



**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA INFORMAČNÍCH TECHNOLOGIÍ**

FACULTY OF INFORMATION TECHNOLOGY

**ÚSTAV INTELIGENTNÍCH SYSTÉMŮ**

DEPARTMENT OF INTELLIGENT SYSTEMS

**AUTOMATICKÁ ANALÝZA KVALITY OBRAZU SÍTNICE**

AUTOMATIC RETINAL IMAGE QUALITY ANALYSIS

**BAKALÁŘSKÁ PRÁCE**

BACHELOR'S THESIS

**AUTOR PRÁCE**

AUTHOR

**ANDRII DOVBUSH**

**VEDOUcí PRÁCE**

SUPERVISOR

**MSc. ANDRII KAVETSKYI**

BRNO 2023

## Zadání bakalářské práce



146459

Ústav: Ústav inteligentních systémů (UITS)  
Student: **Dovbush Andrii**  
Program: Informační technologie  
Specializace: Informační technologie  
Název: **Automatická analýza kvality obrazu sítnice**  
Kategorie: Zpracování obrazu  
Akademický rok: 2022/23

### Zadání:

1. Prostudujte literaturu týkající se lidské sítnice, faktory, které ovlivňují kvalitu zobrazení sítnice a techniky hodnocení kvality snímků sítnice.
2. Navrhněte vlastní algoritmus pro analýzu kvality snímků sítnice.
3. Implementujte algoritmus z předchozího bodu a otestujte jej na datech poskytnutých vedoucím práce.
4. Zhodnoťte dosažené výsledky a navrhněte možnosti dalšího rozšíření práce.

### Literatura:

- C. Shi, J. Lee, G. Wang, X. Dou, F. Yuan and B. Zee. Assessment of Image Quality on Color Fundus Retinal Images Using the Automatic Retinal Image Analysis. Scientific Reports, 2022.
- A. Raj, A. Tiwari and M. Martini. Fundus Image Quality Assessment: Survey, Challenges, and Future Scope. IET Image Processing, 2019.
- P. Costa, A. Campilho, B. Hooi, A. Smailagic, K. Kitani, Sh. Liu, Ch. Faloutsos and A. Galdran. EyeQual: Accurate, Explainable, Retinal Image Quality Assessment. IEEE International Conference on Machine Learning and Application, 2017.

Při obhajobě semestrální části projektu je požadováno:  
Completion of points 1 and 2.

Podrobné závazné pokyny pro vypracování práce viz <https://www.fit.vut.cz/study/theses/>

Vedoucí práce: **Kavetskyi Andrii**  
Vedoucí ústavu: Hanáček Petr, doc. Dr. Ing.  
Datum zadání: 1.11.2022  
Termín pro odevzdání: 10.5.2023  
Datum schválení: 3.11.2022

## Abstrakt

Práce probíhaly v rámci vývoje autonomního oftalmologického dohledového centra. Kromě přesnosti posouzení kvality obrazu byla významným faktorem rychlost výpočtu klíčových parametrů kvality obrazu, která by umožnila provoz centra v reálném čase. Na základě nedávných výzkumů a vědeckých objevů byla potřeba další studie o časové výkonnosti algoritmů.

Hlavním cílem práce bylo vytvořit algoritmus pro určování kvality obrazu, založený na nejlepší kombinaci parametrů kvality obrazu v kontextu výkonnosti-do-času. Hlavní náplní práce se nakonec stal vývoj nástrojů pro analýzu znaků kvality obrazu sítnice a následná analýza vybraných kombinací IQA algoritmů a obrazových kanálů.

Byly zvoleny dvě metody výběru nejlepších kombinací algoritmů a obrazových kanálů: metoda absolutní výkonnosti a metoda relativní výkonnosti. V důsledku toho byly zjištěny jejich nedostatky a bylo navrženo možné řešení těchto problémů pomocí metody nejlepšího pokrytí.

Bylo shromážděno a analyzováno přibližně 150 možných kombinací algoritmů rysů kvality a algoritmů pro extrakci obrazových kanálů. Mezi vybranými algoritmy také se podařilo určit sadu algoritmů závislých na úrovni obrazového šumu, stejně jako vliv snižování rozlišení obrazu na celkový výkon různých algoritmů rysů kvality. Byl vysvětlen vliv šumu na Sobelovův detektor hran a Cannyho detektor hran.

## Abstract

The work was carried out in the context of the development of an autonomous ophthalmological examination center. In addition to the accuracy of assessing image quality, a significant factor was the speed of calculation of key image quality parameters, which would allow real-time operation of the center. Based on recent researches and scientific discoveries, there was a need of additional study on algorithms' time performance.

The main goal of the work was to create an algorithm for assessing image quality, based on the best combination of image quality parameters in the context of effectiveness-to-time performance. This eventually led to the development of a tool for analyzing retinal image quality features and the subsequent analysis of selected combinations of IQA algorithms and image channels.

Two methods for selecting the best combinations of algorithms and image channels were chosen: the absolute performance method and the relative performance method. As a result, their weaknesses were found and a possible solution to these problems was proposed by using the best-coverage approach.

Approximately 150 possible combinations of quality feature and channel extraction algorithms have been collected and analysed. Among the selected algorithms it was also possible to determine the algorithms dependent on the level of image noise and also the influence of resolution downscaling on the overall performance of the different algorithms for quality features. The effect of noise on the Sobel edge detector and the Canny edge detector was explained.

## Klíčová slova

Hodnocení kvality obrazu sítnice, automatizovaný systém screeningu sítnice, wavelet transformace, ostrost, metody výběru algoritmu, percepční kvalita, lidský zrakový systém, .

## Keywords

Retinal image quality assessment, automated retinal screening system, wavelet transform, sharpness, algorithm selection methods, perceptual quality, human visual system.

## Citace

DOVBUSH, Andrii. *Automatická analýza kvality obrazu sítnice*. Brno, 2023. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce MSc. Andrii Kavetskyi

# Automatická analýza kvality obrazu sítnice

## Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně pod vedením pana Andriiho Kavetskyiho. Uvedl jsem všechny literární prameny, publikace a další zdroje, ze kterých jsem čerpal.

.....  
Andrii Dovbush  
10.05.2023

## Poděkování

Rád bych poděkoval zejména mému vedoucímu, panu MSc. Andriimu Kavetskyimu a paní doc. Sangeeta Biswas za podporu, konzultace, literaturu a poskytnuté data, a panu Vladislavovi Mikhedovi za pomoc při sběru dat a za konzultace.

# Obsah

<b>1</b>	<b>Úvod</b>	<b>3</b>
<b>2</b>	<b>Biologie oka člověka</b>	<b>5</b>
2.1	Stavba oka . . . . .	5
2.1.1	Stavba sítnice oka . . . . .	6
2.2	Vlastnosti oka, které ovlivňují hodnocení kvality . . . . .	7
2.2.1	Které biologické faktory mohou ovlivnit kvalitu obrazu . . . . .	7
2.2.2	Výběr kanálu obrazu . . . . .	8
<b>3</b>	<b>Hodnocení kvality obrazu sítnice</b>	<b>10</b>
3.1	Úvod do RIQA . . . . .	10
3.1.1	Objektivní algoritmy pro RIQA . . . . .	11
3.2	Manuální metody RIQA . . . . .	11
3.2.1	Mean Opinion Score . . . . .	11
3.2.2	Single-stimulus a Double-stimulus metody . . . . .	11
3.3	Rysy kvality . . . . .	12
3.3.1	Generické rysy . . . . .	12
3.3.2	Strukturální rysy . . . . .	20
<b>4</b>	<b>Návrh algoritmů</b>	<b>23</b>
4.1	Techniky hodnocení výkonnosti algoritmů . . . . .	23
4.2	Metody výběru rysů kvality pro algoritmus . . . . .	25
4.2.1	Metoda relativní výkonnosti . . . . .	25
4.2.2	Metoda absolutní výkonnosti . . . . .	26
4.3	Etapy analýzy . . . . .	26
4.3.1	První etapa: Sběr primárních dat . . . . .	26
4.3.2	Druhá etapa: Analýza primárních dat . . . . .	27
4.3.3	Třetí etapa: Analýza předběžného zpracování a slučování statistik . . . . .	28
4.3.4	Čtvrtá etapa: Výběr kombinací . . . . .	28
4.3.5	Pátá etapa: Analýza kombinací . . . . .	28
<b>5</b>	<b>Implementace výběrového programu</b>	<b>29</b>
5.1	Architektura výběrového programu . . . . .	29
5.1.1	Sběr primárních dat . . . . .	29
5.1.2	Analýza primárních dat . . . . .	33
5.1.3	Analýza předběžného zpracování a slučování statistik . . . . .	33
5.1.4	Výběr kombinací . . . . .	34
5.1.5	Analýza kombinací . . . . .	34

<b>6</b>	<b>Analýza rysů kvality</b>	<b>36</b>
6.1	Algoritmy vybrané pro analýzu . . . . .	36
6.1.1	Algoritmy rysů kvality . . . . .	36
6.1.2	Algoritmy extrakce obrazových kanálů . . . . .	37
6.2	Databáze . . . . .	40
6.2.1	EyeQ data set . . . . .	40
6.2.2	Vlastní data set . . . . .	41
6.2.3	Snížení rozlišení jako předběžné zpracování databáze . . . . .	42
6.3	Výsledky . . . . .	42
6.3.1	První spuštění . . . . .	42
6.3.2	Sloučení výsledků . . . . .	48
6.3.3	Vybrané kombinace . . . . .	48
6.3.4	Analýza kombinací . . . . .	48
6.3.5	Nedostatky metod . . . . .	55
<b>7</b>	<b>Závěr</b>	<b>56</b>
	<b>Literatura</b>	<b>57</b>

# Kapitola 1

## Úvod

Světová zdravotnická organizace (WHO) odhaduje, že v roce 2020 mělo nejméně 2,2 miliardy lidí zhoršené vidění na blízko nebo na dálku, z toho 20 milionů lidí se středně závažným nebo závažným poškozením zraku na dálku nebo slepotou způsobenou onemocněními sítnice, jako jsou: makulární degenerace související s věkem (8 milionů), glaukom (7,7 milionů), diabetická retinopatie (3,9 milionů) [38]. Taková onemocnění mají mírné, pomalu progredující rané symptomy, které obvykle pacienti procházejí bez povšimnutí. Pacienti si obvykle uvědomují tato nemá onemocnění v jejich pozdních stádiích poté, co již došlo k vážnému poškození zraku. V jejich raných stádiích je medikamentózní léčba tichých očních onemocnění relativně jednoduchá a může pomoci zabránit progresi onemocnění. Při neléčení dochází k patologickým komplikacím vedoucím k těžkým zrakovým vadám vyžadujícím složité léčebné postupy, které jsou většinou neúčinné. Včasná detekce a správná léčba příznaků očního onemocnění jsou proto nezbytné k omezení růstu poruch zraku, kterým lze předejít, na celém světě. Studie například prokázaly, že včasná detekce DR pomocí pravidelného screeningu snižuje riziko slepoty asi o 50% [31].

