence) signálu [7, 8, 9, 11].



Obrázek 11: Znázornění Shannonových waveletů o různé dilataci, jejich příslušná spektra a scalogram zobrazující koeficienty o rozdílném časovém i frekvenčním rozlišení na různých dekompozičních úrovních [7].

### 4.3 1D DWT

Koeficienty jsou získávány postupným filtrováním signálu vysokofrekvenčními a nízkofrekvenčními filtry. Signál je tak postupně rozložen podle tzv. dekompozičního schématu. Přefiltrováním vstupního signálu je na výstupu vysokofrekvenčního filtru detailní složka, která se dále nefiltruje, a na výstupu nízkofrekvenčního filtru je aproximační složka. V této chvíli byla provedena dekompozice 1. úrovně. Filtrováním výstupu nízkofrekvenčního filtru bude dosaženo dekompozice 2. úrovně [7, 8, 9, 11].

Vyjádření detailní složky po dekompozici [8][9]:

$$D_p(n) = \sum_{k=0}^{L-1} h_d(k)x(2n - k) \quad (4.3.1)$$

Kde  $D_p$  je detailní složka,  $h_d(k)$  je definice vysokofrekvenčních filtrů a  $p$  je úroveň dekompozice.


Vyjádření aproximační složky po dekompozici [8][9]:

$$A_p(n) = \sum_{k=0}^{L-1} l_d(k)x(2n - k) \quad (4.3.2)$$

Kde  $A_p$  je aproximační složka,  $l_d(k)$  je definice nízkofrekvenčních filtrů a  $p$  je úroveň dekompozice.

Z dekompozičních filtrů lze vytvořit rekonstrukční filtry. Po dekompozici a vyprahování koeficientů je možno pomocí těchto nově získaných koeficientů využít k inverzní wavelet transformaci (IDWT), kdy se dekompoziční filtry využijí ke zpětné rekonstrukci signálu, který je složen z vyprahovaných koeficientů a je tak z něj odstraněn šum [8].

Na Obrázek 12 z práce [8] je znázorněna DWT EKG signálu.



Obrázek 12: Dekompozice EKG signálu s detekcí nespojitosti [7].



### 4.3.1 Prahování

Aby bylo možné provést potlačení aditivních složek signálu, musí být mimo dekompozice a rekonstrukce signálu provedeno navíc tzv. prahování koeficientů. Prahováním je myšleno nahrazení koeficientů, které splňují určité podmínky. Toto prahování může být jak globální, kdy je uplatněno na všechny úrovně rozkladu, tak lokální, kdy se prahování provede jen na vybrané úrovně rozkladu. Prahování je dvojího typu. Je to prahování tvrdé nebo měkké.

#### Tvrdé prahování

Tímto typem prahování dochází k vynulování koeficientů, které se nacházejí pod úrovní nastaveného prahu. Koeficienty nad úrovní prahu jsou ponechány beze změny. Tvrdé prahování lze popsat jako rovnicí [7, 11]:

$$T_h(n) = \begin{cases} x(n) & \text{pro } |x(n)| > p \\ 0 & \text{pro } |x(n)| \leq p \end{cases} \quad (4.3.1.1)$$

#### Měkké prahování

Měkké prahování funguje na stejném principu jako tvrdé prahování. Rozdíl je v tom, že všechny koeficienty nad úrovní prahu jsou zmenšeny o velikost prahu. Koeficienty pod úrovní prahu jsou vynulovány. Měkké prahování lze popsat jako rovnicí [7, 11]:

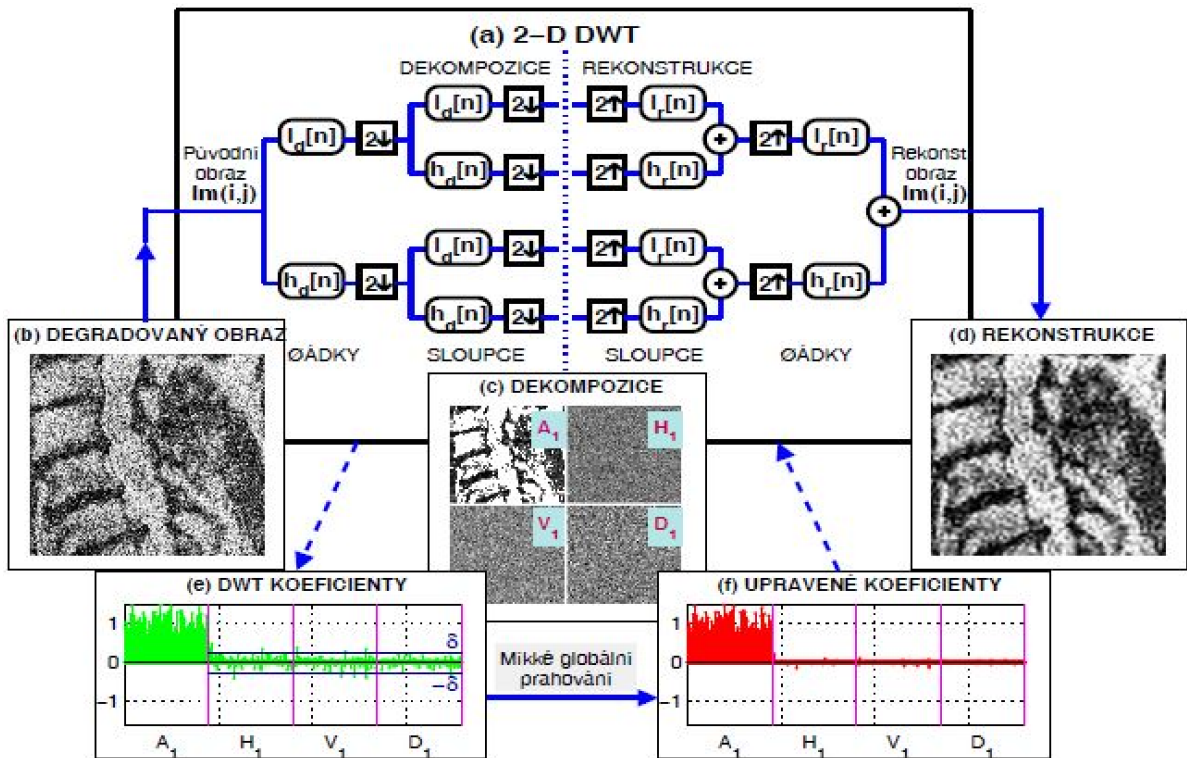

$$T_h(n) = \begin{cases} |x(n)| - p & \text{pro } |x(n)| > p \\ 0 & \text{pro } |x(n)| \leq p \end{cases} \quad (4.3.1.2)$$

## 4.4 2D DWT

Ve zpracování obrazu se WT využívá zejména k detekování hran, různých objektů, kompresi a filtrování aditivních složek. Stejně jako u 1D DWT funguje její princip na dekompozici vhodnou wavelet funkcí, následném prahování koeficientů a na závěr je obraz zrekonstruován. Jednorozměrný signál lze interpretovat jako speciální případ obrazu zredukovaného do jednoho sloupce. 2D DWT je tedy wavelet transformací dvourozměrného signálu.

Obrazová matice  $[G(n, m)]_{N, M}$  je rozložena do první úrovně na aproximační a detailní složku pro každý řádek pomocí dekompozičních filtrů  $l_d(k)$  a  $h_d(k)$ . Dále jsou výstupy obou filtrů podvzorkovány 2, čímž vzniknou dvě nové matice  $[G_L(n, m)]_{N/2, M/2}$  a  $[G_H(n, m)]_{N/2, M/2}$ . Tyto dvě matice jsou následně stejně zpracovány pro sloupce a ve výsledku je tak vstupní obraz rozdělen na čtyři matice  $A1 = [G_{LL}(n, m)]_{N/2, M/2}$ ,  $H1 = [G_{LH}(n, m)]_{N/2, M/2}$ ,  $V1 = [G_{HL}(n, m)]_{N/2, M/2}$ ,  $D1 = [G_{HH}(n, m)]_{N/2, M/2}$ .

$G_{LL}$  jsou aproximační koeficienty,  $G_{LH}$  jsou horizontální detaily,  $G_{HL}$  jsou vertikální detaily a  $G_{HH}$  jsou diagonální detaily obrazu. Princip 2D DWT je zachycen na Obr. 13, kde je znázorněna filtrace šumu z MRI snímku a princip rozkladu. [7, 11, 17].



Obrázek 13: Princip filtrování obrazu pomocí DWT [7, 11, 17].

## 5 Praktická část I. – Filtrace obrazových dat pomocí WT

V praktické části práce byla provedena filtrace šumu pomocí vlnkové transformace. Celkem byly testovány tři rodiny vlnek, které byly použity pro filtraci tří druhů šumů ze tří různých datasetů. Tyto datasety jsou tvořeny klinickými obrazy. Jedná se o dataset CT snímků dutiny břišní, MRI dataset krevních cév a dataset retinálních skenů. Na každý snímek z datasetů byly aplikovány tři typy šumů ve dvaceti úrovních. Pro filtraci byly použity vlnky z rodin Daubechies, Symlets a Coiflets. Z rodiny Daubechies byly testovány vlnky db1, db5 a db10, z rodiny Symlets sym3 a sym8 a z rodiny Coiflets se jednalo o vlnky coif1 a coif5. Vstupní obraz byl rozložen na detailní a aproximační složku v závislosti na nastavení úrovně dekompozice a v závislosti na typu vlnky. Byla použita úroveň rozkladu 3, 5 a 8. K prahování vlnkových koeficientů bylo použito měkké prahování pomocí MATLAB funkce `sorh`. Proces filtrace podle daných parametrů byla provedena funkcí `wdencomp`.

Výstupem celého procesu je vyfiltrovaný obraz, který je dále zkoumán vybranými metodami objektivního hodnocení obrazu. Těmito vybranými metodami jsou korelace, MSE (střední kvadratická chyba), PSNR (maximální poměr signálu a šumu) a SSIM (index strukturální podobnosti).

Tato část práce se zabývá hodnocením efektivity filtrace použitím různých typů vlnek k filtraci různých typů šumu. Výsledky budou vyhodnoceny pro každý dataset zvlášť a v rámci datasetu pro každý šum zvlášť. Výstupem tohoto hodnocení bude zjištění, která z testovaných vlnek je nejvhodnější pro filtraci daného šumu v daném datasetu, ale také bude vyhodnocena, která vlnka je pro daný šum vhodná nejméně. Testováno bylo celkem 60 obrazů ze tří datasetů (20 obrazů pro dataset). Hodnocení bylo provedeno pomocí metod MSE, korelace, PSNR a SSIM a bylo provedeno pro každý snímek zvlášť s tím, že nakonec byl z těchto výsledků spočítán aritmetický průměr, s kterým je pracováno v grafech.

Z databáze hodnot objektivních hodnotících metod byly postupně vybrány vlnky, které jsou v rámci svých rodin nejvhodnější a nakonec byli tito zástupci rodin porovnání mezi sebou. Výsledkem je vlnka, která je pro filtraci daného šumu v daném datasetu nejvhodnější

## 5.1 Výsledky pro dataset CT



Obrázek 14: Stupně hustoty Gaussova šumu 0.02, 0.2 a 0.4, rozptyl 0.01 (zleva)



Obrázek 15: Stupně hustoty Salt&Pepper šumu 0.001, 0.02 a 0.04 (zleva)



Obrázek 16: Stupně hustoty šumu Speckle 0.02, 0.2 a 0.4 (zleva)

Jak bylo popsáno v kapitole 5.1, na obrazová data byl aplikován šum ve dvaceti úrovních podle parametrů daného šumu. Pro Gaussovský šum byly těmito parametry rozptyl 0,01 a střední hodnota 0,02 do 0,4 s krokem 0,02. U šumu Salt&Pepper je parametrem hustota (d) nastavená od 0,02 do 0,4 s krokem 0,02 a u šumu Speckle byla hustota (d) nastavená od 0,02 do 0,4 s krokem 0,02.

Nejnižší, střední a nejvyšší stupeň zašumění pro jednotlivé typy šumu znázorňují obrázky 14, 15 a 16 výše.

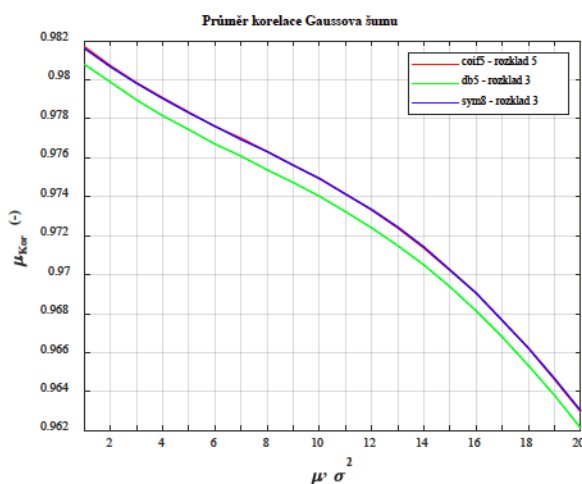
### 5.1.1 Gaussovský šum

Tab. 1 vyobrazuje průměrné číselné hodnoty vybraných objektivních hodnotících metod. Za tyto metody byla zvolena korelace, střední kvadratická chyba (MSE) a index strukturální podobnosti (SSIM). Obr. 17 je graficky znázorňuje hodnoty hodnotících metod napříč celým spektrem stupňů zašumění.


Nejvhodnější vlnka pro Gaussovský šum

	Gaussovský šum; $\mu = 0.02$			Gaussovský šum; $\mu = 0.2$			Gaussovský šum; $\mu = 0.4$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
db5 rozk. 3	0,978	293,695	0,278	0,968	2794,660	0,187	0,955	10076,17	0,150
coif5 rozk. 5	<b>0,9817</b>	<b>252,845</b>	<b>0,292</b>	0,97492	<b>2731,257</b>	0,20126	<b>0,963</b>	<b>9992,882</b>	0,1621
sym8 rozk. 3	0,9816	253,849	0,291	<b>0,97494</b>	2731,924	<b>0,20127</b>	0,963	9995,784	<b>0,1622</b>


Tabulka 1: Hodnoty vybraných hodnotících metod znázorňující nejvhodnější vlnku pro Gaussovský šum




(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 17: Porovnání výsledných hodnot nejlepších vlnek napříč rodinami pro Gaussovský šum.