Včasná detekce onemocnění vyžaduje časté lékařské prohlídky milionů pacientů, jako jsou pacienti s rodinnou anamnézou glaukomu nebo pacienti s diabetem. Nedávná studie také zjistila silný vztah mezi chronickými onemocněními ledvin a oftalmologickými onemocněními způsobujícími léčitelná poškození zraku. Tato studie důrazně doporučila oční screening všech pacientů se sníženou funkcí ledvin [42]. Manuální screening tak velké populace má nevýhodu v tom, že vytváří enormní režii na oftalmology. Manuální screening může být navíc omezen nízkým poměrem oftalmologů k pacientům konkrétně v rozvojových zemích a venkovských oblastech. Automatické retinální screeningové systémy (ARSS) mohou pomoci překonat tato omezení. ARSS zachycuje a analyzuje snímky sítnice bez nutnosti zásahu člověka. Na základě automatické diagnózy se subjektu doporučuje, aby se v případě zjištění příznaků onemocnění obrátil na oftalmologa. Do vývoje ARSS bylo vynaloženo značné výzkumné úsilí, nicméně bylo zjištěno, že jejich výkon silně závisí na kvalitě zpracovaných snímků sítnice [43][27]. Obecně se lékařsky vhodné snímky sítnice vyznačují dvěma hlavními aspekty:

1. Jasnost: Lékařsky vhodné snímky sítnice by měly být ostré, dobře osvětlené a homogenně osvětlené, aby se usnadnilo oddělení struktur sítnice a případných chorobných poškození automatickými systémy. Oftalmologové vyšetřující snímky sítnice také vyžadují, aby byly dostatečně jasné pro spolehlivou diagnózu.
2. Obsah: Snímky sítnice musí mít adekvátní definici pole včetně všech nezbytných struktur sítnice. Jasný obraz s chybějícími nebo neúplnými strukturami sítnice by mohl



vést k obrazu, který není vhodný pro lékařskou diagnózu. Kromě toho by měly být správně detekovány neretinální snímky (*outliers*), aby se předešlo možné chybné diagnóze, pokud by tyto snímky byly dále zpracovávány ARSS.

Snímky sítnice jsou pořizovány pomocí digitálních fundus kamer, které zachycují osvětlení odražené od povrchu sítnice. Studie ukázaly, že procento zobrazení sítnice nevhodných pro ARSS je asi 10% a 20,8% pro rozšířené a nedilatované zornice. Lékařsky nevhodné snímky sítnice mohou být důsledkem několika faktorů, včetně nedostatečného osvětlení, špatného zaostření, přirozeně zakřivené struktury sítnice, změn dilatace zornice a pigmentace mezi pacienty spolu s pohybem pacienta nebo mrkáním. Zpracování nekvalitních snímků může vést k požadavku na opětovné pořízení snímku oftalmologem, což stojí peníze i čas. V horším scénáři může analýza lékařsky nevhodných snímků sítnice pomocí ARSS způsobit, že nemocné oko bude falešně diagnostikováno jako zdravé, což vede k opožděné léčbě. V důsledku toho je hodnocení kvality obrazu sítnice (RIQA) zásadním předběžným krokem k zajištění spolehlivosti ARSS [1].

V této práci budou analyzovány dva různé přístupy k výběru rysů kvality pro výsledný algoritmus hodnocení kvality obrazu lidské sítnice. Existuje nedostatek studií v tomto směru, a proto je jedním z cílů této práce tuto mezeru zaplnit. Po analýze 150 kombinací různých algoritmů pro rysy kvality a algoritmů pro extrakci obrazového kanálu budou tyto přístupy analyzovány. Z dat získaných ze dvou technik výběru parametrů bude ve výsledku vybrána nejlepší kombinace algoritmů pro rysy kvality, která bude implementována jako samostatný program pro klasifikaci kvality obrazů.

Práce bude rozdělena do pěti hlavních kapitol. Kapitola 2 se bude zabývat strukturou lidského oka a vlastnostmi oka a vnějšími faktory, které mohou ovlivnit výslednou kvalitu obrazu lidské sítnice. V kapitole 3 budou popsány základy RIQA (angl. *Retinal Image Quality Assessment*) a různé algoritmy pro výpočet rysů kvality. Kapitola 4 popisuje etapy výběru algoritmů pro stanovení rysů kvality. Implementací programu pro výběr algoritmů a jeho architekturou se zabývá kapitola 5. Následná analýza 150 rysů kvality a konečné výsledky práce jsou představeny v kapitole 6.

## Kapitola 2

# Biologie oka člověka

Pro určení nejlepších přístupů k vytvoření algoritmu pro klasifikaci kvality obrazu sítnice lidského oka je nutné určit základní údaje o fotografovaném objektu: oku.

Podkapitola 2.1 se zaměřuje na popsání základních částí oka pro získání potřebných fundamentálních znalostí pro struktury lidského oka. Důraz je kladen na samotnou sítnici a její hlavní části viditelných na snímcích sítnice.

Podkapitola 2.2 popisuje možné faktory, které mohou přímo ovlivnit kvalitu fotografie. Mezi tyto faktory patří zvláštnosti struktur oka, patologie a vady.

### 2.1 Stavba oka


Oko má přibližně tvar koule s průměrem cca 24mm a je uloženo v očnici člověka, v níž má možnost otáčení kolem své osy o cca  $\pm 30^\circ$ . Oko se principiálně skládá z optického aparátu, který zobrazuje na jeho sítnici převrácený a patřičně nedokonalý obraz vnějšího světa. V očnicích obou očí se nacházejí tři páry vnějších očních svalů, dále závěsný aparát, krevní a nervové zásobení očí.

Hlavní struktury oka popsané v literatuře jsou následující [6]:

- *Rohovka* je umístěna v př v přední části oka. Je to průhledná vazivová tkáň, která spolu s čočkou umožňuje lom světelných paprsků do oka. Její špatné zakřivení způsobuje astigmatismus.
- *Přední komora* je vyplněna nitrooční tekutinou, která je neustále obnovována.
- *Duhovka* má tvar mezikruží, jedna se o kruhovitě uspořádanou svalovinu která zužuje/rozšiřuje zornici.
- *Pupila* je otvor uprostřed duhovky, reguluje množství světla přicházejícího do oka.
- *Čočka* je zavěšená na řasnatém tělísku a má schopnost se vyklenovat, a tím měnit index lomu. Pokud čočka ztratí tuto schopnost, oko nemůže akomodovat (zaostřovat).
- *Sklivec* vyplňuje vnitřní část oka. Jedná se o rosolovitou, čirou hmotu.
- *Oční nerv* nese obrovský počet nervových vláken ústících do centrálního nervového systému.

Stěna oka v zadní části je tvořena třemi vrstvami:

## Stavba oka



Obrázek 2.1: Stavba oka člověka [33]

- *Oční bělmo (Bělíma)* – neprůhledná bílá tkáň, pokrývající celou oční kouli, která v přední části přechází v rohovku,
- *Cévnatka* – složitá soustava cév a vlasečnic vyživujících sítnici, která se nachází mezi bělímou a sítnicí a sestává ze tří na sebe vrstvených složek.
- *Sítnice* – tenká vrstva v zadní části oka obsahující citlivé na světlo buňky.

### 2.1.1 Stavba sítnice oka

Sítnice je tenkou (asi 0,2mm) průsvitnou blánou skládající se z deseti vrstev epitelů s fotoreceptory, má složitou, ale velice pravidelnou strukturu a tato blána zpracovává obrazové informace, které na ni dopadají z optického aparátu oka. Sítnice jako prvek uvnitř oka je dobře chráněný proti poškození. Vzor žil na sítnici oka je u každého člověka zcela unikátní, ale přímo struktura žil není geneticky závislá [15].

Při dopadu světla na sítnici se aktivují dva typy buněk. Tyčinky detekují světlo a tmu a pomáhají vytvářet obrazy za šera. Čípky jsou zodpovědné za barevné vidění. Tyto tři typy čípků se nazývají červený, zelený a modrý, ale každý ve skutečnosti detekuje rozsah vlnových délek a ne tyto specifické barvy.

V zadní části oka cca 18° od jeho vodorovné osy vystupuje zrakový nerv spojující sítnici s nervovými centry mozku. V místě vstupu nervu do sítnice je tzv. slepá skvrna (nebo také optický disk), která neobsahuje žádné fotoreceptory, a naopak tzv. žlutá skvrna (makula), která je situovaná uprostřed sítnice. Zajímavostí je, že žlutá skvrna ve skutečnosti není žlutá, ale je něco červenější než okolí. Tento přívlástek však skvrna dostala podle toho, že žlutou se jeví po smrti jedince. Její střední prohloubená část o průměru asi 1,5mm tvoří

tzv. centrální jamku (*fovea*) s nejvyšší rozlišovací schopností. Tyčinky mimo centrální jamky jsou z velké části zodpovědné za periferní vidění.

Tyčinky a čípky přeměňují světlo na elektrický signál, který je přenášen z optického nervu do mozku. Mozek převádí nervové impulsy do podoby obrazu. Trojrozměrné informace pocházejí z porovnání rozdílů mezi obrazy vytvořenými každým okem [15][6].

## 2.2 Vlastnosti oka, které ovlivňují hodnocení kvality

### 2.2.1 Které biologické faktory mohou ovlivnit kvalitu obrazu

Výsledná kvalita obrazu závisí na mnoha faktorech, včetně biologických. Mohou se lišit od člověka k člověku v závislosti na genetických rozdílech, zraněních a onemocněních oka. Mohou to být [19]:

- **Tvar a velikost oka.** Tvar a velikost oka mohou ovlivnit zaostření obrazu sítnice. Například osoba s kratší oční bulvou může mít více hypermetropické (dlouhozraké) vidění, zatímco osoba s delší oční bulvou může mít více myopické (krátkozraké).
- **Zakřivení rohovky.** Rohovka je čirý, kupolovitý povrch v přední části oka. Její zakřivení hraje zásadní roli při lomu (ohýbání) světla při vstupu do oka a příliš zakřivená nebo příliš plochá rohovka může způsobit rozmazané vidění.
- **Velikost a tvar zornice.** Zornice je malý kruhový otvor ve středu duhovky (barevná část oka), který umožňuje pronikání světla do oka. Velikost zornice může ovlivnit množství světla, které vstupuje do oka, a kvalitu obrazu sítnice.
- **Transparentnost očního média.** Oční médium jsou struktury v oku, které přenášejí světlo, včetně rohovky, komorové vody (čirá tekutina v přední části oka), čočky a sklivce (čirá gelovitá látka v zadní části oka). Jakékoli abnormality nebo opacity v těchto strukturách mohou způsobit rozmazané vidění a ovlivnit kvalitu obrazu sítnice.
- **Přítomnost jakýchkoliv abnormalit v sítnici.** Sítnice je vrstva citlivá na světlo v zadní části oka, která přeměňuje světlo na elektrické signály, které jsou přenášeny do mozku. Jakékoli abnormality nebo poškození sítnice, jako je věkem podmíněná makulární degenerace nebo odchlípení sítnice, mohou ovlivnit kvalitu obrazu sítnice.

### Oční úrazy a nemoci, které ovlivňují kvalitu obrazu

Výslednou kvalitu obrazu sítnice často ovlivňují úrazy vzniklé z nedbalosti nebo z jiných příčin a onemocnění, která oko člověka může mít. Vliv takových vad lze rozdělit do dvou skupin: obecné a strukturální - v souladu s tím, kterou částí obrazu ovlivňují.

Vady, které ovlivňují obecné částí obrazu sítnice, mohou být následující [19]:

**Astigmatismus** - zraková vada charakterizovaná nerovnoměrným zakřivením hemisféry rohovky a absencí jediného ohniska. Tato vada vede k přítomnosti zpravidla několika obrazů současně, překrývajících se na sobě. Díky takovému překrytí se na strukturách sítnice objeví neostře okraje, což snižuje ostrost obrazu.

**Kolobom** - vrozená nebo získaná vada v tkáních různých orgánů. V oftalmologii se projevuje jako komplexní nebo izolovaná absence části některých struktur oka: duhovky, cévnatky, víčka, zrakového nervu, řasnatého tělíška nebo čočky. Zejména kolobom duhovky

způsobuje abnormálně tvarovanou zornici, což vede k nerovnoměrnému osvětlení na fotografii sítnice.

**Šedý zákal** nebo **Katarakta** - patologický stav spojený se zakalením oční čočky a způsobující různé stupně poškození zraku až po její úplnou ztrátu. Zakalení čočky je způsobeno denaturací proteinu, který je její součástí. Taková vada vede k prudkému poklesu ostrosti obrazu a zhoršení osvětlení sítnice na fotografii. V těžších případech již není fotografování sítnice možné.