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejefektivnější pro filtrování Gaussova šumu z CT obrazu. Na základě porovnání dat z Tab. 17 a průběhů z Obr. 17 je možné vybrat vlnku, která je pro v rámci CT datasetu nejvhodnější pro filtraci Gaussova šumu.

Obrázek 17 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. **Napříč celým spektrem zašumění se nejlépe jeví vlnka coif5.** Za povšimnutí stojí, že vlnka sym8 je svými hodnotami korelace velice blízko vlnce coif5. Celkově je trend korelace všech křivek víceméně lineárně sestupný, což ukazuje na fakt, že čím více je obraz zašuměný, tím nižší je efektivita filtrace.

Obrázek 17 (b) znázorňuje MSE. Nejmenších hodnot nabývá vlnka **coif5**, nicméně rozdíl oproti sym8 je opět velmi malý. MSE se s rostoucí úrovní šumu zvyšuje.

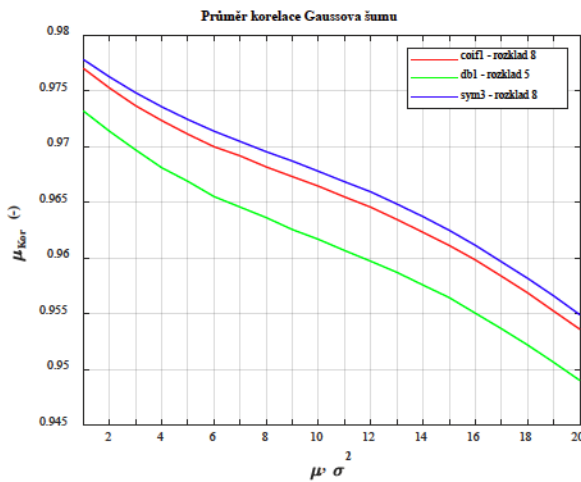
Obrázek 17 (c) znázorňuje SSIM. **Při nejnižší úrovni šumu dosahuje nejlepšího výsledku vlnka coif5 o rozkladu 5, při střední a nejvyšší úrovni je nejefektivnější vlnka sym8.**

Obrázek 17 (d) znázorňuje PSNR. Trend hodnot je napříč spektrem sestupný a hodnoty jsou pro všechny vlnky velmi blízké.

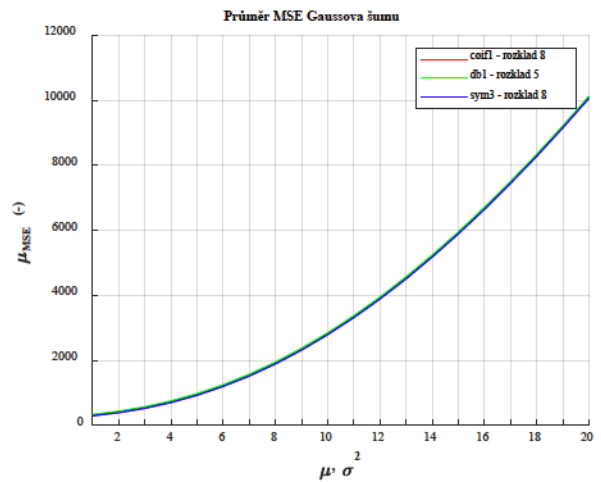
### Nejnevhodnější vlnka pro Gaussovský šum

	Gaussovský šum; $\mu = 0.02$			Gaussovský šum; $\mu = 0.2$			Gaussovský šum; $\mu = 0.4$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
db1 rozk. 5	0,9732	332,7191	0,2548	0,9667	2844,3163	0,1702	0,9490	10127,4771	0,1387
coif1 rozk. 8	0,9770	310,6356	0,2686	0,9665	2818,2315	0,1826	0,9536	10108,5604	0,1474
sym3 rozk.8	0,9778	293,3769	0,2759	0,9678	2795,1623	0,1863	0,9549	10072,5053	0,1496

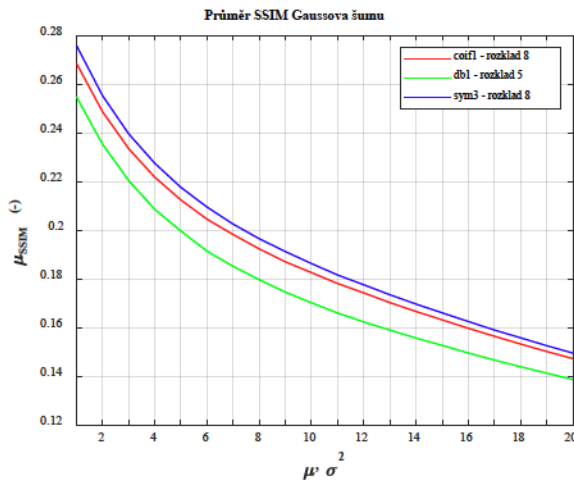
Tabulka 2: Hodnoty vybraných hodnotících metod znázorňující nejméně vhodnou vlnku pro Gaussovský šum



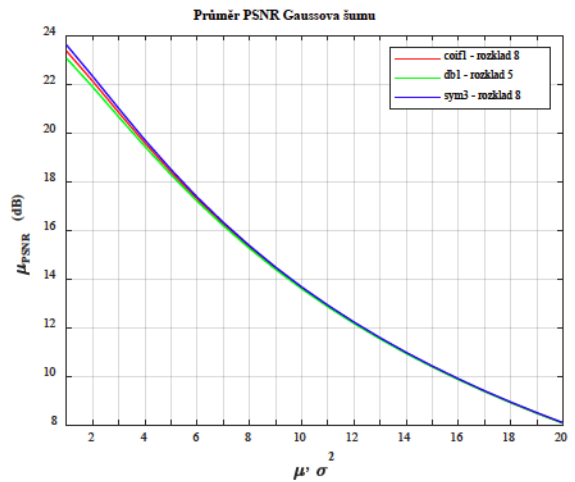
(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 18: Porovnání výsledných hodnot nejméně vhodných vlnků napříč rodinami pro Gaussovský šum.

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejméně efektivní pro filtrování Gaussova šumu z CT obrazu. Na základě porovnání dat z Tab. 2 a průběhů z Obr. 18 je možné vybrat vlnku, která je pro v rámci CT datasetu nejméně vhodná pro filtraci Gaussova šumu.

Obrázek 18 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Napříč celým spektrem zašumění se nejméně efektivně jeví vlnka **db1**. S rostoucím stupněm zašumění efektivita filtrace klesá.

Obrázek 18 (b) znázorňuje MSE. Nejvyšších hodnot nabývá vlnka **db1**. Trend křivky je pro všechny vlnky stejný.

Obrázek 18 (c) znázorňuje SSIM. Napříč celým spektrem je nejméně efektivní vlnka **db1**. Trend křivky je pro všechny vlnky stejný.

Obrázek 18 (d) znázorňuje PSNR. Trend hodnot je napříč spektrem sestupný a hodnoty jsou pro všechny vlnky velmi blízké. Nejméně vhodně se opět jeví vlnka **db1**.



### 5.1.2 Závěr pro dataset CT – Gaussovský šum

Pro nejnižší úroveň šumu je nejvhodnější vlnka **coif5 o rozkladu 5**, zatímco pro střední a nejvyšší úroveň šumu je nejvhodnější vlnka **sym8 o rozkladu 3**. Naopak jako nejméně vhodná vlnka se jeví **db1 o rozkladu 5**. Na základě Tab. 17 a průběhů z Obr. 17 je patrné, že hodnoty obou vlnek jsou si velice podobné a je nemožné označit jen jednu z nich jako nejlepší, ale při zobrazení obrazových výsledků filtrace bylo zjištěno, že si vlnka **sym8 o rozkladu 3** vede daleko lépe.

Obrazové výsledky filtrace jsou zobrazeny na obrázcích níže.




(a) Originální snímek z datasetu CT




(b) Snímek z dat. CT, Gauss. šum:

$$\sigma^2 = 0.01, \mu = 0.4$$



(c) Snímek filtrovaný vlnkou db1 o rozkladu 5





(d) Snímek filtrovaný vlnkou sym8 o rozkladu 3

### 5.1.3 Šum Salt&Pepper

Nejvhodnější vlnka


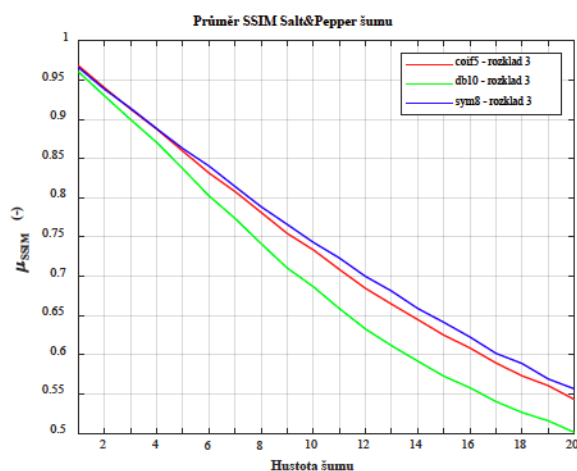
	Salt&Pepper šum; d = 0,001			Salt&Pepper šum; d = 0,02			Salt&Pepper šum; d = 0,04		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
db10 rozk.3	0,9962	31,0188	0,9609	<b>0,9784</b>	<b>179,1888</b>	0,6867	<b>0,9749</b>	<b>209,7846</b>	0,5010
coif5 rozk.3	<b>0,9965</b>	<b>28,6516</b>	<b>0,9686</b>	0,9731	226,3943	0,7337	0,9585	351,4648	0,5430
sym8 rozk.3	0,99633	30,176402	0,966292	0,97159	240,038288	<b>0,743284</b>	0,95470	386,52307	<b>0,556442</b>

Tabulka 3: Hodnoty vybraných hodnotících metod znázorňující nejvhodnější vlnku pro šum Salt&Pepper



(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.

(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.

(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 19: Porovnání výsledných hodnot nejvhodnějších vlnek napříč rodinami pro šum Salt&Pepper.

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejefektivnější pro filtrování Salt&Pepper šumu z CT obrazu. Na základě porovnání dat z Tab. 3 a průběhů z Obr. 19 je možné vybrat vlnku, která je pro v rámci CT datasetu nejvhodnější pro filtraci šumu Salt&Pepper.

Obrázek 19 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Do zhruba **prvních tří stupňů šumu se nejefektivněji jeví vlnka coif5. Při střední úrovni šumu se nejefektivněji jeví vlnka db10.** Při nejvyšší úrovni šumu dosahuje nejlepších výsledků taktéž **vlnka db10.**

Obrázek 19 (b) znázorňuje MSE. Pro nejnižší úroveň šumu se jako nejvhodnější jeví vlnka coif5, nicméně zhruba od 4. úrovně zašumění je jak z tab. 3 i z obr. 19(b) patrné, že vlnka **db10 dosahuje nejnižší hodnoty MSE.**

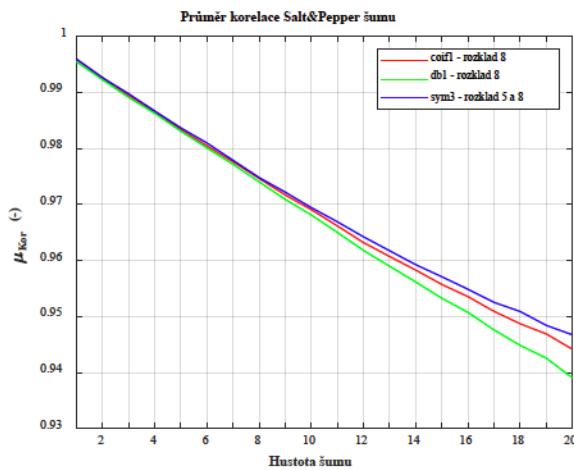
Obrázek 19 (c) znázorňuje SSIM. Při nejnižší úrovni šumu dosahuje největší hodnoty vlnka coif5 a pro střední a nejvyšší úroveň dosahuje nejlepších výsledků vlnka **sym8.**

Obrázek 19 (d) znázorňuje PSNR. Jako nejvhodnější se jeví vlnka **db10.**

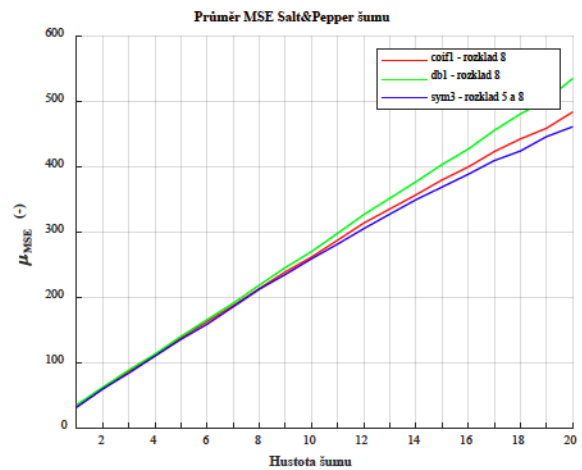
Nejméně vhodná vlnka

	Salt&Pepper šum; $\mu = 0.02$			Salt&Pepper šum; $\mu = 0.2$			Salt&Pepper šum; $\mu = 0.4$		
	<i>Korr</i>	<i>MSE</i>	<i>SSIM</i>	<i>Korr</i>	<i>MSE</i>	<i>SSIM</i>	<i>Korr</i>	<i>MSE</i>	<i>SSIM</i>
<i>db1 rozk. 8</i>	<b>0,9955</b>	<b>36,3510</b>	<b>0,9537</b>	<b>0,9681</b>	<b>270,8864</b>	<b>0,7591</b>	<b>0,9391</b>	<b>535,6234</b>	<b>0,5946</b>
<i>coif1 rozk. 8</i>	0,9959	33,0565	0,9592	0,9691	262,5506	0,7541	0,9442	484,3607	<b>0,5716</b>
<i>sym3 rozk. 8 (5)</i>	0,9960	32,7078	0,9606	0,9694	259,8529	<b>0,7522</b>	0,9467	461,7895	0,5722

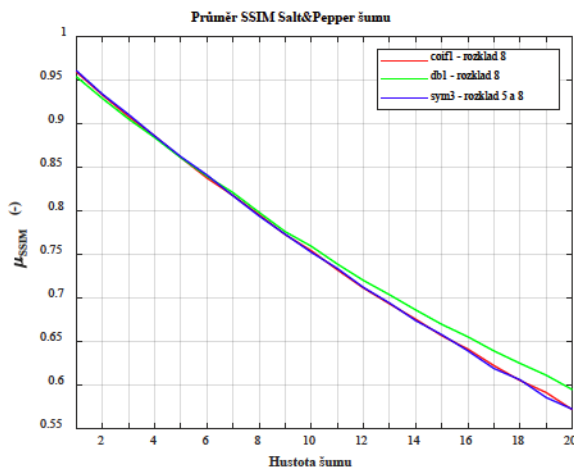
Tabulka 4: Hodnoty vybraných hodnotících metod znázorňující nejméně vhodnou vlnku pro šum Salt&Pepper



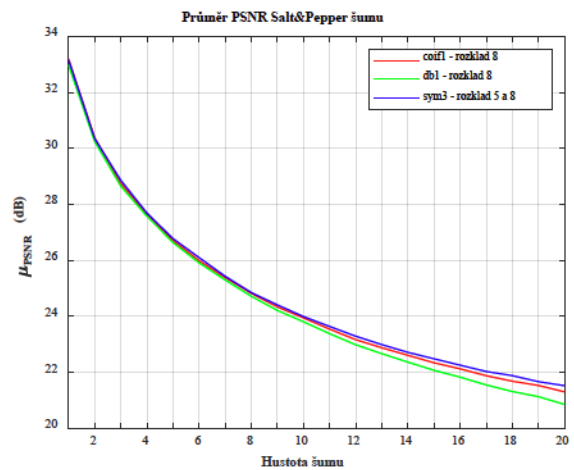
(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 20: Porovnání výsledných hodnot nejméně vhodných vlnek napříč rodinami pro šum Salt&Pepper.