**Destrukce sklivce** - v zorném poli se objevují struktury různých velikostí a tvarů, pohybující se pohybem oka. Nejlépe vidět na rovnoměrně osvětleném bílém pozadí. Je to způsobeno zakalením vláken sklivce, které člověk pozoruje ve formě vláken, "smotků vlny", tečkovaných, granulárních, práškovitých, nodulárních nebo jehličkovitých inkluzí. Tento jev se nazývá "plovoucí opacity"(angl. *floaters*), "housenky" a dokonce "bakterie". Tyto útvary mohou způsobit nerovnoměrnost ostrosti a osvětlení na povrchu sítnice na fotografii díky optickým vlastnostem mírně odlišným od nitrooční tekutiny.

Vady, které ovlivňují strukturální částí obrazu sítnice, mohou být následující:

**Odchlípení sítnice** – nastává, když se sítnice oddělí od podložní tkáně oka. Sítnice je světlocitlivá vrstva buněk v zadní části oka, která přijímá a zpracovává vizuální informace. Když se sítnice oddělí, nemůže již správně fungovat, což vede ke zkreslenému nebo rozmazanému vidění, stejně jako k plovoucím a zábleskům světla. Z toho důvodu dochází k narušení povrchu lidské sítnice, což výrazně ovlivňuje přesnost strukturálních rysů kvality v důsledku zakřivení nebo nepřístupnosti potřebných struktur.

**Diabetická retinopatie** – komplikace cukrovky, která postihuje cévy v sítnici. Vysoká hladina cukru v krvi může poškodit krevní cévy v sítnici a způsobit jejich prosakování nebo ucpání. To může vést ke ztrátě zraku nebo slepotě, pokud se neléčí. Vede ke vzniku viditelných defektů na povrchu sítnice, které mohou být algoritmy vnímány jako další struktury, což snižuje přesnost výpočtu.

**Makulární degenerace** - stav, který postihuje centrální část sítnice, zvanou makula, která je zodpovědná za ostré centrální vidění. Makula se může časem poškodit nebo degenerovat, což vede ke ztrátě zraku nebo slepotě, pokud se neléčí. Má stejné důsledky na kvalitu obrazu jako diabetická retinopatie.

## Míra vlivu vad na vlastnosti kvality obrazu

Vzhledem k výše uvedeným informacím jsou strukturální rysy kvality náchylnější na vnější faktory, jako jsou defekty a nemoci. Stojí za to objasnit, že míra vlivu výše uvedených biologických faktorů nebyla dosud dostatečně prozkoumána. V rámci této práce se zaměříme jenom na obecné parametry kvality.

### 2.2.2 Výběr kanálu obrazu

Barvy pozorované v obrazu sítnice lidského oka závisí především na světle odraženém od různých struktur oka. Model přenosu záření (*angl. Radiation Transport Model*(RTM)[35] ukazuje, že přenos a odraz světla uvnitř oka závisí hlavně na koncentraci hemoglobinu a pigmentů melaninu v jeho strukturách. Vlastní červený odstín sítnice vzniká tím, že paprsky s dlouhou vlnovou délkou odpovídající červené (asi 680-700 nm [26]) nejsou absorbovány ani hemoglobinem, ani melaninem a jsou odráženy vrstvami mimo sítnici. To má za následek načervenalý vzhled obrazů na sítnici a také normálně přesvětlený červený kanál s nízkým kontrastem. Modré světlo je silně absorbováno hemoglobinem a melaninem a také oční čočkou. Výsledkem je normálně tmavý modrý kanál v obrazů sítnice člověka. Zelené světlo

je také absorbováno oběma pigmenty, ale v menší míře než modré světlo. Zejména struktury sítnice obsahující hemoglobin, jako jsou krevní cévy, absorbují více zeleného světla než okolní tkáň, což má za následek vysoký kontrast zeleného kanálu. RTM přímo vysvětluje teorii, která je základem dobře známé představy, že snímky sítnice mají přeexponované červené kanály, vysoce kontrastní zelené kanály a tmavě modré kanály.

Na základě těchto informací budou v tomto článku testovány dvě teorie:

- Zelený kanál bude nejvhodnější pro výpočet strukturálních rysů kvality obrazu, protože na něm bude výraznější kontrast struktur oka.
- Červený saturační kanál je nejvhodnější pro extrakci dat o osvětlení díky největšímu množství odraženého světla v této části spektra.

## Kapitola 3

# Hodnocení kvality obrazu sítnice

Bezprostřední oblast práce zahrnuje analýzu různých metod hodnocení kvality obrazu: objektivní a subjektivní metriky a samotné algoritmy pro hodnocení různých parametrů. V literatuře je popisována jako RIQA (angl. *Retinal Image Quality Assessment*) a je popsána v podkapitole 3.1.

V podkapitole 3.2 jsou popsány manuální metody hodnocení kvality obrazu, které jsou v této oblasti běžné.

V podkapitole 3.3 jsou popsány různé specifické algoritmy, které budou použity při analýze, a také další informace o strukturálních algoritmech.

### 3.1 Úvod do RIQA

#### Co je Retinal Image Quality Assessment

Pro kvalitu obrazu existují minimálně dvě definice. První se týká úrovně přesnosti, se kterou různé zobrazovací systémy zachycují, zpracovávají, ukládají, komprimují, přenášejí a zobrazují signály, které tvoří obraz. Jiná možná definice kvality obrazu je „vážené kombinace všech vizuálně významných atributů obrazu“ [2]. Rozdíl mezi těmito dvěma definicemi spočívá v tom, že jedna se zaměřuje na charakteristiky zpracování signálu v různých zobrazovacích systémech a druhá na percepční hodnocení, díky nimž je obraz pro člověka příjemný.

Proces stanovení úrovně přesnosti se nazývá hodnocení kvality obrazu (angl. *Image Quality Assessment* (IQA)). Hodnocení kvality obrazu je součástí měření kvality zážitků, které jsou založeny na potěšení nebo obtěžování lidských zážitků. Nejspolehlivější IQA je tedy sestavit výpočetní model napodobující lidský vizuální systém (angl. *Human Visual System* (HVS)) [14].

Kvalitu obrazu lze hodnotit pomocí dvou metod: subjektivní a objektivní. Subjektivní metody jsou založeny na percepčním posouzení vlastností obrazu nebo souboru obrazů lidským divákem. Objektivní metody jsou založeny na výpočtových modelech, které dokážou předpovědět percepční kvalitu obrazu. Objektivní a subjektivní metody nejsou nutně konzistentní nebo přesné mezi sebou: lidský divák může vnímat významné rozdíly v kvalitě mezi sadou obrázků, kde počítačový algoritmus nemusí.

Hlavní oblastí, kterou budeme v této práci zabývat, je určení kvality obrazu lidské sítnice.

### 3.1.1 Objektivní algoritmy pro RIQA

Objektivní RIQA algoritmy lze obecně klasifikovat jako algoritmy s úplnou referencí (*Full-Reference*), se sníženou referencí (*Reduced-Reference*) a bez referencí (*No-Reference*). Full-Reference algoritmy jsou vybaveny nedotčeným nepoškozeným stimulem spolu se stimulem, jehož kvalita má být měřena jako vstup [36]. Reduced-Reference algoritmy jsou poskytovány pouze s omezenými informacemi o původním stimulů spolu se poškozeným stimulem, kvalita kterého má být měřena [37]. No-Reference předpovídají kvalitu narušeného stimulu bez jakýchkoli informací o původním stimulů [21].

V této práci se No-Reference algoritmy stanou hlavním směrem této studie, protože sítnice oka se liší od člověka k člověku, což znamená, že není možné mít ideální (referenční) obraz sítnice.

## 3.2 Manuální metody RIQA

### 3.2.1 Mean Opinion Score

Po dlouhou dobu výzkumu v oblasti hodnocení kvality obrazu zůstává aktuální problém vývoje metod, které produkují výsledek blízký lidskému vnímání. Tento náročný úkol vyžaduje vývoj predikčních modelů, které algoritmicky mapují obraz na skóre reprezentující lidské úsudky o jeho vnímané kvalitě. Typické měřítko vnímané kvality obrazu je známé jako průměrné skóre názorů (angl. *Mean Opinion Score* (MOS)). MOS se získá tak, že požádáte pozorovatele, aby ohodnotili kvalitu snímků v určitém rozsahu (například v rozsahu 1-5).

Nejspolehlivější metodou pro hodnocení kvality snímků je subjektivní testování, protože lidští pozorovatelé (v našem případě oftalmologové a další lékaři) jsou konečnými uživateli většiny multimediálních aplikací. Při subjektivním testování je skupina lidí požádána, aby vyjádřila svůj názor na kvalitu každého obrázku. Za účelem provedení subjektivního testování kvality obrazu je navrženo několik mezinárodních standardů, zejména ITU [16]. Hlavní charakteristiky lze shrnout následovně [34]:

- Metody mohou být single-, double- nebo multi- stimulus, tj. s různým počtem testovacích snímků, které mají být porovnány v jednom pokusu. Více obrázků může být prezentováno současně (např. vedle sebe) nebo postupně.
- Počet zobrazení obrázku subjektům (jednou, dvakrát nebo dokonce vícekrát).
- Přítomnost referenčního obrázku, buď explicitně (subjekty vědí, který z nich je referenční), nebo skrytě.
- Subjekty mohou hodnotit pouze testovací snímek, testovací i referenční snímky, nebo rozdíl mezi nimi.
- V závislosti na interaktivitě procesu hlasování a provedení testu může jeden nebo více subjektů hodnotit snímky paralelně.

### 3.2.2 Single-stimulus a Double-stimulus metody

Single-stimulus metoda zahrnuje testování každého snímku pozorovatelem zvlášť [34]. Důležitým faktorem je přitom dodržení stejných testovacích podmínek s minimálním počtem



vnějších podnětů. Single-stimulus metoda je vhodnější pro určení kvality obrazu bez referenčního obrazu, ale v některých případech je implicitní přítomnost referenčního obrázku možná (například když byl referenční obrázek zobrazen na začátku testování).

Double-stimulus metoda je založena na tom, že pozorovatel porovnává dva obrazy současně [34]. Dva hlavní podtypy této metody jsou testování porovnání obrazu s referenčním obrazem a testování párového porovnání obrazu.

Důležitou proměnnou v kontextu takového testování je doba pozorování obrazu, jelikož úpravou tohoto parametru můžeme posunout zaměření pozorovatele od obecných parametrů kvality obrazu (jasnost, přítomnost potřebných struktur, osvětlení atd.) ke specifitějším (šum, rovnoměrnost ostroty atd.).

### 3.3 Rysy kvality

Mnoho různých faktorů, které mohou být přítomny na fotografii lidské sítnice, může ovlivnit výslednou kvalitu obrazu až po úplnou ztrátu potřebných informací, které mohou indikovat přítomnost onemocnění. V různých studiích[5][29] jsou rysy kvality obrazu rozděleny do dvou hlavních skupin: generické a strukturální.

#### 3.3.1 Generické rysy

Hodnocení kvality obrazu založené na obecných rysech obrazu používá obecné parametry, které lze často snadno vypočítat ve srovnání se strukturálními rysy, které závisí na strukturách sítnice oka člověka.


Existují různé skupiny algoritmů pro výpočet kvality určitých obecných charakteristik obrazu. Ty hlavní bych chtěl vyzdvihnout: ostrost, osvětlení, homogenita. V samostatném rohu jsou také charakteristiky, které lze extrahovat pomocí vlnkové transformace, protože tento algoritmus umožňuje extrahovat různé parametry od rovnoměrnosti osvětlení až po úroveň šumu obrazu.

#### Ostrost

Ostrost je jedním z nejdůležitějších parametrů obrazu, který ovlivňuje rychlost a kvalitu analýzy vzhledu lidské sítnice, což je nepochybně důležité při stanovení lékařské diagnózy. V tomto článku se budeme zabývat několika metrikami pro určení stupně ostroty obrázku. Přístupy jsou zaměřeny především na stanovení šířky hran a jsou založeny na měření charakteristik, které s tím přímo či nepřímo souvisejí.