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejméně vhodné pro filtrování Salt&Pepper šumu z CT obrazu. Na základě porovnání dat z Tab. 4 a průběhů z Obr. 20 je možné vybrat vlnku, která je pro v rámci CT datasetu nejméně vhodná pro filtraci šumu Salt&Pepper. Vlnka sym3 dosahovala při úrovni rozkladu 5 a 8 totožných hodnot. Proto byly do porovnání zařazeny obě tyto vlnky.

Obrázek 20 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Napříč celým spektrem dosahuje nejnižší korelace vlnka **db1**.

Obrázek 20 (b) znázorňuje MSE. Z tab. 4 i z obr. 20 lze vyvodit, že největší chyby dosahuje vlnka **db1**.

Obrázek 20 (c) znázorňuje SSIM. Pro nejnižší úroveň šumu dosahuje nejmenšího SSIM vlnka **db1** a pro střední a nejvyšší úroveň šumu jsou to vlnky **coif1** a **sym3**, jejich hodnoty kolísají. Celkově se nejhůře jeví vlnka **sym3**.

Obrázek 20 (d) znázorňuje PSNR. Trend všech vlnek je stejný. Nejmenších hodnot nabývá vlnka **db1**.

#### 5.1.4 Závěr pro dataset CT – Salt&Pepper šum

Jako celkově nejefektivnější se jeví vlnka db10 při rozkladu 3. Dosahuje sice nejnižších hodnot SSIM, ale z hlediska korelace, MSE a PSNR dosahuje výrazně nejlepších výsledků.

Jako nejméně efektivní se ukázala vlnka db1 o rozkladu 8 a to ve všech provedených hodnotících metodách mimo SSIM, kde dosahuje ve většině úrovní nejlepších výsledků.

Obrazové výsledky filtrace jsou zobrazeny na obrázcích níže.



(a) Originální snímek z datasetu CT



(b) Snímek z dat. CT, Salt&Pepper šum,  $d = 0,4$



c) Snímek filtrovaný vlnkou db1 o rozkladu 8



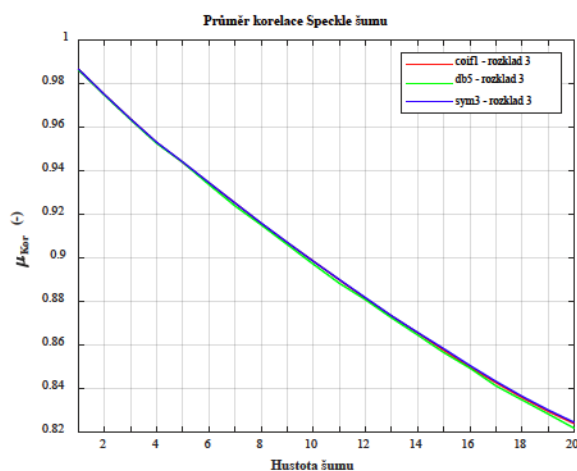
(d) Snímek filtrovaný vlnkou db10 o rozkladu 3

### 5.1.5 Šum Speckle

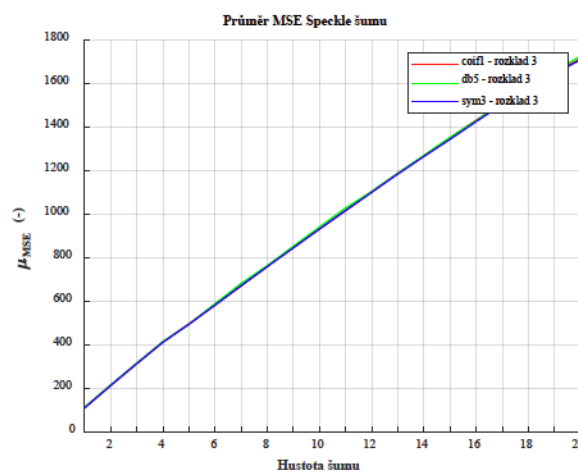
Nejvhodnější vlnka

	Speckle šum; $\mu = 0.02$			Speckle šum; $\mu = 0.2$			Speckle šum; $\mu = 0.4$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
db5 rozk. 3	0,9869	112,1050	0,8537	0,8984	935,6774	0,7225	0,8241	1715,0161	0,6828
sym3 rozk. 3	0,9868	112,6795	0,8530	0,8986	<b>933,9074</b>	0,7232	<b>0,8246</b>	<b>1710,4405</b>	0,6841
coif1 rozk. 3	0,9867	113,1281	0,8526	<b>0,8986</b>	934,1874	<b>0,7241</b>	0,8240	1714,8268	<b>0,6848</b>


Tabulka 5: Hodnoty vybraných hodnotících metod znázorňující nejvhodnější vlnku pro šum Speckle




(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 21: Porovnání výsledných hodnot nejvhodnějších vlnek napříč rodinami pro šum Speckle.

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejefektivnější pro filtrování Speckle šumu z CT obrazu. Na základě porovnání dat z Tab. 5 a průběhů z Obr. 21 je možné vybrat vlnku, která je pro v rámci CT datasetu nejvhodnější pro filtraci šumu Speckle.

Obrázek 21 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Pro nejnižší úroveň šumu se nejlépe jeví vlnka **db5**, pro střední úroveň vlnka **coif1** a pro nejvyšší úroveň vlnka **sym3**. Hodnoty korelace všech vlnek pro všechny úrovně zašumění se od sebe liší jen velice málo a každá z vlnek dosahuje nejvyšší korelace v jedné ze tří úrovní vyznačených v tab. 5. Na základě korelace tak nelze jednoznačně určit nejlepší vlnku.

Obrázek 21 (b) znázorňuje MSE. Při nejnižší úrovni zašumění dosahuje nejlepšího výsledku vlnka **db5**, pro střední a nejvyšší úroveň vlnka **sym3**. Obdobně jako u korelace jsou hodnoty všech vlnek velice podobné. Nejefektivněji se jeví vlnka **db5**.

Obrázek 21 (c) znázorňuje SSIM. Při nejnižší úrovni zašumění dosahuje nejlepšího výsledku vlnka **db5** a pro střední a nejvyšší úroveň vlnka **coif1**. **Nejefektivněji se jeví vlnka coif1.**


Obrázek 21 (d) znázorňuje PSNR. Trend všech vlnek je stejný a hodnoty jsou velice podobné. Nejlépe se jeví vlnka **sym3**.




Nejméně vhodná vlnka

	Speckle šum; $\mu = 0.02$			Speckle šum; $\mu = 0.2$			Speckle šum; $\mu = 0.4$		
	<i>Korr</i>	<i>MSE</i>	<i>SSIM</i>	<i>Korr</i>	<i>MSE</i>	<i>SSIM</i>	<i>Korr</i>	<i>MSE</i>	<i>SSIM</i>
<i>db1 rozk. 8</i>	<b>0,9865</b>	<b>115,4069</b>	<b>0,8468</b>	0,8972	942,7281	<b>0,7155</b>	0,8219	1728,2545	0,6762
<i>sym8 rozk. 8</i>	0,9869	111,9086	0,8533	0,8970	945,4629	0,7184	0,8219	1733,0262	0,6775
<i>coif5 rozk. 8</i>	0,9869	111,8237	0,8559	<b>0,8948</b>	<b>965,1178</b>	0,7180	<b>0,8175</b>	<b>1777,7196</b>	<b>0,6757</b>


Tabulka 6: Hodnoty vybraných hodnotících metod znázorňující nejméně vhodnou vlnku pro šum Speckle




(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 22: Porovnání výsledných hodnot nejméně vhodných vlnek napříč rodinami pro šum Speckle.

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejméně vhodná pro filtrování Speckle šumu z CT obrazu. Na základě porovnání dat z Tab. 6 a průběhů z Obr. 22 je možné vybrat vlnku, která je pro v rámci CT datasetu nejméně vhodná pro filtraci šumu Speckle.

Obrázek 22 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Při nejnižší úrovni šumu dosahuje nejmenší korelace vlnka db1, při střední a nejvyšší vlnka **coif5**.

Obrázek 22 (b) znázorňuje MSE. Při nejnižší úrovni šumu dosahuje největší chyby vlnka db1, při střední a nejvyšší vlnka **coif5**.

Obrázek 22 (c) znázorňuje SSIM. Při nejnižší a střední úrovni šumu dosahuje nejmenší SSIM vlnka db1 a při nejvyšší úrovni vlnka **coif5**.


Obrázek 22 (d) znázorňuje PSNR. Napříč celým spektrem dosahuje nejmenší hodnoty PSNR vlnka **coif5**.

### 5.1.6 Závěr pro dataset CT – Speckle šum

Na základě obr. 21 se jako celkově nejefektivnější se jeví vlnka **sym3 při rozkladu 3**. Na základě tab. 5 nelze snadno usoudit, která vlnka je nejefektivnější. Při blízkém prohlédnutí jednotlivých grafů z obr. 21 lze spatřit, že vlnka **sym3 při rozkladu 3** se v grafech jeví jako nejefektivnější.

Jako nejméně efektivní se ukázala vlnka **coif5 o rozkladu 8**. Ve všech grafech nabývá ve většině úrovní zašumění nejhorších hodnot.


Obrazové výsledky filtrace jsou zobrazeny na obrázcích níže.



(a) Originální snímek z datasetu CT



(b) Snímek z dat. CT, Speckle šum,  $d = 0,4$




c) Snímek filtrovaný vlnkou coif5 o rozkladu 8




(d) Snímek filtrovaný vlnkou sym3 při rozkladu

3

## 5.2 Výsledky pro dataset MRI



Obrázek 23: Stupně hustoty Gaussova šumu 0.01, 0.1 a 0.2, rozptyl 0.01 (zleva)



Obrázek 24: Stupně hustoty Salt&Pepper šumu 0.005, 0.05, 0,1 (zleva)



Obrázek 25: Stupně hustoty šumu Speckle 0.01, 0.1, 0.2 (zleva)

Na obrazová data byl aplikován šum ve dvaceti úrovních podle parametrů daného šumu. Pro Gaussovský šum byly těmito parametry rozptyl 0,01 a střední hodnota od 0,01 do 0,2 s krokem 0,01. U šumu Salt&Pepper je parametrem hustota (d) nastavená od 0,005 do 0,1 s krokem 0,005 a u šumu Speckle byla hustota (d) nastavená od 0,01 do 0,1 s krokem 0,01.


Nejnižší, střední a nejvyšší stupeň zašumění pro jednotlivé typy šumu znázorňují výše Obr. 23, Obr. 24 a Obr. 25.

## 5.2.1 Gaussovský šum


Nejvhodnější vlnka

	Gaussovský šum; $\mu = 0,01$			Gaussovský šum; $\mu = 0,1$			Gaussovský šum; $\mu = 0,2$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
<i>db5 rozk.3</i>	0,9650	351,5246	0,4370	0,9569	2789,4463	0,3140	0,9350	9933,3869	0,2268
<i>coif5 rozk. 3</i>	<b>0,9670</b>	<b>309,1810</b>	<b>0,4505</b>	<b>0,9630</b>	<b>953,7744</b>	<b>0,3774</b>	<b>0,9587</b>	<b>2777,7954</b>	<b>0,3178</b>
<i>sym8 rozk. 3</i>	0,9660	343,4273	0,4394	0,9579	2780,3197	0,3164	0,9361	9928,1389	0,2284


Tabulka 7: Hodnoty vybraných hodnotících metod znázorňující nejvhodnější vlnku pro Gaussovský šum




(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 26: Porovnání výsledných hodnot nejvhodnějších vlnek napříč rodinami pro Gaussovský šum

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejefektivnější pro filtrování Gaussova šumu z MRI obrazu. Na základě porovnání dat z Tab. 7 a průběhů z Obr. 26 je možné vybrat vlnku, která je pro v rámci MRI datasetu nejvhodnější pro filtraci Gaussova šumu.

Obrázek 26 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Z hlediska korelace je jasně nejlepší volbou vlnka **coif5**, která nejenže v celém spektru dosahuje nejvyšších hodnot, ale zároveň není oproti ostatním vlnkám tak náchylná ke zhoršování efektivity filtrace v závislosti na stupni šumu.

Obrázek 26 (b) znázorňuje MSE. Z grafu na obrázku i z tab 7 lze jednoznačně vypožorovat, že vlnka **coif5** dosahuje oproti ostatním vlnkám méně než třetinové hodnoty MSE.


Obrázek 26 (c) znázorňuje SSIM. Napříč celým spekrem dosahuje nejlepší hodnoty vlnka **coif5**.

Obrázek 26 (d) znázorňuje PSNR. Napříč celým spekrem dosahuje nejlepší hodnoty vlnka **coif5**.


Nejméně vhodná vlnka

	Gaussovský šum; $\mu = 0,01$			Gaussovský šum; $\mu = 0,1$			Gaussovský šum; $\mu = 0,2$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
<i>db1 rozk. 5</i>	<b>0,954</b>	<b>459,779</b>	<b>0,390</b>	<b>0,941</b>	<b>2951,747</b>	<b>0,274</b>	<b>0,916</b>	<b>10144,177</b>	<b>0,198</b>
<i>coif1 rozk. 5</i>	0,959	387,053	0,416	0,952	1045,312	0,345	0,947	2873,427	0,290
<i>sym3 rozk. 8</i>	0,960	405,818	0,416	0,949	2822,345	0,299	0,925	9966,046	0,213


Tabulka 8: Hodnoty vybraných hodnotících metod znázorňující nejméně vhodnou vlnku pro Gaussovský šum




(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 27: Porovnání výsledných hodnot nejméně vhodných vlnků napříč rodinami pro Gaussovský šum

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejméně efektivní pro filtrování Gaussova šumu z MRI obrazu. Na základě porovnání dat z Tab. 8 a průběhů z Obr. 27 je možné vybrat vlnku, která je pro v rámci MRI datasetu nejméně vhodná pro filtraci Gaussova šumu.

Obrázek 27 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Jasně nejhorší úrovně korelace dosahuje vlnka **db1**.

Obrázek 27 (b) znázorňuje MSE. Nejvyšší hodnoty dosahuje vlnka **db1**.

Obrázek 27 (c) znázorňuje SSIM. Nejmenší hodnoty dosahuje vlnka **db1**.

Obrázek 27 (d) znázorňuje PSNR. Nejmenší hodnoty PSNR dosahuje vlnka **db1**.



### 5.2.2 Závěr pro dataset MRI – Gaussovský šum


Na základě Obr. 26 a Tab. 7 se jako celkově nejefektivnější se jeví vlnka **coif5** při rozkladu 3.. Svými objektivními výsledky významně převyšuje ve všech parametrech ostatní vlnky.

Jako **nejméně efektivní se ukázala vlnka db1** o rozkladu 5. Ve všech grafech z Obr. 27 i v Tab. 8 nabývá ve všech případech nejhorsích výsledků.

Obrazové výsledky filtrace jsou zobrazeny na obrázcích níže.



(a) Originální snímek z datasetu MRI



(b) Snímek z dat. MRI, Gauss šum,

$$\sigma^2 = 0.01, \mu = 0.2$$



(c) Snímek filtrovaný vlnkou db1 o rozkladu 5





(d) Snímek filtrovaný vlnkou coif5 při rozkladu 3

### 5.2.3 Šum Salt&Pepper

Nejvhodnější vlnka



	Šum Salt&Pepper; $d = 0,005$			Šum Salt&Pepper; $d = 0,05$			Šum Salt&Pepper; $d = 0,1$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
<b>db10 rozk. 3</b>	0,9829	135,3765	0,7322	<b>0,9470</b>	472,4058	<b>0,4054</b>	0,9262	790,8713	0,3216
<b>coif5 rozk. 3</b>	<b>0,9857</b>	<b>112,7082</b>	<b>0,8226</b>	0,9447	<b>445,7945</b>	0,4041	<b>0,9429</b>	<b>526,1269</b>	<b>0,3517</b>
<b>sym8 rozk. 3</b>	0,9789	166,2572	0,7708	0,9392	517,3847	0,3458	0,9315	755,9598	0,3302

Tabulka 9: Hodnoty vybraných hodnotících metod znázorňující nejvhodnější vlnku šum Salt&Pepper



(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.

(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.

(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 28: Porovnání výsledných hodnot nejvhodnějších vlnek napříč rodinami pro šum Salt&Pepper

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejefektivnější pro filtrování Salt&Pepper šumu z MRI obrazu. Na základě porovnání dat z Tab. 9a průběhů z Obr. 28 je možné vybrat vlnku, která je pro v rámci MRI datasetu nejvhodnější pro filtraci šumu Salt&Pepper.

Obrázek 28 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Pro první dvě úrovně zašumění se nejlépe jeví vlnka **coif5**. Od 2. do 11. úrovně největší efektivitu vykazuje vlnka **db10** a od 11. úrovně do 20. má nejlepší výsledky vlnka **coif5**.

Obrázek 28 (b) znázorňuje MSE. Pro první dvě úrovně zašumění se nejlépe jeví vlnka **coif5**. Od 2. do 11. úrovně největší efektivitu vykazuje vlnka **db10** a od 9. úrovně do 20. má nejlepší výsledky vlnka **coif5**.


Obrázek 28 (c) znázorňuje SSIM. Z obrázku lze vyčíst, že celkově nejlepší efektivitu dosahuje vlnka **coif5**. Vlnka **db10** má od 9. úrovně do 12. úrovně oproti vlnce **coif5** lehce vyšší efektivitu.

Obrázek 28 (d) znázorňuje PSNR. Pro první dvě úrovně zašumění se nejlépe jeví vlnka **coif5**. Od 2. do 11. úrovně největší efektivitu vykazuje vlnka **db10** a od 11. úrovně do 20. má nejlepší výsledky vlnka **coif5**.


Nejméně vhodná vlnka

	Šum Salt&Pepper; $d = 0,005$			Šum Salt&Pepper; $d = 0,05$			Šum Salt&Pepper; $d = 0,1$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
<b>db1 rozk. 8</b>	<b>0,9752</b>	<b>195,5674</b>	<b>0,7732</b>	<b>0,8215</b>	<b>1587,5969</b>	<b>0,2620</b>	<b>0,7230</b>	<b>2581,0976</b>	<b>0,1608</b>
coif1 rozk. 8	0,9844	122,6994	0,8226	0,9134	685,7555	0,3545	0,9056	784,5221	0,2554
<b>sym3 rozk. 8</b>	<b>0,9779</b>	<b>173,6757</b>	<b>0,7672</b>	<b>0,9267</b>	<b>611,4484</b>	<b>0,3028</b>	<b>0,9156</b>	<b>933,7510</b>	<b>0,2957</b>


Tabulka 10: Hodnoty vybraných hodnotících metod znázorňující nejméně vhodnou vlnku pro šum Salt&Pepper




(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 29: Porovnání výsledných hodnot nejméně vhodných vlnek napříč rodinami pro šum Salt&Pepper

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejméně efektivní pro filtrování Salt&Pepper šumu z MRI obrazu. Na základě porovnání dat z Tab. 10 a průběhů z Obr. 29 je možné vybrat vlnku, která je pro v rámci MRI datasetu nejméně vhodná pro filtraci šumu Salt&Pepper.

Obrázek 29 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Z obrázku je jasně patrné, že svým průběhem i hodnotami je nejhorší vlnka **db1**, jejich efektivita strmě klesá se zvyšující se úrovní šumu.

Obrázek 29 (b) znázorňuje MSE. Nejvyšší chyby dosahuje vlnka **db1**. Její hodnota při nejvyšším stupni šumu je více než 2,7násobná oproti vlnce sym3.

Obrázek 29 (c) znázorňuje SSIM. Do úrovně šumu 6 se jako nejméně efektivní jeví vlnka sym3. Od této úrovně její místo přebírá vlnka **db1**

Obrázek 29 (d) znázorňuje PSNR. Nejmenších hodnot napříč spektrem jasně dosahuje vlnka **db1**.

## 5.2.4 Závěr pro dataset MRI – Šum Salt&pepper


Na základě Obr. 28 ani Tab. 9 nelze jednoznačně usoudit, která vlnka je nejlepší. Lze říci, že pro první dvě úrovně šumu se jako nejefektivnější jeví vlnka **coif5** při rozkladu 3, od úrovně 2 do úrovně 11 je nejlepší volbou vlnka **db10** při rozkladu 3 a od úrovně 11 do úrovně 20 se nejefektivněji opět jeví vlnka **coif5** při rozkladu 3.

Jako nejméně efektivní se jednoznačně jeví vlnka **db1** o rozkladu 8. Mimo SSIM pro prvních 7 úrovní šumu nabývá pro všechny parametry nejnižších hodnot.


Obrazové výsledky filtrace jsou zobrazeny na obrázcích níže.



(a) Originální snímek z datasetu MRI



(b) Snímek z dat. MRI, šum Salt&Pepper,  $d = 0,1$



(c) Snímek filtrovaný vlnkou db1 o rozkladu 8





(d) Snímek filtrovaný vlnkou coif5 při rozkladu 3

## 5.2.5 Šum speckle

Nejvhodnější vlnka



	Speckle šum; $d = 0,01$			Speckle šum; $d = 0,1$			Speckle šum; $d = 0,2$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
db10 rozk. 3	0,9709	235,9924	0,7600	0,8664	1007,8560	0,5946	0,8403	1170,5728	0,5579
coif5 rozk.3	<b>0,9943</b>	<b>46,4257</b>	<b>0,8845</b>	<b>0,9704</b>	<b>237,8844</b>	<b>0,7707</b>	<b>0,9478</b>	<b>413,5999</b>	<b>0,7195</b>
sym8 rozk. 3	0,9701	239,7911	0,7710	0,8577	1060,3074	0,6027	0,8307	1228,3993	0,5639

Tabulka 11: Hodnoty vybraných hodnotících metod znázorňující nejvhodnější vlnku pro šum Speckle



(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.

(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.

(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 30: Porovnání výsledných hodnot nejvhodnějších vlnek napříč rodinami pro šum Speckle

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejefektivnější pro filtrování Speckle šumu z MRI obrazu. Na základě porovnání dat z Tab. 11 a průběhů z Obr. 30 je možné vybrat vlnku, která je pro v rámci MRI datasetu nejvhodnější pro filtraci šumu Speckle.

Obrázek 30 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Jasně **nejlepší korelace v celém spektru zašumění dosahuje vlnka coif5.**

Obrázek 30 (b) znázorňuje MSE. Nejnižší chyby dosahuje, obdobně jako v případě korelace, vlnka **coif5.**

Obrázek 30 (c) znázorňuje SSIM. Daleko nejlepších hodnot SSIM nabývá vlnka **coif5.**



Obrázek 30 (d) znázorňuje PSNR. Obdobně jako u ostatních parametrů se jako nejefektivnější jeví vlnka **coif5.**



Nejméně vhodná vlnka



	Speckle šum; $d = 0,01$			Speckle šum; $d = 0,1$			Speckle šum; $d = 0,2$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
db1 rozk. 8	0,9658	277,6439	0,7196	0,8313	1236,1497	0,5118	0,7924	1473,5912	0,4536
coif1 rozk. 8	0,9937	52,4673	0,8665	0,9682	260,4526	0,7367	0,9440	450,9346	0,6765
sym8 rozk. 8	0,9690	253,8402	0,7353	0,8464	1144,1185	0,5300	0,8149	1337,0569	0,4798

Tabulka 12: Hodnoty vybraných hodnotících metod znázorňující nejméně vhodnou vlnku pro šum Speckle



(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.

(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.

(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 31: Porovnání výsledných hodnot nejméně vhodných vlnků napříč rodinami pro šum Speckle

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejméně efektivní pro filtrování Speckle šumu z MRI obrazu. Na základě porovnání dat z Tab. 12 a průběhů z Obr. 31 je možné vybrat vlnku, která je pro v rámci MRI datasetu nejméně vhodná pro filtraci šumu Speckle.

Obrázek 31 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Nejmenších hodnot korelace nabývá vlnka **db1**.

Obrázek 31 (b) znázorňuje MSE. V celém spektru dosahuje nejvyšší chyby vlnka **db1**.

Obrázek 31 (c) znázorňuje SSIM. Stejně jako u ostatních parametrů se jako nejméně efektivní jeví vlnka **db1**.

Obrázek 31 (d) znázorňuje PSNR. I u něj nejmenší efektivitu dosahuje vlnka **db1**.

## 5.2.6 Závěr pro dataset MRI – Šum Speckle

Na základě obr. Obr. 30 a Tab. 11 lze jednoznačně usoudit, že nejefektivnější vlnkou je **coif1 při rozkladu 8**. Ve všech parametrech má velice významný náskok oproti jiným vlnkám. S rostoucím stupněm zašumění klesá efektivita filtrace.

**Jako nejméně efektivní se jednoznačně jeví vlnka db1 o rozkladu 8**, která se nejhůře jeví ve všech testovaných parametrech.


Obrazové výsledky filtrace jsou zobrazeny na obrázcích níže.



(a) Originální snímek z datasetu MRI



(b) Snímek z dat. MRI, šum Speckle,  $d = 0,2$




(c) Snímek filtrovaný vlnkou db1 o rozkladu 8




(d) Snímek filtrovaný vlnkou coif1 o rozkladu 8


### 5.3 Výsledky pro dataset RS



Obrázek 32: Stupně hustoty Gaussova šumu 0.001, 0.01, 0.02, rozptyl 0.1 (zleva)



Obrázek 33: Stupně hustoty Salt&Pepper šumu 0.005, 0.05, 0.1 (zleva)



Obrázek 34: Stupně hustoty šumu Speckle 0.01, 0.1, 0.2 (zleva)

Na obrazová data byl aplikován šum ve dvaceti úrovních podle parametrů daného šumu. Pro Gaussovský šum byly těmito parametry rozptyl 0,01 a střední hodnota 0,001 do 0,02 s krokem 0,001. U šumu Salt&Pepper je parametrem hustota ( $d$ ) nastavená od 0,005 do 0,1 s krokem 0,005 a u šumu Speckle byla hustota ( $d$ ) nastavená od 0,01 do 0,2 s krokem 0,01.


Nejnižší, střední a nejvyšší stupeň zašumění pro jednotlivé typy šumu znázorňují obrázky Obr. 32, Obr. 33 a Obr. 34.