#### Effective Number of Neighbors

První přístup, který se objevuje v literatuře, je použití míry efektivního počtu sousedů (Effective Number of Neighbors) popsané v článku Wen-Hung Liao z roku 2013 [20]. Navrhovaný odhad spočívá ve výpočtu míry ostroty obrazu z rozložení hran na obrázku. Hlavní myšlenkou je, že ostré snímky mají obvykle jasně definované okraje a jemné struktury, což má za následek ostré a izolované vrcholy po aplikaci detektoru hran, ve srovnání s rozmazanými snímky. Obrázek 3.1 ukazuje Sobelovu hranovou mapu původního (a) a Gaussova rozmazaného (b) obrázku. Je vidět, že okraje rozmazaného obrazu mají tendenci se shlukovat.



Obrázek 3.1: Sobelova hranová mapa původního obrazu Lena (a) a rozmazaná verze (b) [20]

Toto chování nám umožňuje vypočítat efektivní počet sousedů (ENN) pro každý hranový pixel v sousedním okně podle:

$$ENN(p) = \sum_{p' \in N_p, p' \neq p} \frac{I(p')}{d(p, p')} \quad (3.1)$$

Kde:

$$d(p, p') = |x - x'| + |y - y'| \quad (3.2)$$

$$I(p') = \begin{cases} 1, & \text{jestli } p' \text{ je hranový pixel} \\ 0, & \text{jinak} \end{cases} \quad (3.3)$$

V tomto případě budou mít neostré obrázky větší hodnoty ENN kvůli vyšší úrovni shlukování.

### Just Noticeable Blur

V roce 2009 Ferzliho studie [10] představila koncept Just Noticeable Blur (JNB) pomocí studií vnímání člověkem rozostření obrazu. Tento algoritmus založený na analýze hran a přilehlých oblastí v obrazech navržených Marzilianem a kol.[22]. Byl představen model popisující úroveň rozmazání obrazu:

$$P_{BLUR}(e_i) = 1 - \exp\left(-\left|\frac{w(e_i)}{w_{JNB}(e_i)}\right|^\beta\right) \quad (3.4)$$

$w(e_i)$  je naměřené okrajové rozpětí, jak je uvedeno v [22],  $w_{JNB}(e_i)$  je šířka „just noticeable blur“, která se získá v subjektivních experimentech měřením šířky rozmazaného okraje s různými Gaussovými standardními odchylkami. Jako jejich výsledek byla shrnuta následující závislost na úrovni kontrastu  $C$ :

$$w_{JNB} = \begin{cases} 5, & \text{jestli } C \leq 50, \\ 3, & \text{jestli } C > 50 \end{cases} \quad (3.5)$$

V rovnici 3.4, vzhledem k tomu, že  $w(e_i)$  odpovídá  $w_{JNB}(e_i)$ , dostaneme pravděpodobnost, která odpovídá pravděpodobnosti detekce rozmazání  $P_{BLUR} = P_{JNB} = 63\%$ .

Metrika 3.4 je založena na modelu, který předpokládá, že zhoršení rozostření se zvyšuje, když se zvyšuje  $P_{BLUR}$ . Metrika 3.4 však ignoruje skutečnost, že rozostření pravděpodobně nebude vnímáno, když je pod JNB.

Následně byl koncept v důsledku rozšířen v studie Narvekar a kol. [23] o Cumulative Probability of Blur Detection (CPBD). Prezentovaná metoda využívá této skutečnosti tím, že bere v úvahu hodnotu  $P_{BLUR}$  vzhledem k  $P_{JNB}$ , a popsána jako:

$$CPBD = P(P_{BLUR} \leq P_{JNB}) \quad (3.6)$$

Obě metody využívají aproximaci lidské foveální oblasti navrženou Ferzli a kol.: bloky  $64 \times 64$  pixelů. Vypočítají  $P_{BLUR}$  pro každý blok, pokud více než 0,2% z celkového počtu pixelů v bloku bylo klasifikováno jako hrany. Pravděpodobnost detekce zkraslení rozostření v každém z těchto bloků,  $P_{BLUR}$ , se používá v Minkowského metrice k odvození celkové ostrosti obrazu.

### Difference of differences

Ostrost obrazu může být často určena stupněm výraznosti hran obrazu. Tento výraz lze popsat jako rozdíl v intenzitách pixelů v oblasti přechodů. V souladu s tím, čím větší je rozostření v obrázku, tím menší je rozdíl v intenzitách při stejném měření. Tuto myšlenku využili Kumar a kol. ve svém výzkumu na téma hodnocení úrovně ostrosti obrazu v roce 2012 [17].

Navržená metrika je založena na výpočtu rychlosti přechodů v oblasti hraničních pixelů a je prezentována jako rozdíl v rozdílech (*angl. difference of differences*) ( $\Delta DoM$ ) v obrazu dříve filtrovaném od šumu.

Výpočet ( $\Delta DoM$ ) se provádí podle horizontální a vertikální osy odděleně pomocí rovnic:

$$\Delta DoM_x(i, j) = [I_m(i+2, j) - I_m(i, j)] - [I_m(i, j) - I_m(i-2, j)] \quad (3.7)$$

kde  $I_m(i, j)$  je hodnota ve stupních šedi pixelu umístěného na  $(i, j)$  v filtrovaném obrázku. V rámci této práce bude tato definice rozšířena na intenzitu pixelu v konkrétním kanálu obrazu, jako je barevný kanál, saturační kanál nebo jiné níže popsané kanály.

Dále se pro výpočet ostrosti okna kolem pixelu o velikosti  $2w+1$  používá poměr ( $\Delta DoM$ ) a kontrastu dané oblasti:

$$S_x(i, j) = \frac{\sum_{i-w \leq k \leq i+w} |\Delta DoM_x(k, j)|}{\sum_{i-w \leq k \leq i+w} |\Delta I_m(k, j) - I_m(k-1, j)|} \quad (3.8)$$

Pixel je považován za ostrý, pokud je ostrost  $S_x(i, j)$  větší než předem definovaný práh T. Ve studii Kumara a kol. hodnota T byla použita jako 0,0001, stejná hodnota bude použita i v této práci.

Dále se pro stanovení míry ostrosti obrazu používá poměr počtu ostrých pixelů k počtu všech hraničních pixelů:

$$R_x = \frac{\#sharpPixels_x}{\#edgePixels_x}, R_y = \frac{\#sharpPixels_y}{\#edgePixels_y} \quad (3.9)$$

Ostrost ve směrech x a y je kombinována pomocí Frobeniusovy normy, aby se získala celková ostrost obrazu:

$$S_I = \sqrt{R_x^2 + R_y^2} \quad (3.10)$$

Maximální hodnota  $S_I$  je  $\sqrt{2}$ , když jsou všechny okrajové pixely v obou směrech detekovány jako ostré.

### Inherentní ostrost

Nezbytnou součástí rysů kvality jsou rysy založené na vlnkové transformaci. Jedním z takových algoritmů je metoda navržená Ryu a kol. [30]. Prezentovaná metrika je založena na konceptu inherentní ostrosti (angl. *inherent sharpness* (InS) a generuje vnímané skóre ostrosti založené na vlnkových koeficientech.

Tým studoval odezvu HVS na ostrost v obrazech obsahujících různé prostorové aktivity a odhalil, že vnímaná ostrost se zvýšila jako funkce vysokofrekvenční složky (VF) pro nízké i vysoké prostorové aktivity. Snímky obsahující stejnou VF, ale různé prostorové aktivity však poskytují rozdílnou vnímanou ostrost. Výsledkem je, že množství VF potřebné ke zvýšení vnímané ostrosti je relativně úměrné prostorové aktivitě.

Prostorovou aktivitu pojmenovali Ryu a kol. jako inherentní ostrost (InS) a lze ji popsat následovně:

$$InS = \frac{1}{MN} \sum_i \sum_j m_k(i, j), \quad (3.11)$$

$$m_k(i, j) = \max(M_k(i, j)) - \min(M_k(i, j)), \quad (3.12)$$

$$M_k(i, j) = \{X(i+x, j+y) \mid -1 < x, y < 1\} \quad (3.13)$$

kde  $m_k(i, j)$  je morfologický gradient umístění  $(i, j)$ ,  $X$  je vstupní obrázek a  $M, N$  jsou horizontální a vertikální velikosti obrázku.

Navrhovaná metrika ostrosti využívá diagonální koeficienty vlnkových rozkladů. Vzhledem k tomu, že svislé a vodorovné detaily jsou závislé na svislých nebo vodorovných hranách, které se obraz od obrazu velmi liší, představují diagonální detaily obecnější vlastnosti, a proto jsou pro tuto metriku užitečnější. Diagonální vlnkové koeficienty lze vypočítat následovně:

$$w_{HH}(u, v) = \sum_{i=0}^K \sum_{j=0}^K \psi_{HH}(i, j) \cdot X(2u-i, 2v-j) \quad (3.14)$$


kde  $\psi_{HH}(i, j)$  je diagonální vlnková funkce složená ze dvou impulsních odezev horizontálních a vertikálních horních propustí.  $X$  je vstupní obraz a  $w_{HH}(u, v)$  jsou vypočtené diagonální koeficienty.

Poté je vypočítána síla diagonálních koeficientů,  $W$ , a normalizována pomocí  $InS$  3.11, aby se zohlednil vliv prostorových aktivit na vnímanou ostrost. V souladu s tím může být ostrost  $S$  vypočtena jako:

$$S = \frac{\sum_i \sum_j m_k(i, j)}{\sum_u \sum_v |w_{HH}(u, v)|^2} \quad (3.15)$$

## Osvětlení

Různé úrovně osvětlení v obrazu lidské sítnice mohou ovlivnit viditelnost struktur sítnice a viditelnost symptomů onemocnění. Úroveň kontrastu může v důsledku, ne-li zkrátit, ale výrazně snížit přesnost analýzy obrazu neuronovými sítěmi nebo samotnými lékaři. V práci Abdel-Hamid a kol. [1], na základě údajů z článku Forachia a kol. [11] bylo ukázáno, že vlnková aproximace subpásma L4 sestává prakticky pouze z informace o osvětlení. V souladu s tím rysy kvality založené na L4 RGB vlnkové transformace mají největší vliv na kvalitu obrazu.



Obrázek 3.2: Příklady snímků sítnice s různým osvětlením: dobře osvětlené (první řada), přesvětlené (druhá řada) a nedostatečně osvětlené (třetí řada). Zleva doprava: barevný obrázek, červený kanál, zelený kanál, modrý kanál [1].

Obrázek 3.2 ukazuje příklady RGB kanálů při různých úrovních osvětlení: dobře osvětlené, přesvětlené a nedostatečně osvětlené. Na příkladu těchto snímků je vidět, že změna osvětlení ovlivňuje každý jednotlivý kanál ve stejné míře. V předchozích studiích byly k hodnocení kvality osvětlení v obraze použity informace z kanálů RGB. Yu a kol. [43] identifikovali sedm hlavních charakteristik (střední hodnota, rozptyl, šikmost a špičatost kumulativní distribuční funkce) obrazu na základě dat z histogramů různých kanálů. V tomto článku bude analyzován vliv každého z těchto parametrů na kvalitu obrazu.

## Střední hodnota

Střední hodnota kumulativní distribuční funkce (KDF) je očekávaná hodnota náhodné proměnné spojené s KDF. Jinými slovy, je to dlouhodobá průměrná hodnota náhodné veličiny.

Pro spojitou náhodnou veličinu  $X$  s KDF je  $F(x)$  střední hodnota definována jako:

$$\mu = \int_{-\infty}^{\infty} xf(x)dx \quad (3.16)$$

## Rozptyl

Rozptyl KDF je mírou rozptylu distribuce. Je to míra míry, do jaké jsou hodnoty náhodné proměnné spojené s KDF rozptýleny kolem průměru distribuce.