### 5.3.1 Gaussovský šum


Nejvhodnější vlnka

	Gaussovský šum; $\mu = 0,001$			Gaussovský šum; $\mu = 0,01$			Gaussovský šum; $\mu = 0,02$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
db10 rozk. 3	<b>0,9548</b>	<b>21,0689</b>	<b>0,8890</b>	<b>0,9548</b>	<b>27,5060</b>	<b>0,8889</b>	<b>0,9547</b>	<b>46,8079</b>	<b>0,8879</b>
coif5 rozk. 3	0,9547	21,1223	0,8887	0,9547	27,5346	0,8885	0,9547	47,0796	0,8878
sym8. rozk. 3	0,9547	21,1132	0,8885	0,9547	27,5634	0,8883	<b>0,9547</b>	47,0696	0,8874


Tabulka 13: Hodnoty vybraných hodnotících metod znázorňující nejvhodnější vhodnou vlnku pro Gaussovský šum




(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 35: : Porovnání výsledných hodnot nejvhodnějších vlnek napříč rodinami pro Gaussovský šum

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejefektivnější pro filtrování Gaussova šumu z RS obrazu. Na základě porovnání dat z Tab. 13 a průběhů z Obr. 35 je možné vybrat vlnku, která je pro v rámci RS datasetu nejvhodnější pro filtraci Gaussova šumu.

Obrázek 35 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Jak lze vidět na obr. 32, hodnoty korelace u všech vlnek velmi kolísají a bylo by tak velice složité z něj určit, která vlnka dosahuje nejlepších výsledků. Objektivně má však při nejnižší a střední úrovni šumu nejlepší výsledky vlnka **db10**. Při nejvyšší úrovni má nejlepší výsledek vlnka sym8, ale rozdíl hodnot je velice malý.

Obrázek 35 (b) znázorňuje MSE. Nejnižší MSE dosahuje v celém spektru zašumění vlnka **db10**. Na rozdíl od korelace mají všechny vlnky stejný trend růstu.


Obrázek 35 (c) znázorňuje SSIM. Obdobně jako u korelace jsou hodnoty SSIM velmi kolísavé, ale nejlépe se jeví vlnka **db10**.

Obrázek 35 (d) znázorňuje PSNR. Čím vyšší je úroveň šumu, tím více hodnoty PSNR klesají. Nejefektivněji se jeví vlnka **db10**.


Nejméně vhodná vlnka

	Gaussovský šum; $\mu = 0,001$			Gaussovský šum; $\mu = 0,01$			Gaussovský šum; $\mu = 0,02$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
db1 rozk. 8	<b>0,9255</b>	<b>36,2277</b>	<b>0,8881</b>	<b>0,9254</b>	<b>42,6451</b>	<b>0,8879</b>	<b>0,9253</b>	<b>61,8942</b>	<b>0,8871</b>
coif1. rozk. 8	0,9370	30,0347	0,9005	0,9371	36,5657	0,9002	0,9375	55,9864	0,8995
sym3 rozk. 8	0,9391	29,4225	0,9017	0,9392	36,0891	0,9014	0,9391	55,7207	0,9006


Tabulka 14: Hodnoty vybraných hodnotících metod znázorňující nejméně vhodnou vlnku pro Gaussovský šum




(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 36: Porovnání výsledných hodnot nejméně vhodných vlnků napříč rodinami pro Gaussovský šum

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejméně vhodná pro filtrování Gaussova šumu z RS obrazu. Na základě porovnání dat z Tab. 14 a průběhů z Obr. 36 je možné vybrat vlnku, která je pro v rámci RS datasetu nejméně efektivní pro filtraci Gaussova šumu.

Obrázek 36 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Jednoznačně nejhůř se jeví vlnka **db1** a to v celém spektru zašumění.

Obrázek 36 (b) znázorňuje MSE. Nejnížší efektivitu dosahuje vlnka **db1**, a to v celém spektru zašumění.

Obrázek 36 (c) znázorňuje SSIM. Nejvyšší střední kvadratické chyby dosahuje vlnka **db1** a to v celém spektru zašumění.


Obrázek 36 (d) znázorňuje PSNR. Nejnižších hodnot nabývá vlnka **db1** a to v celém spektru zašumění.




### 5.3.2 Závěr pro dataset RS – Gaussovský šum

Na základě Obr. 35 (a) nelze vůli velkým výchytkám jednoznačně usoudit, která vlnka je nejlepší, ale **nejmenších výkyvů a největší stability dosahuje vlnka db10 při rozkladu 3**. Taktéž dosahuje nejlepších výsledků z hlediska PSNR, SSIM i MSE. S rostoucím stupněm zašumění klesá efektivita filtrace.


**Jako nejméně efektivní se jednoznačně jeví vlnka db1 o rozkladu 8**, která se nejhůře jeví ve všech testovaných parametrech.




(a) Originální snímek z datasetu RS



(b) Snímek z dat. RS, Gauss. šum,  
 $\sigma^2 = 0.01$ ,  $\mu = 0.02$



c) Snímek filtrovaný vlnkou db1 o rozkladu 8




(d) Snímek filtrovaný vlnkou db10 o rozkladu 3

### 5.3.3 Šum Salt&Pepper


Nejvhodnější vlnka

	Šum Salt&Pepper; $d = 0,005$			Šum Salt&Pepper; $d = 0,05$			Šum Salt&Pepper; $d = 0,1$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
db10 rozk. 5	<b>0,9030</b>	<b>49,6879</b>	<b>0,8071</b>	<b>0,9479</b>	<b>25,5719</b>	<b>0,8823</b>	<b>0,9442</b>	<b>32,6152</b>	<b>0,8997</b>
coif5 rozk. 5	0,8798	65,0177	0,8052	0,8076	105,5737	0,5384	0,9415	33,1132	0,8802
sym8 rozk. 5	0,8770	67,0226	0,8061	0,7857	123,3261	0,5022	0,9395	34,0953	0,8755


Tabulka 15: Hodnoty vybraných hodnotících metod znázorňující nejvhodnější vlnku pro šum Salt&Pepper




(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 37: Porovnání výsledných hodnot nejvhodnějších vlnek napříč rodinami pro šum Salt&Pepper

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejefektivnější pro filtrování Salt&Pepper šumu z RS obrazu. Na základě porovnání dat z Tab. 15 a průběhů z Obr. 37 je možné vybrat vlnku, která je pro v rámci RS datasetu nejvhodnější pro filtraci šumu Salt&Pepper.

Obrázek 37 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Největších hodnot nabývá vlnka **db10**. Trend křivky ukazuje, že použitím této vlnky se korelace zvyšuje. Maximální hodnoty dosahuje okolo 10. úrovně zašumění a poté jen velice málo klesá.

Obrázek 37 (b) znázorňuje MSE. Nejlépe se jeví vlnka **db10**. Z počátku se až do 2. úrovně chyba zvyšuje, od této úrovně klesá, okolo úrovně 9 je v minimu a poté velice pomalu roste.

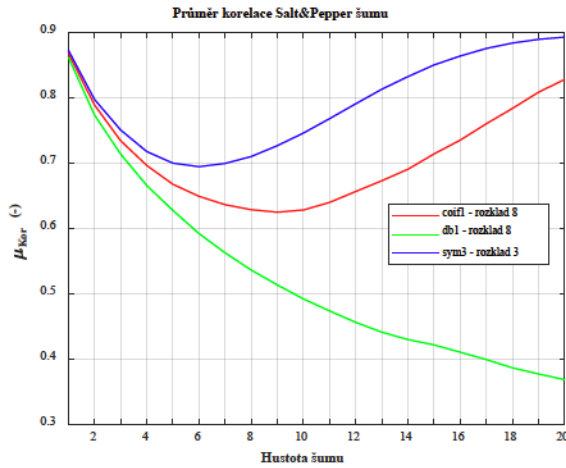
Obrázek 37 (c) znázorňuje SSIM. Křivka je obdobného trendu, jako korelace. Nejlépe se jeví vlnka **db10**. Do druhé úrovně klesá a od této úrovně se neustále zvyšuje. Čím je hladina šumu vyšší, tím je SSIM vyšší.

Obrázek 37 (d) znázorňuje PSNR. Křivka je obdobného trendu, jako korelace a SSIM. Nejlépe se jeví vlnka **db10**. Do druhé úrovně klesá, od této úrovně roste do úrovně 9 a poté lehce klesá. Čím je hladina šumu vyšší, tím je SSIM vyšší.


Nejméně vhodná vlnka

	Šum Salt&Pepper; $d = 0,005$			Šum Salt&Pepper; $d = 0,05$			Šum Salt&Pepper; $d = 0,1$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
db1 rozk. 8	<b>0,8624</b>	<b>77,5054</b>	0,8079	<b>0,4926</b>	<b>717,1635</b>	<b>0,2043</b>	<b>0,3691</b>	<b>1344,11</b>	<b>0,0835</b>
coif1 rozk. 8	0,8684	72,6646	<b>0,8050</b>	0,6287	311,6373	0,3148	0,8284	82,6239	0,6473
sym3 rozk. 3	0,8731	70,4051	0,8066	0,7464	167,9289	0,4384	0,8931	53,7613	0,7849


Tabulka 16: Hodnoty vybraných hodnotících metod znázorňující nejméně vhodnou vlnku pro šum Salt&Pepper




(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 38: Porovnání výsledných hodnot nejméně vhodných vlnek napříč rodinami pro šum Salt&Pepper

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejméně efektivní pro filtrování Salt&Pepper šumu z RS obrazu. Na základě porovnání dat z Tab. 16 a průběhů z Obr. 38 je možné vybrat vlnku, která je pro v rámci RS datasetu Nejméně vhodná pro filtraci šumu Salt&Pepper.

Obrázek 38 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Největších hodnot nabývá vlnka **db10**. Trend křivky ukazuje, že použitím této vlnky se korelace zvyšuje. Maximální hodnoty dosahuje okolo 10. úrovně zašumění a poté jen velice málo klesá.

Obrázek 38 (b) znázorňuje MSE. Nejlépe se jeví vlnka **db10**. Z počátku se až do 2. úrovně chyba zvyšuje, od této úrovně klesá, okolo úrovně 9 je v minimu a poté velice pomalu roste.

Obrázek 38 (c) znázorňuje SSIM. Křivka je obdobného trendu, jako korelace. Nejlépe se jeví vlnka **db10**. Do druhé úrovně klesá a od této úrovně se neustále zvyšuje. Čím je hladina šumu vyšší, tím je SSIM vyšší.


Obrázek 38 (d) znázorňuje PSNR. Křivka je obdobného trendu, jako korelace a SSIM. Nejlépe se jeví vlnka **db10**. Do druhé úrovně klesá, od této úrovně roste do úrovně 9 a poté lehce klesá. Čím je hladina šumu vyšší, tím je SSIM vyšší.

### 5.3.4 Závěr pro dataset RS – Salt&Pepper šum


**Jako nejefektivnější se jeví vlnka db10 při rozkladu 5**, která dosahuje nejlepších hodnot ve všech objektivních parametrech. S rostoucím stupněm zašumění se efektivita filtrace zvyšuje.

**Jako nejméně efektivní se jednoznačně jeví vlnka db1 o rozkladu 8**, která se nejhůře jeví ve všech testovaných parametrech a na rozdíl od ostatních vlnek má ryze sestupný trend.


Na obrázcích níže lze jasně vidět, že WT filtrace je v případě RS obrazů neefektivní. Dojde sice k filtraci šumu, ale tato filtrace je za cenu tak vysokého rozostření obrazu, že informace v obrazu obsažené jsou naprosto ztracené.




(a) Originální snímek z datasetu RS



(b) Snímek z dat. RS, šum Salt&Pepper,  $d = 0,1$



(c) Snímek filtrovaný vlnkou db1 o rozkladu 8





(d) Snímek filtrovaný vlnkou db10 o rozkladu 5

### 5.3.5 Šum Speckle

Nejvhodnější vlnka



	Speckle šum; $d = 0,01$			Speckle šum; $d = 0,1$			Speckle šum; $d = 0,2$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
db10 rozk. 5	0,9632	16,9536	0,9091	0,9451	25,9093	0,9008	0,9368	30,7164	0,8998
<b>coif5 rozk. 5</b>	<b>0,9647</b>	<b>16,2249</b>	<b>0,9104</b>	<b>0,9460</b>	<b>25,5463</b>	<b>0,9010</b>	<b>0,9373</b>	<b>30,6534</b>	<b>0,9000</b>
sym8 rozk. 5	0,9645	16,3811	0,9102	0,9455	25,8665	0,9009	0,9366	30,8147	0,8999

Tabulka 17: Hodnoty vybraných hodnotících metod znázorňující nejvhodnější vlnku pro šum Speckle



(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.

(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.

(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 39: Porovnání výsledných hodnot nejvhodnějších vlnek napříč rodinami pro šum Speckle

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejefektivnější pro filtrování Speckle šumu z RS obrazu. Na základě porovnání dat z Tab. 17 průběhů z Obr. 39 je možné vybrat vlnku, která je pro v rámci RS datasetu nejvhodnější pro filtraci šumu Speckle.

Obrázek 39 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. V celém spektru se nejlépe jeví vlnka **coif5**. Čím vyšší je úroveň šumu, tím nižší je efektivita filtrace.

Obrázek 39 (b) znázorňuje MSE. V celém spektru se nejlépe jeví vlnka **coif5**. Se zvyšující se úrovní šumu MSE roste.

Obrázek 39 (c) znázorňuje SSIM. V celém spektru se nejlépe jeví vlnka **coif5**. Čím vyšší je úroveň šumu, tím nižší je efektivita filtrace.


Obrázek 39 (d) znázorňuje PSNR. V celém spektru se nejlépe jeví vlnka **coif5**. Čím vyšší je úroveň šumu, tím nižší je efektivita filtrace.




### Nejméně vhodná vlnka

	Speckle šum; $d = 0,01$			Speckle šum; $d = 0,1$			Speckle šum; $d = 0,2$		
	Korr	MSE	SSIM	Korr	MSE	SSIM	Korr	MSE	SSIM
<i>db1 rozk. 3</i>	<b>0,9664</b>	<b>15,6882</b>	0,8926	<b>0,9195</b>	<b>38,3060</b>	0,8178	<b>0,8716</b>	<b>63,0630</b>	<b>0,7629</b>
<i>coif1 rozk. 3</i>	0,9716	13,1464	0,9076	0,9255	35,4851	0,8443	0,8772	60,6346	0,7922
<i>sym3 rozk.3</i>	0,9728	12,6022	<b>0,8065</b>	0,9265	34,9704	<b>0,4404</b>	0,8790	59,8087	0,8327


Tabulka 18: Hodnoty hodnotících metod znázorňující nejméně vhodnou vlnku pro šum Speckle




(a) Grafické zobrazení průměru korelace mezi původním obrazem a filtrovaným obrazem.



(b) Grafické zobrazení průměru MSE mezi původním obrazem a filtrovaným obrazem.



(c) Grafické zobrazení průměru SSIM mezi původním obrazem a filtrovaným obrazem.



(d) Grafické zobrazení průměru PSNR mezi původním obrazem a filtrovaným obrazem.

Obrázek 40: Porovnání výsledných hodnot nejméně vhodných vlnků napříč rodinami pro šum Speckle

Vybrány byly vlnky, které se v rámci svých rodin jeví jako nejméně efektivní pro filtrování Speckle šumu z RS obrazu. Na základě porovnání dat z Tab. 18 a průběhů z Obr. 40 je možné vybrat vlnku, která je pro v rámci RS datasetu nejméně vhodná pro filtraci šumu Speckle.

Obrázek 40 (a) znázorňuje průběh korelace mezi referenčním a vyfiltrovaným obrazem. Jako nejméně efektivní se v celém spektru jeví vlnka **db1**.

Obrázek 40 (b) znázorňuje MSE. Nejvyšší střední kvadratické chyby nabývá vlnka **db1** v celém průběhu křivky.

Obrázek 40 (c) znázorňuje SSIM. Nejhůře se jeví vlnka **sym3**, která má nejnižší hodnotu SSIM už při první úrovni šumu a poté následuje až do úrovně 8 strmý propad. Od této úrovně křivka roste a v posledních dvou úrovních nabývá nejvyšší hodnoty. I přes to zle ale objektivně usoudit, že je vlnka **sym3** nejméně efektivní.


Obrázek 40 (d) znázorňuje PSNR. Z hlediska PSNR se nejhůře jeví opět vlnka **db1**. Všechny křivky mají stejný trend.

### 5.3.6 Závěr pro dataset RS – Speckle šum


Jako nejefektivnější se jeví vlnka **coif5** při rozkladu **5**, která dosahuje nejlepších výsledků v každém z parametrů. Se zvyšující se úrovní šumu klesá efektivita filtrace.

Podle Obr. 39 tato vlnka nedosahuje jasně nejlepších výsledků, ale vlnka **sym3** o rozkladu **3**, která se ve všech parametrech, mimo SSIM, jeví jako nejlepší, má v průběhu hodnot SSIM signifikantní propad. Z toho důvodu je jako **nejvhodnější vlnka vybrána coif5** při rozkladu **5**, která dosahuje **konzistentnějších výsledků**.


Jako nejméně efektivní se jeví vlnka **db1** o rozkladu **3**. Podle Obr. 40 tato vlnka dosahuje nejhorších výsledků mimo parametr SSIM, kde je nejhorší vlnka **sym3** o rozkladu **3**, která má v průběhu hodnot SSIM signifikantní propad. Proto nakonec soudím, že **pro prvních 18 úrovní je nejméně efektivní vlnou sym3** o rozkladu **3** a **pro zbývající dvě úrovně je nejméně efektivní vlnka db1** o rozkladu **3**.




(a) Originální snímek z datasetu RS



(b) Snímek z dat. RS, Gauss. šum,  $d = 0,2$



(c) Snímek filtrovaný vlnkou **db1** o rozkladu **3**



(d) Snímek filtrovaný vlnkou **coif5** o rozkladu **5**

## 5.4 Závěrečné hodnocení praktické části I.

Přehled nejefektivnějších vlnek			
	Dataset CT	Dataset MRI	Dataset RS
Gaussovský šum	sym8 rozklad 3	coif5 rozklad 3	db10 rozklad 3
Šum Salt&Pepper	db10 rozklad 3	db10 rozklad 3	db10 rozklad 5
Šum Speckle	sym3 rozklad 3	coif1 rozklad 8	coif5 rozklad 5
Přehled nejméně efektivních vlnek			
	Dataset CT	Dataset MRI	Dataset RS
Gaussovský šum	db1 rozklad 5	db1 rozklad 5	db1 rozklad 8
Šum Salt&Pepper	db1 rozklad 8	db1 rozklad 8	db1 rozklad 8
Šum Speckle	coif5 rozklad 8	db1 rozklad 8	sym3 rozklad 3

Tab. 1: Závěrečný přehled

Jak lze vidět v Tab. výše, z výsledků práce nelze vyvodit univerzální vlnku, která by byla napříč všemi datasey jedinou správnou volbou.

V případě CT datasetu se při filtraci různých typů šumu nejvíce osvědčila jiná rodina vlnek. Rodina Symlets se osvědčila při filtraci Gaussova šumu, rodina Daubechies u šumu Salt&Pepper a rodina Symlets u šumu Speckle. Z hlediska úrovně rozkladu se jako nejoptimálnější jeví rozklad 3 při filtrování Gaussova šumu. Nejméně efektivní vlnky jsou většinou z rodiny Daubechies, konkrétně db1. Tento výsledek není příliš překvapující, neboť vlnka db1, neboli Haarova vlnka, je charakterizována svým „obdélíkovým“ průběhem, který negativně ovlivňuje vlnkové koeficienty ve scalogramu. Jako nejméně efektivní úroveň rozkladu se jeví rozklady 8, nebo 5 v případě Gaussova šumu. Pro šum Speckle je nejméně efektivní vlnkou coif5.

U datasetu MRI je patrné, že ani u tohoto datasetu nelze označit pouze jednu rodinu za nejvhodnější. U Gaussova a Speckle šumu se nejvíce osvědčila rodina Coiflets a u šumu Salt&Pepper rodina Daubechies. U Gaussova a Salt&Pepper se nejvíce osvědčil rozklad 3, zatímco u šumu Speckle rozklad 8. Jako nejméně efektivní se jednoznačně ukázala vlnka z rodiny Daubechies a to konkrétně db1. U Gaussova šumu byl nejhorším rozkladem rozklad 5 a u ostatních šumů rozklad 8.

U datasetu RS byly získány validně vypadající výsledky korelace, MSE, SSIM i PSNR, ale při pohledu na výstupní obrazy vzešlé z filtrace je patrné, že WT, respektive použité vlnky, je pro dataset RS nevhodnou metodou pro filtraci šumu. Filtrací sice došlo k potlačení šumu, ale zasažení ostrosti hran a následné rozmazání obrazu je natolik velké, že z takto filtrovaných obrazů nelze vyčíst žádné informace. K této degradaci došlo, neboť RS obrazy jsou standardně v nízkém rozlišení, kdy po filtraci, která je vždy kompromisem mezi potlačením šumu a ostrostí obrazu, dojde příliš velkým změnám vlastností pixelů. Z tohoto důvodu již nebudu dále hodnotit, která vlnka je nejefektivnější a která nejméně efektivní.

## 6 Praktická část II. – Efektivita segmentace snímků filtrovaných pomocí WT

Cílem této části práce je otestování efektivitu WT filtrace při segmentování obrazu. Originální obrazová data byla podrobena segmentaci pomocí Otsu metody a výstup této segmentace uložen. V dalším kroku byl na stejné originální snímky aplikován šum, tyto zašuměné snímky filtrovány pomocí WT a následně byly taktéž segmentovány Otsu metodou. Výstup originální původní segmentace a segmentace filtrovaných snímků byl následně porovnán pomocí korelace a MSE. Výsledky ideální segmentace originálních dat byly použity jako referenční data při hodnocení.

### 6.1 Segmentace obrazu

Jedná se o metodu, která využívá určitých matematických algoritmů k vyhledání charakteristických objektů, které jsou v obraze zobrazeny. Objekty jsou myšleny částí obrazu, které jsou pro zdravotnického pracovníka z nějakého důvodu zajímavé. Tyto důvody v praxi zahrnují například zobrazení a extrakci kalcifikací na vnitřních stěnách cév, nebo rozdělení tkáně mozku na bílou hmotu, šedou hmotu a mozkomíšní mok, neboli liquor [15, 16].

Segmentace obecně zahrnuje metody, které dokáží obraz rozdělit podle pixelů, mezi kterými platí konkrétní vztah. Mezi segmentační techniky patří například:

**Prahování** – rozděluje pixely vstupního obrazu do různých skupin v závislosti na zvolené prahovací úrovni. Proces prahování pracuje s histogramem obrazu. Pokud je použit jeden globální práh, jsou všechny pixely rozděleny do dvou skupin. Jedna skupina je tvořena pixely, jejichž intenzita jsou se nachází pod prahovací úrovní, a druhá skupina je tvořena pixely, jejichž intenzita jsou rovna nebo vyšší než prahovací úroveň. Tímto způsobem je pixelům pod prahovací úrovní dána hodnota 0, jsou přeneseny do pozadí, a pixelům nad prahovací úrovní je dána hodnota 1, jsou přeneseny do popředí snímku. Tento způsob prahování je nejjednodušší, ale hrozí zde chybná klasifikace objektů, což znamená, že do pozadí mohou být přeneseny i pixely, které patří do popředí. Lepším typem prahování je prahování adaptivní, u kterého je obraz rozdělen na větší množství menších částí, kterým je hodnota prahu přizpůsobena [15, 16].

**Segmentace na základě rozpoznávání regionů** – principem této metody je sdružování pixelů, které mají stejné vlastnosti jako třeba jas nebo barvu. Algoritmus postupně prochází pixely a rozděluje je do skupin podle jejich parametrů [15, 16].

**Segmentace pomocí detekování hran** – její princip spočívá v rozpoznání skupiny pixelů tvořící hranici mezi dvěma oblastmi. Tyto oblasti se od sebe liší rozdílnou intenzitou jasu. Hrany jsou tedy definovány jako oblasti skokového přechodu intenzity jasu, které má za úkol detekovat příslušný algoritmus [15, 16].

Tato část práce se zabývá pouze segmentací založené na prahování, konkrétně prahování pomocí metody Otsu.

### 6.1.1 Otsu prahování

Jak bylo zmíněno v kapitole 6.1, jeden globální práh může mít za následek špatnou klasifikaci objektů a proto je třeba tento práh zvolit co nejvhodněji. Otsu metoda tento práh stanovuje na základě postupného výpočtu vnitřního rozptylu, nebo hodnot mezi-rozptylu pro každou úroveň jasu, která je v obraze zastoupena. Každá z těchto úrovní je potenciální práh. Jako neoptimálnější prahovací úroveň je určena úroveň jasu, u které je hodnota vnitřního rozptylu nejnižší, nebo hodnota mezi-rozptylu nejvyšší.

Z hlediska výpočetní náročnosti je lepší výpočet mezi-rozptylu, který je definován jako [15]:

$$\sigma_B^2 = W_b \cdot W_f \cdot (\mu_b - \mu_f)^2 \quad (6.1.1.1)$$

Kde  $W_b$  je váha pozadí,  $\mu_b$  je průměrná hodnota intenzity pozadí,  $W_f$  je váha popředí a  $\mu_f$  je průměrná hodnota intenzity popředí [15]:


$$W_b = \sum_{i=1}^K \frac{n_i}{N} \quad (6.1.1.2)$$

$$W_f = \sum_{i=K+1}^L \frac{n_i}{N} \quad (6.1.1.2)$$


$$\mu_b = \sum_{i=1}^k \frac{n_i \cdot i}{N_k} \quad (6.1.1.3)$$

$$\mu_f = \sum_{i=K+1}^L \frac{n_i \cdot i}{N - N_k} \quad (6.1.1.4)$$


Kde  $L$  značí pixely snímku o stupních šedi od 0 do  $L$ .  $n_i$  je počet pixelů, jejichž stupeň šedi je  $i$ .  $N$  je celkový počet pixelů, který je dán součtem všech pixelů ve všech odstínech šedi.  $b$  a  $f$  značí skupiny snímků.  $b$  je pozadí a  $f$  je popředí snímku [15]. Příklad Otsu segmentace je zobrazen na obr. 40 níže.




(a) Otsu prahování obrazu; počet prahů 1



(b) Otsu prahování obrazu; počet prahů 2




(c) Otsu prahování obrazu; počet prahů 3



(d) Otsu prahování obrazu; počet prahů 5



(e) Otsu prahování obrazu; počet prahů 10



(f) Otsu prahování obrazu; počet prahů 20

Obr. 40: Příklady množství segmentačních prahů

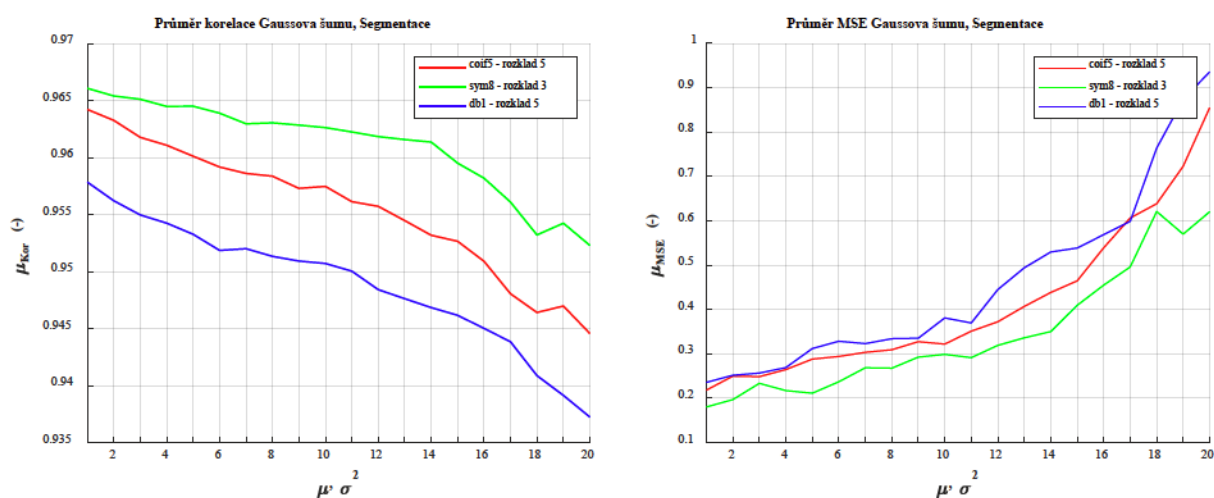
## 6.2 Výsledky pro dataset CT

Na obrazová data byl aplikován stejně jako v 5.1 šum ve dvaceti úrovních.