Rozptyl spojitě náhodné veličiny  $X$  s  $F(x)$  a střední hodnotou  $\mu$  je definován jako:

$$\sigma^2 = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx \quad (3.17)$$

## Šikmost

Šikmost je mírou symetrie KDF. Je to míra míry, do jaké jsou hodnoty náhodné veličiny distribuovány asymetricky kolem střední hodnoty rozdělení.

Šikmost KDF lze vypočítat jako:

$$Skew[X] = \frac{E[(X - \mu)^3]}{\sigma^3} \quad (3.18)$$

kde  $E[(X - \mu)^3]$  je třetí centrální moment distribuce.

Distribuce s kladnou šikmostí se říká, že je šikmá doprava, což znamená, že má dlouhý ocas na pravé straně distribuce a kratší ocas na levé straně. Distribuce s negativní šikmostí se říká, že je šikmá doleva, což znamená, že má dlouhý ocas na levé straně distribuce a kratší ocas na pravé straně. Distribuce se šikmostí 0 se nazývá symetrická, což znamená, že je rovnoměrně vyvážená na obou stranách distribuce.

## Špičatost

Špičatost je to míra „sledovitosti“ distribuce, přičemž vysoká špičatost ukazuje na vrcholovější nebo užší distribuci a nízká špičatost označuje plošší nebo širší distribuci.

Špičatost KDF lze vypočítat jako:

$$Kurt[X] = \frac{E[(X - \mu)^4]}{\sigma^4} \quad (3.19)$$

kde  $E[(X - \mu)^4]$  je čtvrtý centrální moment rozdělení.

Distribuce s vysokou špičatostí bude mít více špičatý tvar, zatímco distribuce s nízkou špičatostí bude mít plošší tvar. Špičatost normálního rozdělení je 3, což je považováno za "normální" nebo "typickou" hodnotu špičatosti. Distribuce s hodnotami špičatosti nad 3 jsou považovány za leptokurtické, zatímco distribuce s hodnotami špičatosti pod 3 jsou považovány za platykurtické.

## Homogenita

Dobré osvětlení je důležité pro nejlepší kvalitu obrazu lidské sítnice. Struktura oka je velmi složitá, což může vést k nerovnoměrnému osvětlení. V důsledku toho může být v různých oblastech obrazu narušena ostrost a viditelnost struktur sítnice oka, což může ovlivnit spolehlivost lékařské diagnózy. Z toho vyplývá, že důležitým faktorem je homogenita osvětlení.

Ve většině literatury se k určení homogenity používají tzv. texturní rysy [4][28], které bohužel nejsou dostatečně přizpůsobeny pro snímky lidské sítnice a mohou být při výpočtech velmi náročné na zdroje [3]. Mnohem relevantnější rysy homogenity osvětlení byly

prezentovány v Abdel-Hamid a kol.[1]. Oni představují dva možné přístupy: založené na saturačním kanálu a založené na vlnkové transformaci.

### Rysy homogenity saturačního kanálu

Obrázky, které mají jednu dominantní barevnou složku, mají obvykle jeden nejjasnější barevný kanál, který má také nízký kontrast. Tuto skutečnost můžeme využít ke zkoumání homogenity osvětlení zkoumáním saturačního kanálu (sytosti) dominantní barevné složky. Sytost je podle definice barevnost barvy vzhledem k jejímu vlastnímu jasu[9]. V barevném modelu HSV se sytost vypočítává jako nejdominantnější z kanálů RGB s ohledem na nejméně převažující barvu, jak je dáno následující rovnicí:


$$S_{HVS} = \frac{\max(R, G, B) - \min(R, G, B)}{\max(R, G, B)} \quad (3.20)$$

Abdel-Hamid a kol. pro lepší znázornění saturace jednoho kanálu se navrhuje vypočítat ji na základě rozdílu dominantní složky k ostatním dvěma následovně:

$$S = \begin{cases} \frac{D-S_1}{D} * \frac{D-S_2}{D}, & \text{pro } D > 0 \\ 0, & \text{pro } D = 0 \end{cases} \quad (3.21)$$

Kde  $D$  je dominantní složka a  $S_1, S_2$  jsou ostatní.


Obrázek 3.3 ukazuje příklady různých stupňů homogenity osvětlení. Dobře osvětlené obrazy (řádky 1 a 2) mají rozložení intenzity pixelů kanálu saturace dominantní složky podobné Gaussovu rozložení umístěnému uprostřed histogramu. Nehomogenní snímky lidské sítnice (řádky 3 a 4) mají zároveň zakřivený tvar posunutý doprava. Toto chování nám umožňuje vytvořit sadu rysů pro určení kvality homogenity osvětlení obrazu. Zahrnuje standardní sadu rysů charakterizujících rozložení, které byly popsány dříve v části o osvětlení 3.3.1, a také procentuální míru počtu pixelů umístěných ve středu histogramu saturačního kanálu.



Obrázek 3.3: Příklady fotografií lidské sítnice s různou úrovní homogenity. Zleva doprava: původní snímek, saturační kanál dominantní složky, histogram saturačního kanálu [1]

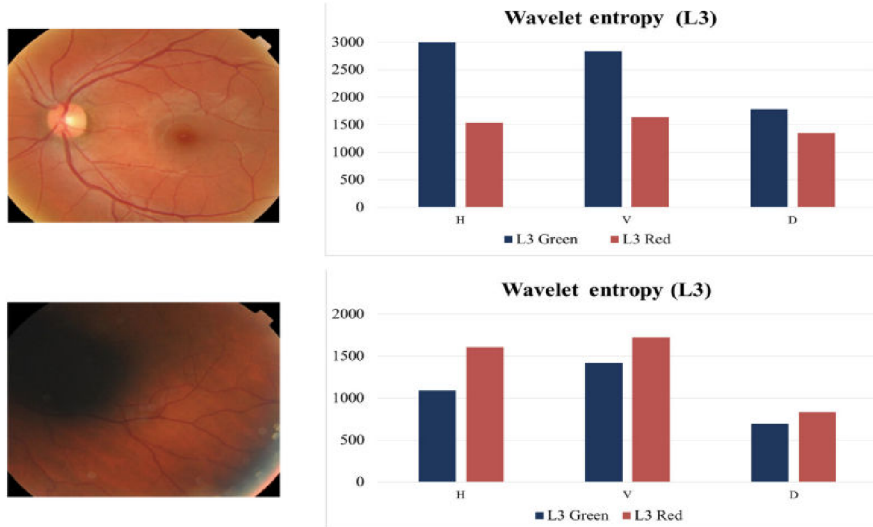
### Rysy homogenity založené na vlnkové transformaci

Jak vysvětluje teorie RTM shrnutá v 2.2.2, typicky zelený kanál snímků sítnice má vyšší kontrast než přesycený červený kanál. Vyšší kontrast zeleného kanálu určí ekvivalentně vyšší informační obsah, který lze měřit vlnkovou entropií L3 podpásma. Tak pro dobře osvětlené obrazy sítnice, vlnkové entropie L3 zeleného kanálu je běžně větší než u podrobných podpásem červeného kanálu. Rozdíly v osvětlení v obrazech sítnice však jsou výraznější v červených než zelených kanálech jak je vidět na obrázku 3.4. Proto nehomogenní sítnice obrázky mají tendenci ukazovat větší vlnkové entropie červeného kanálu než vlnkové entropie zeleného kanálu. Obrázek 3.5 ukazuje příklady homogenních a nehomogenních obrázky spolu s jejich zelenými a červenými vlnkovými entropiemi L3. Rozdíl mezi červeným a zeleným kanálem L3 vlnkové entropie lze tedy využít i k určení homogenity obrazu.



Obrázek 3.4: Nehomogenně osvětlená fotografie sítnice. Barevný obrázek (a), červený kanál (b), zelený kanál (c). [1]





Obrázek 3.5: Zleva doprava: barevný obraz, vlnkové entropie zeleného a červeného kanálu L3 horizontální, vertikální a diagonální podpásma. [1]

Nirmala a kol.[25] ve své práci určili, že informace týkající se velkých cév sítnice se nejlépe zobrazují v podpásmu L3, kdy L1 má minimum informací souvisejících se strukturami sítnice. Výsledkem je, že homogenně osvětlené obrazy mají mnohem vyšší entropii na L3 než na L1. V případě nekvalitně nasvíceného obrazu má podpásmo L1 mnohem více informací, L3 naopak méně. Homogenní obrazy mají tedy větší poměry  $\text{WaveletEntropyL3}/\text{WaveletEntropyL1}$  než nehomogenní obrazy.

### 3.3.2 Strukturální rysy

Spolu s metodami, které používají obecné parametry obrazu, které byly popsány výše, existuje skupina algoritmů založených na strukturálních vlastnostech oka. Tyto specifické přístupy využívají rysy vlastní pouze obrazům sítnice lidského oka, a konkrétně jejich struktury. Viditelnost hlavních struktur je základním faktorem kvality fotografie. Tato závislost jednak činí metody více přizpůsobené pro obrazy sítnice a jednak zvyšuje složitost nejen ve výpočtech, ale také při určování kvality obrazu poškozené sítnice, protože oční choroby, různé patologie a úrazy výrazně zkreslují výsledky strukturálních metod.

Pro určení kvality celého obrazu, stojí za to vzít struktury, které se nacházejí na co největší ploše oka a nejlépe se spoustou detailů. V rámci této práce se budeme zabývat jednou hlavní skupinou metod. Jedním z hlavních směrů ve vývoji algoritmů pro RIQA založených na strukturálních vlastnostech oka jsou metody pro určování kvality obrazu měřením oblasti pokrytí obrazu cévami oka. V tomto směru byla provedena řada studií [18][32][36].

#### Rysy kvality založené na segmentaci cév

Köhler a kol.[18] navrhli metodu založenou na váženém měření úrovně šumu a rozostření v obraze. Váha každého segmentu obrazu byla určena stupněm jeho příslušnosti k cévám, vypočítaným pomocí míry navržené Frangi a kol. [12].

Jako základ pro měření hluku a neostrosti byla vzata míra navržená Zhu a kol. [44] v roce 2010:

Nechť  $\mathbf{I}$  je obrázek ve stupních šedi o velikosti  $M \times N$ .  $\mathbf{I}$  rozložíme na sadu odlišných patchů, přičemž každý patch  $\mathbf{P}$  má velikost  $n \times n$ . Lokální gradientová matice  $\mathbf{G}$  o velikosti  $n^2 \times 2$  pro  $\mathbf{P}$  je dána vztahem:

$$\mathbf{G} = \begin{pmatrix} P_x(1,1) & P_y(1,1) \\ \vdots & \vdots \\ P_x(n,n) & P_y(n,n) \end{pmatrix} \quad (3.22)$$

kde  $P_x(x_i, y_i)$  a  $P_y(x_i, y_i)$  označuje derivaci  $\mathbf{P}$  v pixelu  $(x_i, y_i)$  v  $x$ - a  $y$ - směru. Dekompozice singulární hodnoty  $\mathbf{G}$  je dána vztahem:

$$\mathbf{G} = \mathbf{U} \mathbf{D} \mathbf{V}^T = \mathbf{U} \begin{pmatrix} s_1 & 0 \\ 0 & s_2 \end{pmatrix} \mathbf{V}^T \quad (3.23)$$

pro ortogonální matice  $\mathbf{U}$  a  $\mathbf{V}$  a singulární hodnoty  $s_1, s_2$ . V [44] je ukázáno, že místní metrika kvality pro kvantifikaci obrazového šumu a rozostření v anizotropní oblasti  $\mathbf{P}$  je dána:

$$q(\mathbf{P}) = s_1 \cdot R \quad (3.24)$$

kde  $R$  označuje koherenci:

$$R = \frac{s_1 - s_2}{s_1 + s_2} \quad (3.25)$$

Obrázky s lepší kvalitou s pohledu šumu a rozostření budou mít větší hodnoty  $q(\mathbf{P})$ . Pro získání celkového šumu a rozostření se všechny  $q(\mathbf{P})$  sečtou ze všech anizotropních patchů a normalizují se následovně:

$$Q = \frac{1}{MN} \sum_{i,j:\mathcal{P}(i,j)=1} q(\mathbf{P}_{ij}) \quad (3.26)$$

kde  $\mathcal{P}(i, j)$  označuje mapu patchů pro obrázek  $\mathbf{I}$  tak, že  $\mathcal{P}(i, j) = 1$ , pokud  $\mathbf{P}_{ij}$  je anizotropní.