### 6.2.1 Gaussovský šum

	Gaussovský šum; $\mu = 0,02$		Gaussovský šum; $\mu = 0,2$		Gaussovský šum; $\mu = 0,4$	
	Korr	MSE	Korr	MSE	Korr	MSE
<i>coif5 rozklad 5</i>	0,964207	0,218204	0,957463	0,322024	0,944561	0,854871
<i>sym8 rozklad 3</i>	<b>0,96606</b>	<b>0,180267</b>	<b>0,962616</b>	<b>0,298856</b>	<b>0,952287</b>	<b>0,620332</b>
<i>db1 rozklad5</i>	0,957834	0,235664	0,950703	0,381049	0,937237	0,935738

Tabulka 19: Hodnoty korelace a MSE s vyznačenými hodnotami nejefektivnější vlnky



(a) Zobrazení průměru korelace

(b) Zobrazení průměru MSE


Obrázek 41: Grafické zobrazení výsledků korelace a MSE mezi ideálním výstupem segmentace a obrazy segmentovanými po aplikaci WT filtrace

Pro vypočítání a zobrazení hodnot korelace a MSE byly použity tři vlnky, které vyšly jako výsledek z praktické části I. První dvě z těchto vlnek (**coif5 o rozkladu 5** a **sym8 o rozkladu 3**) se v praktické části I. jevíly pro konkrétní šum v rámci datasetu jako nejvhodnější a vybrána byla také jedna vlnka, která se jevíla jako nejméně vhodná (**db1 o rozkladu 5**).




## 6.2.2 Závěr pro efektivitu segmentace – Gaussovský šum


Zatím co v kapitole 5.2.1 nebylo jednoznačně snadné rozhodnout, která z vlnek *coif5* a *sym8* byla nejméně efektivní, v případě segmentace jsou výstupní hodnoty korelace a MSE z Tab. 19 a Obr. 41 zřetelně odlišitelné. **Nejefektivněji se jeví vlnka *sym8* o rozkladu 3 a nejméně efektivně vlnka *db1* o rozkladu 5.** Na Obr. 42 jsou vykresleny výsledky segmentace jednotlivými vlnkami.




(a) Výstup ideální segmentace



(b) Výstup segmentace obrazu degradovaného Gaussovým šumem a filtrovaného vlnkou *coif5* o rozkladu 5



(c) Výstup segmentace obrazu degradovaného Gaussovým šumem a filtrovaného vlnkou *sym8* o rozkladu 3




(d) Výstup segmentace obrazu degradovaného Gaussovým šumem a filtrovaného vlnkou *db1* o rozkladu 5

Obrázek 42: Zobrazení výsledku ideální segmentace a výsledků segmentace po filtrování různými vlnkami při nejvyšším stupni zašumění


### 6.2.3 Šum Salt&Pepper

	Šum Salt&Pepper; $d = 0,00166$		Šum Salt&Pepper; $d = 0,0166$		Šum Salt&Pepper; $d = 0,0333$	
	Korr	MSE	Korr	MSE	Korr	MSE
db10 rozklad 3	0,984099	<b>0,076175</b>	<b>0,949043</b>	0,345283	<b>0,9498</b>	<b>0,337418</b>
coif5 rozklad 3	<b>0,984292</b>	0,077443	0,935525	<b>0,322383</b>	0,911804	0,751102
db1 rozklad 8	0,982744	0,08906	0,908765	0,427351	0,837416	0,753637

Tabulka 20: Hodnoty korelace a MSE s vyznačenými hodnotami nejefektivnějších vlnky



(a) Zobrazení průměru korelace



(b) Zobrazení průměru MSE


Obrázek 43: Grafické zobrazení výsledků korelace a MSE mezi ideálním výstupem segmentace a obrazy segmentovanými po aplikaci WT filtrace

Pro vypočítání a zobrazení hodnot korelace a MSE byly použity tři vlnky, které vyšly jako výsledek z praktické části I. První dvě z těchto vln (db10 a coif5, obě o rozkladu 3) se v praktické části I. jeví pro konkrétní šum v rámci datasetu jako nejvhodnější a vybrána byla také jedna vlnka, která se jeví jako nejméně vhodná (db1 o rozkladu 8).


### 6.2.4 Závěr pro efektivitu segmentace – Šum Salt&Pepper

V kapitole 5.1.3 se jako nejefektivnější pro filtraci Salt&Pepper šumu z CT obrazu jeví vlnka db10 o rozkladu 3. Tato vlnka se celkově jako nejefektivnější jeví i v případě segmentace, kde jak u korelace, tak u MSE dosahuje většinou nejlepších výsledků. Jak je zobrazeno na obr. 39 (a), korelace z počátku klesá, v blízkosti úrovně šumu pokles ustává, poté do úrovně 16 lehce roste a nakonec jsou hodnoty lehce kolísavé, ale přibližně stejné. V případě ostatních dvou vln korelace v celém spektru jen klesá. Jasně nejhůře se jeví vlnka db1 o rozkladu 8.


Jak je zobrazeno na Obr. 43 (b), MSE přibližně odpovídá průběhu korelace s tím, že v maximální úrovni šumu dosahuje jasně nejnižší hodnoty. **Nejhůře se jeví vlnka db1 o rozkladu 8.** Na Obr. 44 jsou vykresleny výsledky segmentace po filtrování všemi testovanými vlnkami. Je možné vidět, že vlnka db10 o rozkladu 5 dokázala nejlépe potlačit šum a zároveň dosáhla při segmentaci dobrých výsledků. Výsledky segmentace vlnkou coif5 o rozkladu 3 jsou také relativně dobré, ale obraz je stále hodně poškozen šumem. Vlnka db1 o rozkladu 8 v segmentaci neuspěla. V obrazu je vzhledem k Obr. 44 (a) méně rozlišitelných úrovní a navíc je šum filtrací prakticky nedotčený.




(a) Výstup ideální segmentace



(b) Výstup segmentace obrazu degradovaného Gaussovým šumem a filtrovaného vlnkou db10 o rozkladu 5



(c) Výstup segmentace obrazu degradovaného Gaussovým šumem a filtrovaného vlnkou coif5 o rozkladu 3



(d) Výstup segmentace obrazu degradovaného Gaussovým šumem a filtrovaného vlnkou db1 o rozkladu 8

Obrázek 44: Zobrazení výsledku ideální segmentace a výsledků segmentace po filtrování různými vlnkami při nejvyšším stupni zašumění


## 6.3 Výsledky pro dataset MRI

Na obrazová data byl aplikován, stejně jako v kapitole 5.2, šum ve dvaceti úrovních.

### 6.3.1 Gaussovský šum

	Gaussovský šum; $\mu = 0,02$		Gaussovský šum; $\mu = 0,2$		Gaussovský šum; $\mu = 0,4$	
	Korr	MSE	Korr	MSE	Korr	MSE
coif5 rozklad 3	0,932212	0,295717	0,925966	0,398966	<b>0,913484</b>	0,643686
sym8 rozklad 3	<b>0,932794</b>	<b>0,290315</b>	<b>0,92868</b>	0,418944	0,913164	<b>0,637256</b>
db1 rozklad 5	0,920018	0,359684	0,916202	<b>0,381354</b>	0,900943	0,645871

Tabulka 21: Hodnoty korelace a MSE s vyznačenými hodnota nejefektivnější vlnky



(a) Zobrazení průměru korelace


(b) Zobrazení průměru MSE

Obrázek 45: Grafické zobrazení výsledků korelace a MSE mezi ideálním výstupem segmentace a obrazy segmentovanými po aplikaci WT filtrace


Pro vypočítání a zobrazení hodnot korelace a MSE byly použity tři vlnky, které vyšly jako výsledek z praktické části I. První dvě z těchto vlnk (**coif5 a sym8, obě o rozkladu 3**) se v praktické části I. jevíly pro konkrétní šum v rámci datasetu jako nejvhodnější a vybrána byla také jedna vlnka, která se jevíla jako nejméně vhodná (**db1 o rozkladu 5**).

### 6.3.2 Závěr pro efektivitu segmentace – Gaussovský šum


V kapitole 5.2.1 se nejefektivněji jevíla vlnka **coif5 o rozkladu 3** s velkým náskokem oproti ostatním vlnkám. Jak lze vidět na Obr. 45, v případě segmentace výsledek tak jednoznačný není. **Jako nejefektivnější je vybrána vlnka sym8 o rozkladu 3**, která sice nedosahuje nejvyšších hodnot, ale na rozdíl od coif5 o rozkladu 3 nenabývá tak velkých výkyvů hodnot. Jako nejméně efektivní se jeví vlnka db1 o rozkladu 5. Jak je vidět i na Obr. 46, **nejlepšího výsledku segmentaci opravdu dosáhla vlnka sym8 o rozkladu 3**. Vlnka coif5 o rozkladu 3 v rámci segmentace obstála dobře, ale příliš neobstála ve filtraci šumu, kvůli kterému je obraz méně čitelný.




(a) Výstup ideální segmentace



(b) Výstup segmentace obrazu degradovaného Gaussovým šumem a filtrovaného vlnkou  $\text{coif}_3$  o rozkladu 3



(c) Výstup segmentace obrazu degradovaného Gaussovým šumem a filtrovaného vlnkou  $\text{sym}_8$  o rozkladu 3




(d) Výstup segmentace obrazu degradovaného Gaussovým šumem a filtrovaného vlnkou  $\text{db}_1$  o rozkladu 5

Obrázek 46: Zobrazení výsledku ideální segmentace a výsledků segmentace po filtrování různými vlnkami při nejvyšším stupni zašumění

### 6.3.3 Šum Salt&Pepper

	Šum Salt&Pepper; $d = 0,0033$		Šum Salt&Pepper; $d = 0,033$		Šum Salt&Pepper; $d = 0,066$	
	Korr	MSE	Korr	MSE	Korr	MSE
coif5 rozklad 3	<b>0,97431</b>	<b>0,112758</b>	0,920276	0,344655	0,895754	0,577278
db10 rozklad 3	0,971595	0,131296	<b>0,930547</b>	<b>0,301219</b>	<b>0,917426</b>	<b>0,359394</b>
db1 rozklad 8	0,970036	0,144952	0,913391	0,395141	0,854264	0,705454

Tabulka 22: Hodnoty korelace a MSE s vyznačenými hodnotami nejefektivnější vlnky



(a) Zobrazení průměru korelace

(b) Zobrazení průměru MSE


Obrázek 47: Grafické zobrazení výsledků korelace a MSE mezi ideálním výstupem segmentace a obrazy segmentovanými po aplikaci WT filtrace

Pro vypočítání a zobrazení hodnot korelace a MSE byly použity tři vlnky, které vyšly jako výsledek z praktické části I. První dvě z těchto vlnk (**coif5 a db10, obě o rozkladu 3**) se v praktické části I. jeví pro konkrétní šum v rámci datasetu jako nejvhodnější a vybrána byla také jedna vlnka, která se jeví jako nejméně vhodná (**db1 o rozkladu 8**).


### 6.3.4 Závěr pro efektivitu segmentace – Šum Salt&Pepper

V kapitole 5.2.3 byly jako nejefektivnější vlnky vybrány coif5 a db10, obě o rozkladu 3, s tím, že db10 byla nejvhodnější pro filtrování Salt&Pepper šumu do úrovně 11 a coif5 byla nejefektivnější pro filtraci šumu nad touto úrovní. V případě segmentace je výsledek podobný, neboť **do úrovně 4 se nejefektivněji jeví vlnka coif5**, poté je dvě úrovně nejefektivnější vlnka db1 o rozkladu 8, která však byla vybrána jako nejméně vhodná vlnka a nakonec **od úrovně 6 je jasně nejefektivnější vlnkou db10 o rozkladu 3 a nejméně efektivní je vlnka db1 o rozkladu 8, jejíž trend od 4 úrovně zašumění prudce klesá**. Z Obr. 48 lze vyčíst, že výsledky nejsou tak jednoznačné, jak se jeví na Obr. 47. Z hlediska filtrace vůbec neuspěla vlnka db1 o rozkladu 8, ale z hlediska segmentace je výstup této vlnky docela dobře čitelný. To je způsobeno zejména povahou a hustotou daného šumu.


Nejčistšího výsledku dosáhla vlnka db10 o rozkladu 3, avšak detaily anatomického uspořádání menších cév uvnitř hlavy jsou ztraceny. Výstup vlnky coif5 o rozkladu 3 je z hlediska kvality kompromisem mezi dvěma výše uvedenými případy. Vyfiltrování šumu není ideální, ale některé struktury jsou viditelnější, než na obr. 45 (c).




(a) Výstup ideální segmentace



(b) Výstup segmentace obrazu degradovaného Gaussovým šumem a filtrovaného vlnkou coif5 o rozkladu 3



(c) Výstup segmentace obrazu degradovaného Gaussovým šumem a filtrovaného vlnkou db10 o rozkladu 3



(d) Výstup segmentace obrazu degradovaného Gaussovým šumem a filtrovaného vlnkou db8 o rozkladu 8

Obrázek 48: Zobrazení výsledku ideální segmentace a výsledků segmentace po filtrování různými vlnkami při nejvyšším stupni zašumění

## 6.4 Závěrečné hodnocení praktické části II.

Nejefektivnější vlnky		
	Dataset CT	Dataset MRI
Gaussovský šum	sym8 rozklad 3	sym8 rozklad 3
Šum Salt&Pepper	db10 rozklad 3	db10 rozklad 3
Nejméně efektivní vlnky		
	Dataset CT	Dataset MRI
Gaussovský šum	db1 rozklad 5	db1 rozklad 5
Šum Salt&Pepper	db1 rozklad 8	db1 rozklad 8

Tab. 2: Závěrečný přehled

Jak lze vidět v Tab. 2, v rámci segmentace se pro konkrétní šum jeví nejefektivněji pro oba datasey stejné vlnky. Pro Gaussovský šum je to vlnka sym8 o rozkladu 3 a pro šum Salt&Pepper je to vlnka db10 o rozkladu 3. Pro oba datasey jsou shodné také nejméně efektivní vlnky, kterými jsou db1 o rozkladu 5 pro Gaussovský šum a db1 o rozkladu 8 pro šum Salt&Pepper.