Jedním z hlavních problémů této metody je automatická detekce anizotropních patchů. Köhler a kol. navrhuje pro jejich konstrukci použít strom sítnicových cév, protože hranice cév jsou poměrně dobře definovány na pozadí jiných struktur sítnice.


K definování cév používá se zelený kanál ( $\mathbf{I}_g$ ) obrázku  $\mathbf{I}$ , protože má nejvyšší kontrast (2.2.2) ve srovnání s jinými kanály. Pro každý pixel  $s$  ( $\mathbf{I}_g$ ) se vypočítá lokální Hessova matice:

$$\mathbf{H} = \begin{pmatrix} \frac{\delta d^2 \mathbf{I}_g}{\delta x^2} & \frac{\delta d^2 \mathbf{I}_g}{\delta x \delta y} \\ \frac{\delta d^2 \mathbf{I}_g}{\delta x \delta y} & \frac{\delta d^2 \mathbf{I}_g}{\delta y^2} \end{pmatrix} \quad (3.27)$$

Pro detekci krevních cév byla použita míra "cévnosti" navržená Frangi a kol. [12] následujícím způsobem:

$$V = \exp\left(-\frac{\lambda_1^2}{\lambda_2^2}\right) (1 - \exp(-(\lambda_1^2 + \lambda_2^2))) \quad (3.28)$$

kde  $\lambda_1$  a  $\lambda_2$  jsou vlastní hodnoty  $\mathbf{H}$  a  $\lambda_1 \leq \lambda_2$ .  $V$  zde představuje míru pravděpodobnosti, kde velké hodnoty indikují vysokou pravděpodobnost umístění pixelů na krevní cévě (Obrázek 3.6). Aby se odstranily nepotřebné fragmenty, používá se práh  $V_0$  pro pravděpodobnost  $V$ . Köhler a kol. použili hodnotu 80. percentilu pro všechny nenulové rozměry  $V$ .



Obrázek 3.6: Příklad barevného snímku (a) a vypočítaná míra pro detekci krevních cév (b) [18]

Výsledná metrika je kombinací anizotropních patchů umístěných v hranicích stromu krevních cév a je definována takto:

$$Q_v = \sum_{i,j:\mathcal{P}(i,j)=1} \sum'_{ij} \cdot q(\mathbf{P}_{ij}) \quad (3.29)$$

kde  $\sum'_{ij}$  označuje normalizovaný lokální rozptyl míry cévnatosti v patchi  $\mathbf{P}_{ij}$ . Zde je  $\sum'_{ij}$  určeno výpočtem rozptylu cévnatosti  $V$  v  $\mathbf{P}_{ij}$ , kde se normalizace provádí pomocí takového celkového čísla patchů, že  $\sum \sum'_{ij} = 1$ . Patchi  $\mathbf{P}_{ij}$  umístěné na hranici krevních cév označených velkým  $\sum'_{ij}$  tedy mají vyšší dopad na celkový odhad šumu a rozmazání obrazu.

## Kapitola 4

# Návrh algoritmů

Návrh algoritmu spočívá ve správném výběru rysů kvality, které se mají použít. K tomu je třeba určit, jak lze jejich výkonnost vyhodnotit a porovnat s ostatními.

Podkapitola 4.1 je věnována popisu technik hodnocení účinnosti algoritmů.

Metody výběru rysů kvality na základě dat o výkonnosti algoritmů jsou popsány v podkapitole 4.2.

Poslední podkapitola 4.3 popisuje hlavní kroky analýzy, které budou v této práci použity pro výběr nejlepší kombinace parametrů kvality obrazu.

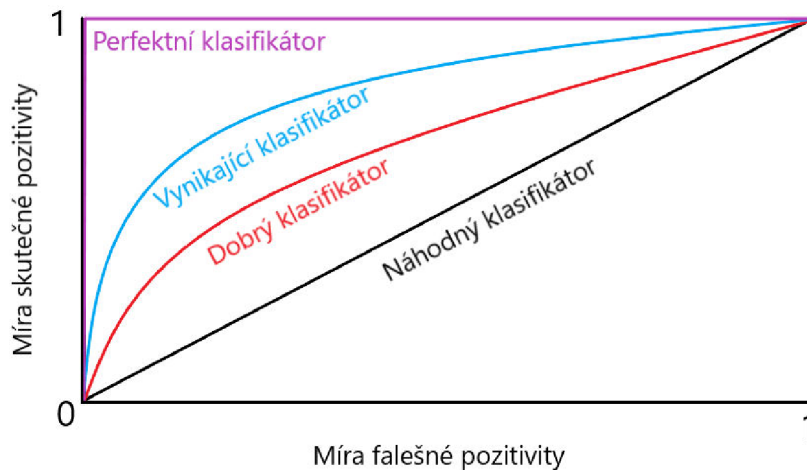
### 4.1 Techniky hodnocení výkonnosti algoritmů

Kontext této práce zahrnuje vývoj algoritmu pro hodnocení kvality obrazu, který bude použit v automatické stanici, která bude schopna pracovat bez jiných lékařů. V souladu s tím jsou základní charakteristiky algoritmu, jako je účinnost a rychlost. V tomto článku bude měřítkem účinnosti algoritmu statistická míra AUC (angl. *area under the curve*) a mírou rychlosti bude doba výpočtu.

#### Area under the curve

AUC je měřítkem kvality binárního klasifikátoru, který na základě vstupních dat určuje, zda jsou data objektem určité třídy či nikoli.

AUC se vypočítá s grafu míry skutečné pozitivity (angl. *true positive rate* (TPR)) a míry falešné pozitivity (angl. *false positive rate* (FPR)) při různých nastaveních prahů. TPR je podíl případů, které jsou správně klasifikovány jako pozitivní mezi všemi pozitivními instancemi, zatímco FPR je podíl případů, které jsou nesprávně klasifikovány jako pozitivní, mezi všemi negativními instancemi. Křivka ROC (angl. *receiver operating characteristic*) je grafem TPR proti FPR pro různé prahové hodnoty klasifikace a AUC je plocha pod touto křivkou.



Obrázek 4.1: ROC pro různé klasifikátory

Metriku AUC lze interpretovat jako pravděpodobnost, že klasifikátor zařadí náhodně vybraný pozitivní výskyt výše než náhodně vybraný negativní výskyt. AUC se pohybuje mezi 0 a 1, kde hodnota 1 představuje dokonalý klasifikátor a hodnota 0,5 představuje klasifikátor, který není lepší než náhodné hádání. Klasifikátor s AUC 1 bude mít ROC křivku, která obepíná levý horní roh grafu, což indikuje TPR 1 a FPR 0. Na druhou stranu klasifikátor s AUC 0,5 bude mít ROC křivku to je diagonální čára z levého dolního rohu do pravého horního rohu.

AUC je široce používaná metrika pro hodnocení výkonu binárního klasifikátoru, protože není ovlivněna nerovnováhou tříd. To znamená, že není ovlivněn rozdílem v počtu instancí ve dvou třídách. Je také necitlivý na práh používaný pro klasifikaci instancí.

V rámci této práce není klasifikace obrázků nutně binární. K určení účinnosti algoritmu se proto použije variace pro vícetřídní AUC vytvořením ROC pro klasifikaci typu *One-VsMany* (buď je třída X, nebo ne). V souladu s tím se vypočte tolik AUC, kolik je tříd, a jako výsledek se pak vezme průměrná AUC.

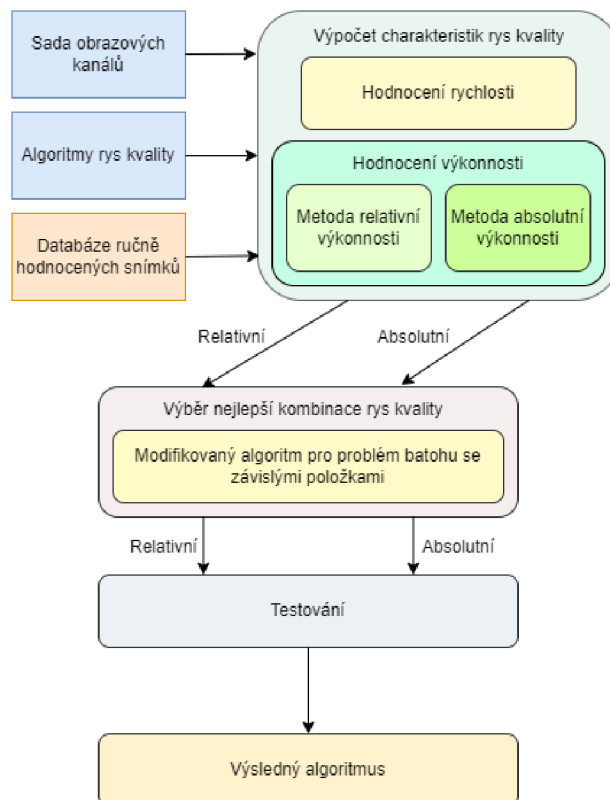
### Výběr prahových hodnot

Pro co nejlepší definici třídy kvality hodnoceného obrázku je nutné nastavit optimální prahové hodnoty pro náš klasifikátor. Tyto hodnoty by měly vést k nejvyšší specificitě a citlivosti. Proto bude pro výběr nejlepší prahové hodnoty použit geometrický průměr těchto parametrů.

$$\begin{aligned}
 G_{mean} &= \sqrt{\text{Citlivost} \cdot \text{Specificita}} \\
 &= \sqrt{TPR \cdot \frac{TN}{FP + TN}} \\
 &= \sqrt{TPR \cdot \left(1 - \frac{FP}{FP + TN}\right)} \\
 &= \sqrt{TPR \cdot (1 - FPR)}
 \end{aligned}
 \tag{4.1}$$

kde  $TPR$  je míra skutečné positivity a  $FPR$  je míra falešné positivity.

Hledání optimální hraniční hodnoty spočívá v nalezení bodu na ROC s největší hodnotou geometrického průměru citlivosti a specificity.



Obrázek 4.2: Postup vytváření algoritmu

## 4.2 Metody výběru rysů kvality pro algoritmus

Algoritmus bude postaven na základě souboru rysů kvality. V této práci je rys kvality definovaný jako dvojice vstupního obrazového kanálu a odpovídajícího algoritmu. Pro výběr nejlepší kombinace rysů kvality budou použity dva přístupy pro jejich výběr: metoda relativní výkonnosti a metoda absolutní výkonnosti. Každá z těchto metod na základě AUC a doby výpočtu pro každý rys kvality vybere nejlepší sadu párů algoritmů a obrazových kanálů. Postup vytvoření výsledného algoritmu je znázorněn na obrázku 4.2.

### 4.2.1 Metoda relativní výkonnosti

Tato metoda zahrnuje přímé porovnání rysů kvality na základě jejich váhy ve výsledku a jejich rychlosti.

Pro stanovení míry ovlivnění jednotlivých kombinací algoritmů a kanálů byla použita metoda částečných nejmenších čtverců (PLS)[41][39][40]. Snímky byly ohodnoceny pomocí MOS (3.2) a tyhle a skóre byli převedené na číselné hodnoty pro použití v PLS analýze. Tato skóre sloužila jako závislá proměnná, zatímco dříve zmíněné rysy byly použity jako nezávislé prediktorové proměnné. PLS byl poté využit k vytvoření lineární regresní rovnice, která generuje spojité skóre kvality.