Jako nejefektivnější úroveň rozkladu se ukázala úroveň rozkladu 3 a jako nejméně efektivní úroveň 5 pro Gaussovský šum a úroveň 8 pro šum Salt&Pepper.

V případě šumu Salt&Pepper je nejefektivnější vlnkou vlnka, která se ukázala jako nejefektivnější také v rámci filtrace tohoto šumu. Nejméně efektivní vlnky jsou stejné vlnky, které nejméně efektivně filtrovaly šum, jak je uvedeno v kapitole 5.4.

Nejméně efektivní vlnky jsou z rodiny Daubechies, konkrétně db1. Tento výsledek není příliš překvapující, neboť vlnka db1, neboli Haarova vlnka, je charakterizována svým „obdélníkovým“ průběhem, který negativně ovlivňuje vlnkové koeficienty ve scalogramu. V případě šumu Salt&Pepper není vlnka db1 o rozkladu 8 schopna prakticky žádné filtrace šumu. V případě Gaussova šumu je obraz zcela znehodnocen.



## 7 Diskuze

Práce se zabývala testováním efektivity filtrace pomocí Wavelet transformace. K analýze bylo využito celkem tří rodin vlnek, konkrétně rodiny Daubechies, Symlets a Coiflets. Z rodiny Daubechies byly vybrány vlnky db1, db5, db10, z rodiny Symlets sym3, sym8 a z rodiny Coiflets coif1 a coif5. Testování efektivity filtrace šumu těmito vlnkami bylo provedeno na třech datasetech, konkrétně na datasetu CT, obsahující transversální řezy břišní dutinou, datasetu MRI, který obsahuje kontrastní snímky cév krku a hlavy, a dataset RS, který obsahuje skeny očního pozadí.

Všechny snímky napříč datasety byly uměle zašuměny pomocí šumových generátorů z prostředí MATLAB. Pro účely testování byl zvolen Gaussovský šum, šum Salt&Pepper a šum Speckle. Šum byl na obrazy aplikován ve dvaceti úrovních, následně filtrován pomocí WT a výstupní obrazy byly podrobeny analýze pomocí metod korelace, MSE, PSNR a SSIM.

V druhé části práce byla testována efektivita WT při segmentaci obrazu. Data byla uměle zašuměna, filtrována pomocí WT a následně byla výstupní data segmentována pomocí Otsu metody. Výsledek této segmentace byl porovnán s výsledky segmentace, které vznikly aplikací Otsu metody na originální data. Testování a analýza byla provedena jen na datasetu CT a MRI, jelikož u datasetu RS se WT filtrace ukázala jako neefektivní. Také byly použity pouze dva typy šumu (Gaussovský šum a šum Salt&Pepper).

Obrazové výstupy měření nejsou vždy úplně uspokojivé, a proto by mohly být výsledky vylepšeny například použitím většího počtu vlnek, více rodin nebo vícero úrovní rozkladu obrazu.

Například v kapitole 5.1.6 se ukázalo, že u velmi vysoké úrovně zašumění šumem Speckle je velice obtížné jej filtrovat. Vylepšením by tak mohl být algoritmus, který by na snímky aplikoval šum, jehož hustota by odpovídala hustotě, která se může na snímcích v praxi vyskytnout. Společně s těmito vylepšeními by mohla být navržena i metoda prahování, která by z obrazu dokázala do popředí přenést ještě více informací. Následně by bylo možné uvažovat i o aplikaci použitelné v praxi. Práce je tak dobrým základem pro diplomovou práci.

## 8 Závěr

Cílem práce byla aplikace šumových generátorů na soubor klinických obrazových dat a jejich následná filtrace pomocí WT. WT je metoda, která rozkládá vstupní signál na složku aproximační a složku detailní. Parametry filtrace musí být nastaveny tak, aby došlo k co největšímu potlačení šumu, ale zároveň aby zůstaly hrany a celková ostrost zachovány. U WT se volí typ vlnky a úroveň rozkladu.

K testování bylo použito 60 anonymních obrazových snímků náležících do tří datasetů (CT, MRI, RS). Na všechny snímky byl pomocí šumových generátorů z prostředí MATLAB aplikován šum ve 20 stupních. Jedná se o Gaussovský šum, šum Salt&Pepper a šum Speckle. K testování bylo využito vlnek ze tří rodin (Daubechies – db1, db5, db10, Symlets – sym3, sym8, Coiflets, coif1, coif5). Zvolené úrovně rozkladu byly 3, 5 a 8.

Jak výsledky ukázaly v Tab. 3 (tabulka z kapitoly 5.4.), není možné zvolit jedinou vlnku, která by byla univerzálně vhodná pro filtrování všech datasetů, ale i přesto se ukázaly některé souvislosti mezi datasety CT a MRI. Pro filtraci šumu Salt&Pepper se v obou datasetech ukázala jako nejefektivnější vlnka db10 o rozkladu 3. Z hlediska vlnek vhodných pro filtraci je to jediná shoda napříč datasety. U šumu speckle byla pro každý dataset nejefektivnější jiná vlnka i rozklad, žádná souvislost zde tedy není. Mimo jiné se ukázalo že, vlnka, která se jeví jako nejefektivnější pro jeden typ dat a konkrétní šum, může být pro jiná data a jiný šum naprosto nevhodná. Tento případ nastal u datasetu CT a MRI, kdy se vlnka coif5 o rozkladu 3 se jevila jako nejlepší, ale v datasetu CT při filtrování speckle šumu dosáhla nejhorších výsledků. Jedná se sice o jiný stupeň rozkladu, ale vlnka coif5 o rozkladu 3 je oproti rozkladu 8 lepší jen nepatrně. Volba nejefektivnější vlnky nezávisí jen na typu dat a typu šumu, tak také na úrovni zašumění, jak bylo zjištěno například v kapitole 5.2.3. Ukázalo se, že čím vyšší je úroveň zašumění, tím nižší je efektivita filtrace. V kapitole 5.1.6 se ukázalo, že u vysoké úrovně zašumění šumem Speckle je velice obtížné filtrovat.

U datasetu RS (kapitola 5.3) byly získány validně vypadající výsledky korelace, MSE, SSIM i PSNR, ale při pohledu na výstupní obrazy vzešlé z filtrace je patrné, že WT, respektive použité vlnky, je pro dataset RS nevhodnou metodou pro filtraci šumu. Filtrací sice došlo k potlačení šumu, ale zasažení ostrosti hran a následné rozmazání obrazu je natolik velké, že z takto filtrovaných obrazů nelze vyčíst žádné informace. K této degradaci došlo, neboť RS obrazy jsou standardně v nízkém rozlišení, kdy po filtraci, která je vždy kompromisem mezi potlačením šumu a ostrostí obrazu, dojde příliš velkým změnám vlastností pixelů.

Při segmentaci se ve  $\frac{3}{4}$  případů osvědčily stejné vlnky, jako vlnky nejefektivnější v praktické části I. To ukazuje na fakt, že vlnka, která je nejvhodnější čistě pro filtraci obrazu, nemusí být nejvhodnější volbou také pro filtraci, po které chceme provést ještě segmentaci.

Jako nejméně efektivní se ve většině případů osvědčila vlnka db1 o rozkladu 5 nebo 8. Její neefektivita spočívá v jejím „obdélníkovém“ průběhu a nespojitosti. Obecně se ve většině případů neosvědčily vysoké nejvyšší úrovně rozkladu

## 8.1 Tabulka k závěru: Výsledky I. praktické části

Přehled neefektivnějších vlnek			
	Dataset CT	Dataset MRI	Dataset RS
Gaussovský šum	sym8 rozklad 3	coif5 rozklad 3	db10 rozklad 3
Šum Salt&Pepper	db10 rozklad 3	db10 rozklad 3	db10 rozklad 5
Šum Speckle	sym3 rozklad 3	coif1 rozklad 8	coif5 rozklad 5
Přehled nejméně efektivních vlnek			
	Dataset CT	Dataset MRI	Dataset RS
Gaussovský šum	db1 rozklad 5	db1 rozklad 5	db1 rozklad 8
Šum Salt&Pepper	db1 rozklad 8	db1 rozklad 8	db1 rozklad 8
Šum Speckle	coif5 rozklad 8	db1 rozklad 8	sym3 rozklad 3

Tab. 3: Závěrečný přehled efektivních/neefektivních vlnek při filtraci

## 8.2 Tabulka k závěru: Výsledky II. praktické části

Přehled neefektivnějších vlnek		
	Dataset CT	Dataset MRI
Gaussovský šum	sym8 rozklad 3	sym8 rozklad 3
Šum Salt&Pepper	db10 rozklad 3	db10 rozklad 3
Přehled nejméně efektivních vlnek		
	Dataset CT	Dataset MRI
Gaussovský šum	db1 rozklad 5	db1 rozklad 5
Šum Salt&Pepper	db1 rozklad 8	db1 rozklad 8

Tab. 4: Závěrečný přehled efektivních/neefektivních vlnek při segmentaci

## 9 Literatura a použité zdroje:

- [1] Md Zahangir Alom, Chris Yakopcic, Mahmudul Hasan, Tarek M. Taha, and Vijayan K. Asari "Recurrent residual U-Net for medical image segmentation," Journal of Medical Imaging 6(1), 014006 (27 March 2019). <https://doi.org/10.1117/1.JMI.6.1.014006>
- [2] MALLAT, S. G. *A wavelet tour of signal processing: the sparse way*. 3rd ed. Amsterdam: Elsevier/Academic Press, c2009. ISBN 978-0-12-374370-1.
- [3] MFMIImage. In: <https://med.virginia.edu/obgyn/divisions/maternal-fetal-medicine/> [online]. [cit.2019 2 19]. Dostupné z: <https://med.virginia.edu/obgyn/wp-content/uploads/sites/286/2015/11/MFMIImage062012-300x203.jpg>
- [4] SEERAM, Euclid a David SEERAM. Image Postprocessing in Digital Radiology - A Primer for Technologists. Journal of Medical Imaging and Radiation Sciences [online]. 2008(39) [cit. 2019-12-27]. Dostupné z: [https://www.jmirs.org/article/S1939-8654\(08\)00005-2/pdf](https://www.jmirs.org/article/S1939-8654(08)00005-2/pdf)
- [5] BAXES, Gregory A. Digital image processing: principles and applications. New York: Wiley, c1994. ISBN 9780471009498.
- [6] GONZALES, R. C., & Woods, R. E. (2008). Digital image processing. Harlow: Prentice-Hall. Antonín Vojáček. In: Automatizace.hw [online]. Praha, 2006 [cit. 2019 12 1]. Dostupné z: <https://automatizace.hw.cz/images/wavelet/smallmeyerwave.gif>
- [7] HOŠŤÁLKOVÁ, Eva a Aleš PROCHÁZKA. Zpracování biomedicínských signálů a obrazů pomocí wavelet transformace. Automatizace [online]. 2007, 2007(6), 9 [cit. 2019-12-31]. Dostupné z: <http://dsp.vscht.cz/hostalka/upload/Automatizace07.pdf>
- [8] T. Nguyen G. Strang. Wavelets and Filter Banks. Wellesley-Cambridge Press, 1996.
- [9] N. KINGSBURY. Complex Wavelets for Shift Invariant Analysis and Filtering of Signals. Journal of Applied and Computational Harmonic Analysis, 10(3):234–253, May 2001.
- [10] GONZALEZ, Rafael C. a Paul A. WINTZ. Digital image processing. 2nd ed. Reading, Mass.: Addison-Wesley, c1987. ISB 978-0-201-11026-5.
- [11] VILÍMEK, Dominik. Filtrace šumu typu speckle v ultrazvukových obrazech [online]. Ostrava, 2019 [cit. 2020-01-04]. Dostupné z: <http://hdl.handle.net/10084/136215>. Diplomová práce. VŠB-TUO.
- [12] LIPUS, Mariusz. Filtrace MR obrazu na základě metody Nonlocal Means [online]. Ostrava, 2019 [cit. 2020-01-04]. Dostupné z: <http://hdl.handle.net/10084/136214>. Diplomová práce. VŠB-TUO.

- [13] KUBÍČEK, Jan. *Zpracování medicínských obrazových dat*. Opava: Slezská univerzita v Opavě, 2014. ISBN 978-80-7248-941
- [14] Miroslav Fribert. *Základy zpracování obrazu*. Univerzita Pardubice, 2013. ISBN 978-80-7395-534-2.
- [15] VALOŠEK, Jan. *Software pro vizualizaci a kvantitativní vyhodnocení cévních kalcifikací* [online]. Ostrava, 2017 [cit. 2020-01-26]. Dostupné z: <http://hdl.handle.net/10084/119119>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.
- [16] ŠPANĚL, Michal. *Obrazové segmentační techniky*. Brno: Vysoké učení technické v Brně, 2005 [cit. 2020-01-23]. Dostupné z: [http://www.fit.vutbr.cz/~spanel/segmentace/#\\_Toc125769333](http://www.fit.vutbr.cz/~spanel/segmentace/#_Toc125769333)
- [17] A. Benkrid, K. Benkrid, and D. Crookes. Design and implementation of a generic 2d orthogonal discrete wavelet transform on fpga. *IEEE Comp. Sci. Engi.*, pages 162–172, 2003. doi: 10.1109/FPGA.2003.1227252. URL <https://ieeexplore.ieee.org/abstract/document/1227252>
- [18] Gajanand Gupta. Algorithm for image processing using improved median filter and comparison of mean, median and improved median filter. *International Journal of Soft Computing and Engineering (IJSCE)*, 1(5):304–311, 2011. ISSN 2231-2307.
- [19] Suresh Kumar, Papendra Kumar, Manoj Gupta, and Ashok Kumar Nagawat. Performance comparison of median and wiener filter in image de-noising. *International Journal of Computer Applications (0975–8887) Volume*, 12, 2010. URL <https://pdfs.semanticscholar.org/5b64/ebf95b55ebe4d36c2d5613f4e5983ee2f1a3.pdf>.

# Seznam příloh

Příloha I. Vypracování a výsledky