PLS je extrémně účinná metoda pro stanovení vztahu mezi jednou nebo více závislými proměnnými a sadou nezávislých prediktorových proměnných. Existují však i jiné metody

předpovídání kvality založené na nezávislých proměnných, ale některé nemusí v určitých situacích dobře fungovat, například když je přítomna multikolinearita. Multikolinearita je stav, ke kterému dochází, když jsou některé z nezávislých proměnných navzájem vysoce korelované. V tomto konkrétním případě má stejná vlastnost aplikovaná na různé barevné kanály tendenci vysoce korelovat, i když se jejich velikosti liší. Proto je problém zajištění kvality při použití společné sady funkcí vysoce multikolineární.

Výběr kombinací párů algoritmů a obrazových kanálů se provádí pomocí algoritmu pro problém batohu (Knapsack problem) s řadou drobných úprav. Míra vlivu algoritmu bude variací hmotnosti objektů v původní formulaci problému batohu a rychlost bude cenou (čím rychlejší, tím cennější). Odtud bude výsledným cílem vybrat nejhodnotnější kombinaci, která přispívá největší váhou (například 90%).

#### 4.2.2 Metoda absolutní výkonnosti

Tato metoda nevypočítá relativní dopad, ale vezme v úvahu absolutní výkonnost rysu kvality obrazu. Výkonnost algoritmu bude určena pomocí AUC. Výběr nejlepší kombinace bude proveden podobně jako v předchozím přístupu: s použitím upraveného algoritmu pro problém batohu se závislými položkami (tentokrát bude vahou celková normalizovaná účinnost algoritmu), nebo založené pouze na hodnotách AUC.

Oba přístupy budou použity při výběru nejlepší kombinace parametrů, jejímž výsledkem bude klasifikátor. Jedním z cílů této práce bude porovnat tyto výběrové algoritmy a určit nejlepší metodu, případně shromáždit data, na jejichž základě bude možné vytvořit pokročilejší výběrový algoritmus.

### 4.3 Etapy analýzy

Popis procesu výběru rysů kvality pro algoritmy kvality obrazu lidské sítnice nebyl dosud v literatuře uveden, proto má smysl popsat konkrétní kroky a metody, které budou použity v této práci. Analýzu algoritmů popsanych v teorii lze rozdělit do 5 hlavních etap:

#### 4.3.1 První etapa: Sběr primárních dat

Prvním krokem je shromáždění dat z existujících databází a jejich modifikací (např. s různými úrovněmi komprese obrazu nebo jiným předzpracováním). Čím více různých modifikací databází se nám podaří shromáždit - tím lépe, takže důležitou součástí budou v budoucnu metody kombinování výsledků dohromady. Základní myšlenkou zavedení několika databází s různým předzpracováním je analýza vlivu té či oné úpravy obrazu, která by určila závislosti mezi výkonností jednotlivých algoritmů a danou úpravou. Na rozdíl od implementace předzpracování do rysů kvality obrazu, tento přístup má přednost, protože dodatečné předzpracování zabudované do samotných algoritmů výrazně zpomalí proces analýzy jednotlivých kombinací parametrů.

Hlavními údaji, které budou potřeba k určení nejlepší kombinace parametrů, jsou:

- Seznam možných tříd kvality.
- Pole vrácených hodnot pro každý parametr kvality pro každý obrázek.
- Pole časů výpočtu pro každý parametr kvality pro každý obrázek.

Tyto údaje postačí k provedení všech základních výběrů parametrů, neboť je lze použít nejen samostatně v metodách, jako je metoda relativního výkonu 4.2.1 a metoda absolutního výkonu 4.2.2, ale také k výpočtu dalších možných souhrnných parametrů (průměrná doba výpočtu, počet správně klasifikovaných snímků).

### 4.3.2 Druhá etapa: Analýza primárních dat

Dalším krokem je primární analýza, jinými slovy analýza neopracovaných dat. Ta bude zahrnovat výpočet různých agregovaných parametrů, jako je AUC, koeficienty z PLS analýzy, výpočet průměrného času pro každý rys kvality.

#### Výpočet AUC

Možnost existence více než dvou možných tříd kvality obrazu (např. 'Dobrá', 'Použitelná', 'Odmítnout') si vynucuje definici způsobu výpočtu této metriky pro každý parametr. V kontextu této práce se předpokládá, že možný rozsah hodnot kvality obrazu lze nastavit jako 0 až 1. Přímé použití strategie *OneVsMany* by tedy nebylo správné, protože hodnoty tříd jsou ve stejné dimenzi. Proto byla tato strategie upravena tak, aby neporovnávala jednu třídu se všemi ostatními třídami, ale jednu třídu se všemi horšími ostatními třídami. Máme-li tedy například třídy A, B, C a D, kde A je nejlepší a D nejhorší, algoritmus je následující:

1. Výpočet AUC pro klasifikátor "A nebo B,C,D" na obrazech s třídami kvality A,B,C a D.
2. Výpočet AUC pro klasifikátor "B nebo C,D" na obrazech s třídami kvality B,C a D.
3. Výpočet AUC pro klasifikátor "C nebo D" na snímcích s třídami kvality C a D.
4. Výpočet konečné hodnoty AUC jako průměru mezi předchozími třemi hodnotami.

V této práci bude k výpočtu AUC použit pouze výše popsáný algoritmus.

Může se také stát, že parametr má obrácený vztah a má vyšší hodnotu pro nejhorší fotografie. V takových případech bude hodnota AUC v této práci přepočítána jako  $1 - AUC$  s poznámkou, že vztah je obrácený.

#### Výpočet PLS koeficientů

Aby analýza PLS fungovala správně, musí být vrácené parametry před předáním dat algoritmu normalizovány na rozsah 0 až 1, jinak může dojít k neproporcionálním koeficientům. Normalizace se provede pro každý existující parametr zvlášť, nikoli pro všechny najednou.

V této práci bude k výpočtu nejlepších koeficientů použit algoritmus SIMPLS, přičemž počet hlavních komponent bude zvolen tak, aby byla minimalizována chyba. Pro další výběr rysů kvality budou vypočtené PLS koeficienty normalizovány na rozsah 0 až 1 a se součtem 1 následujícím způsobem:

1. Vypočítá se součet absolutních hodnot koeficientů.
2. Každý koeficient se přepočítá jako jeho absolutní hodnota vydělená tímto součtem.

Absolutní hodnota se používá proto, aby bylo možné porovnávat parametry s přímým i opačným vztahem. Tímto způsobem se tato analýza PLS stává necitlivou na znaménko závislosti jednotlivých rysů kvality.



### 4.3.3 Třetí etapa: Analýza předběžného zpracování a slučování statistik

Po prvotní analýze dat je možné porovnat, do jaké míry má konkrétní předběžné zpracování databáze vliv na samotné parametry kvality. Hlavním způsobem bude porovnání průměrných hodnot AUC pro jednotlivé parametry ve všech obrazových kanálech. Tímto způsobem bude možné vyčlenit konkrétní algoritmy a porovnat jejich celkovou výkonnost v závislosti na úpravě databáze.

Po analýze tohoto vlivu na výkonnost jednotlivých algoritmů budou modifikace databáze sloučeny s původní databází výběrem nejlepší kombinace parametrů a modifikací. Je důležité poznamenat, že data by měla být slučována pouze v rámci jedné databáze a jejich modifikací, v žádném případě by neměla být slučována data z různých databází.

### 4.3.4 Čtvrtá etapa: Výběr kombinací

Na základě údajů získaných z různých databází se pro každou z nich vypočítá nejlepší kombinace parametrů. Tyto kombinace lze rozdělit do dvou skupin podle toho, zda se použijí koeficienty AUC nebo PLS. Dále je možné je rozdělit do dalších dvou podskupin: s časem nebo bez času. Tyto kombinace se pak vzájemně porovnají, aby se určila nejlepší kombinace.

### 4.3.5 Pátá etapa: Analýza kombinací

Pro každou kombinaci budou vypočteny koeficienty pomocí PLS regrese, ale bez normalizace, aby bylo možné je spojit do jednoho agregovaného parametru kvality. Tyto koeficienty se vypočítají pro každou databázi, aby se získaly průměrné údaje o výkonnosti. Pomocí těchto koeficientů budou vypočteny agregované hodnoty kombinací pro každý snímek. Přepočítá se doba výpočtu jako součet doby výpočtu všech použitých parametrů.

Data z výsledné statistiky se použijí k výpočtu AUC kombinace parametrů a průměrné doby výpočtu. AUC se vypočítá pro každou dvojici koeficientů a databází, aby se určila průměrná hodnota AUC pro danou kombinaci. Tímto způsobem můžeme posoudit celkovou efektivitu dané kombinace parametrů a porovnat tuto efektivitu s jinými kombinacemi.

## Kapitola 5

# Implementace výběrového programu

Tato kapitola popisuje architekturu výběrového programu na základě kroků analýzy popsaných v kapitole 4.

### 5.1 Architektura výběrového programu

Architektura výběrového programu bude určena samotnou strukturou etap popsaných dříve v 4.3. Z analýzy kroků v jednotlivých fázích je zřejmé, že nejvýhodnější je mít ne jeden program, ale několik, přičemž každý z nich řeší konkrétní problém. Každý takový nástroj patří do jedné z následujících kategorií: sběr primárních dat, analýza primárních dat, kombinace primárních dat na základě analýzy, vytváření kombinací, analýza vybraných kombinací. Tyto kategorie odpovídají etapám analýzy, i když je třeba poznamenat, že některé nástroje lze použít v několika etapách najednou: například analýzu primárních dat lze použít na dříve sloučených datech. Hlavním programovacím jazykem zvoleným pro tuto práci je Java, takže některá architektonická řešení budou dána vlastnostmi tohoto jazyka. Rozdělení programů do jednotlivých etap a jejich architektury budou popsány níže.

#### 5.1.1 Sběr primárních dat

Pro sběr primárních údajů se program skládá z několika hlavních částí:

- Načtení algoritmů pro vlastnosti kvality a extrakci kanálů.
- Kombinování načtených algoritmů do rysů kvality.
- Sběr dat pro třídy kvality v databázi.
- Výpočet rysů kvality pro vše snímky z databáze.
- Serializace a ukládání výsledků.

#### Nahrávač algoritmů

Záměrem bylo načítat algoritmy dynamicky, takže změnou jediného řádku v konfiguračním souboru by bylo možné změnit sadu načtených algoritmů. K tomu, aniž by bylo nutné třídu

registrovat v samotném kódu, lze použít rozhraní Java Reflection API k vyhledání třídy pomocí konkrétních paketů a k získání metadat o načtených třídách.

Algoritmus načítání požadovaných tříd je popsán v následujících krocích:

1. Načte seznam tříd a jejich metadat z paketů definovaného v konfiguračním souboru.
2. Filtrování tříd na základě jejich rozhraní.
3. Nahrajte je do programu pomocí proxy tříd, aby se dostaly pod obecné rozhraní, definované v programu.

V rámci této práce se počítá se dvěma hlavními typy algoritmů: Algoritmy rysů kvality obrazu a algoritmy extrakce obrazových kanálů. V souladu s tím jsou pro každý z nich definována Java rozhraní:

- *QFAlgorithm* - (*Quality Feature Algorithm*) je funkční rozhraní s jedinou metodou, která přijímá obrázek jako vstup a vrací číselnou hodnotu jako vypočtený parametr kvality.
- *CEAlgorithm* - (*Channel Extraction Algorithm*) je funkční rozhraní s jedinou metodou, která přijímá obrázek jako vstup a vrací vybraný obrazový kanál.

Aby se algoritmy nemusely vázat na rozhraní definované v tomto programu, budou třídy, které implementují algoritmy pro výpočet rysů kvality nebo pro extrakci kanálů, přímo implementovat nativní rozhraní Java: *Function<BufferedImage, Double>* a *Function<BufferedImage, BufferedImage>*.

Načtené algoritmy budou přivedené k rozhraním *QFAlgorithm* a *CEAlgorithm* pomocí vzoru Adapter. Všimněte si, že takové třídy adaptérů slouží jako prostředníci mezi programem a načítanými algoritmy s možností přidání funkčnosti navíc (např. logování), takže budou označovány jako proxy třídy pro algoritmy. Již tyto proxy třídy budou v programu dále používány.

## Kombinátor algoritmů

Rysy kvality jsou kombinací algoritmu pro vlastnost kvality a algoritmu pro extrakci kanálu. V programu jsou znázorněny jako třída *QualityFeature*, která obsahuje objekt typu *QFAlgorithm* a objekt typu *CEAlgorithm*. Vytváření objektů této třídy je poměrně jednoduché - vytvářejí se všechny možné kombinace. Již oni přímo budou sloužit ke sběru dat z obrázků v data setech.

## Extraktor dat z databáze

Stejně důležité by bylo shromáždit údaje o třídách kvality obrazu reprezentovaných v databázi. Tento seznam zahrnuje nejen názvy samotných tříd, ale také jejich procentuální podíl a pořadí. Vzhledem k tomu, že názvy tříd mohou být značně netriviální (např. GOOD, MAYBE, REJECT), jejich pořadí od nejlepšího k nejhoršímu by mělo být definováno uživatelem v konfiguračním souboru ve složce s obrázky. Zvolil jsem nejjednodušší řešení: JSON se seznamem tříd seřazených od nejlepší po nejhorší. Tímto způsobem se sběr dat skládá ze třech jednoduchých kroků:

1. Načtení tříd a jejich pořadí z konfiguračního souboru.

2. Výpočet procentuálního podílu počtu snímků s třídami definovanými v konfiguračním souboru.
3. Výpočet mediánové hodnoty pro každou třídu kvality.

Mediánová hodnota je v tomto případě agregovaná hodnota na základě pořadí a procentuálního podílu. Výpočet je jednoduchý: součet počtu snímků všech tříd, které jsou horší než cílová hodnota, plus polovina počtu snímků cílové třídy kvality dělená celkovým počtem snímků. Například pokud máme dvě třídy A a B, kde procentní podíly jsou po 50% a třída A je lepší než třída B, máme mediánovou hodnotu 0,75 pro třídu A a 0,25 pro třídu B, resp.

Výsledkem extrakce dat tříd kvality bude JSON s výše uvedenými parametry pro každou třídu.

### Výpočet rysů kvality

Soubor rysů kvality získaný v 5.1.1 a 5.1.1 se spustí nad všemi obrázky v databázi. Za tímto účelem definujeme v programu třídu-executor *QualityFeatureExecutor* a třídu-orchestrátor *ExecutionOrchestrator*.

*QualityFeatureExecutor* shromažďuje údaje pouze o spuštění jedné kombinace nad obrázkem. Výsledkem je vrácení celkové statistiky v kombinaci s odkazem na spuštěnou kombinaci. Tato statistika obsahuje dobu běhu algoritmu v milisekundách a vrácený výsledek výpočtů.

*ExecutionOrchestrator* je zodpovědný za pořadí, v jakém se spouštějí rysy kvality nad obrázky. Tato posloupnost je následující:

1. Načtení souboru rysů kvality.
2. Načítání seznamu obrázků.
3. Inicializace seznamu výsledků.
4. Pro každý obrázek v seznamu:
  - (a) Načtení obrázku a jeho třídy kvality do paměti RAM.
  - (b) Výpočet masky obrazu.
  - (c) Paralelní spuštění všech kombinací algoritmů na daném obrázku pomocí třídy-executora a shromažďování statistik.
  - (d) Přidání těchto statistik do seznamu výsledků.
  - (e) Odstranění obrazu z paměti RAM (v jazyce Java probíhá automaticky).
5. Vrácení seznamu výsledků.

Důležité je také poznamenat, jakým způsobem je maska obrazu vytvořena. Předpokládá se, že obraz sítnice je v obraze vycentrován a má tvar kruhu.



Obrázek 5.1: Příklad obrazu lidské sítnice

Maska obrázku tedy bude mít tvar kruhu se středem uprostřed fotografie. Zbývá určit pouze průměr masky. V této práci se to provede tak, že se pomocí intenzity pixelů zjistí horní, dolní, levá a pravá hranice kruhu. Po určení těchto hranic vybereme kruh, který se do nich vejde. Masku se vytváří pro původní obraz, nikdy ne pro jeho kanály, protože v některých kanálech mohou být části obrazu zcela černé, což by vedlo k nesprávně definované masce.

### Serializace a ukládání výsledků.

Seznam statistik získaných z třídy orchestrátoru je pak uložen pomocí třídy *ExecutionStatsWriter* jako soubor *calculatedResults.txt*. Tento soubor obsahuje objekt JSON se dvěma atributy: seznam rysů kvality a seznam výsledků pro všechny obrázky. Výsledek analýzy obrázku obsahuje třídu obrázku, seznam vrácených hodnot z každého rysu kvality a seznam s časem výpočtu pro každou kombinaci. Celková struktura je následující:

```
{
  "features" : ["QFAlgorithm && CEAlgorithm", ...],
  "results" : [
    {
      "class" : "A",
      "results" : [0.65, ...],
      "executionTime" : [343, ...]
    },
    ...
  ]
}
```

Tyto údaje budou později použity při analýze a výběru kombinací.

### 5.1.2 Analýza primárních dat

Po získání vypočtených statistik z databáze je dalším krokem jejich analýza pomocí dvou metod popsaných dříve v části 4.2. Každou metodu lze rozdělit na dva kroky - výpočet hodnot a další analýzu. V tomto okamžiku se provede aktivace prvního kroku. Tenhle krok bude realizován jako samostatný program.

Pro výpočet hodnot AUC (pro metodu absolutního výkonu), koeficientů PLS (pro metodu relativního výkonu) a průměrného času se použijí odpovídající tři třídy *AbsolutePerformanceComputer*, *RelativePerformanceComputer* a *AverageTimeComputer*. Každá třída dědí společné funkční rozhraní *Computer*, které má jedinou metodu *compute(...)*, do níž vstupují statistiky vypočtené v prvním kroku 5.1.1 a výstupem jsou dvojice: vlastnost kvality - vypočtený parametr.

#### **AbsolutePerformanceComputer**

Architektura této třídy je založena výhradně na principu popsaném v 4.3.2. AUC jsou vypočtené pro každou kombinaci třída - nejhorší třídy, a jako výsledek se bere průměrná hodnota AUC. Upozorňuji, že v tomto programu, pokud rys kvality má obrácený vztah, bude vrácená hodnota AUC záporná. To znamená, že pokud parametr  $X$  má  $AUC = -0,74$ , pak  $1 - X$  bude mít  $AUC = 0,74$ . To bylo provedeno pro lepší vizualizaci výsledků a pro pozdější snadnější porovnání (porovnáním absolutních hodnot AUC).

#### **RelativePerformanceComputer**

Stejně jako v případě *AbsolutePerformanceComputer* je tato třída úplným ztvárněním kroků popsaných v 4.3.2. Vrací dvojice rysy kvality - váhové koeficienty vypočtené algoritmem SIMPLS a normalizované tak, aby součet všech koeficientů byl roven 1.

#### **AverageTimeComputer**

Tato třída shromažďuje průměrný výpočetní čas na obrázek na základě dříve shromážděných statistik. Neprovádí se žádná normalizace.

#### **Výsledek této etapy**

Výsledkem tohoto kroku jsou tři seznamy dvojic kvalita-hodnota. Pro každý typ analýzy jsou tyto údaje uloženy v souborech *auc.txt*, *pls.txt* a *time.txt*.

### 5.1.3 Analýza předběžného zpracování a slučování statistik

Shromážděním údajů pro různé metody analýzy je možné porovnat dopad předběžného zpracování na snímky z databáze na základě srovnání průměrné hodnoty AUC pro stejný algoritmus, ale z dat z různých modifikací databáze. Pokud je průměrná hodnota AUC určitého algoritmu vyšší na upravených databázových obrazech, lze tvrdit, že toto předběžné zpracování před spuštěním určitého algoritmu má smysl, zejména pokud snižuje dobu výpočtu (např. snižuje rozlišení obrazu).

V této práci bude analyzován dopad snížení rozlišení obrazu jako jedné z úprav databáze. Tak je možné vybrat nejlepší "verze" algoritmů pro další výběr kombinací. Kombinace

výsledků z původní i upravené databáze budou kombinovány následujícím způsobem: do výsledného seznamu statistik bude zařazen algoritmus s předzpracováním, pokud je jeho průměrná AUC vyšší než průměrná AUC algoritmu spuštěného na neupravené databázi. A platí to i naopak: pokud algoritmus bez předzpracování dosáhne lepších výsledků, bude ve výsledném seznamu statistik zařazen.

Snížení rozlišení obrazu výrazně zkracuje celkovou dobu výpočtu, proto bylo bráno jako příklad úpravy, kterou stojí za to prozkoumat.

Potenciálně je možné tyto kroky provádět nejen na průměrných hodnotách AUC, ale také na dalších agregovaných parametrech, jako jsou koeficienty z analýzy PLS, ale to bude mimo rozsah této práce. Pro propojení dvou seznamů statistik ze dvou různých modifikací je představen samostatný program, který jako vstup přijme seznam algoritmů, které se mají převzít z jednoho výsledku, a všechny ostatní se převezmou z druhého výsledku.

#### 5.1.4 Výběr kombinací

Po výběru nejlepších rysů kvality ze všech modifikací databáze je dalším krokem výběr nejlepších kombinací parametrů. V této práci se budeme zabývat jedním způsobem výběru kombinací pro analýzu na základě absolutní výkonnosti a dvěma způsoby výběru kombinací pro analýzu na základě relativní výkonnosti. Jedná se o tyto způsoby:

- *Top N* - top  $N$  nejkvalitnějších rysů kvality. Velmi přímočarý výběr, který spočívá v jednoduchém výběru určitého počtu nejlepších rysů kvality na základě hodnot AUC.
- *Top 90%* - kombinace rysů kvality, ve které mají koeficienty PLS jednotlivých složek kombinovanou váhu 90% celkové váhy. Vybírají se vlastnosti jakosti s nejvyššími koeficienty.
- *Fastest 90%* - kombinace rysů kvality, ve které mají koeficienty PLS jednotlivých složek kombinovanou váhu 90% celkové váhy. Je vybrána kombinace s nejkratší celkovou dobou výpočtu.

Tento soubor kombinací se vypočítá nad výsledky z každé databáze (výsledky z modifikací byly předem sloučeny). Popsané algoritmy jsou implementovány v samostatném programu. Implementace prvních dvou algoritmů *Top N* a *Top 90%* je velmi jednoduchá, ale *Nejrychlejší 90%* by měl být popsán podrobněji.

*Fastest 90%* je softwarově realizován výběrem nejlepšího souboru rysů kvality na základě hodnoty parametru, který lze popsat jako váhu normalizovanou časem. Pro každou vlastnost kvality se vypočítá poměr  $Weight_{normalized} = PLS_{weight} / AverageTime$  a seřadí se sestupně. Vlastnosti kvality se do množiny přidávají jedna po druhé (počínaje nejvyšší normalizovanou váhou), dokud jejich celková váha nedosáhne 90%.

Výsledkem tohoto výběru budou soubory s objektem JSON, který obsahuje seznam vybraných rysů kvality.

#### 5.1.5 Analýza kombinací

Pro testování těchto kombinací není nutné je znovu spouštět po databázích. Stačí vybrat vlastnosti kvality použité ve vybraných kombinacích a spojit je do jednoho parametru. Chcete-li je zkombinovat, vypočtete jejich nejvhodnější koeficienty a pak je jednoduše přičtete k sobě. Poté je možné provést analýzu přímo jako ve druhém kroku, popsáném v 5.1.2. Tato přímá vazba na druhý krok je důvodem, proč bylo rozhodnuto přidat tuto funkci do

programu pro druhý krok. Mezi tyto dodatečné funkce patří: možnost vybrat podmnožinu rysů kvality pro analýzu, na základě zvolené kombinace vypočítat koeficienty a spojit je do jednoho parametru.

Výběr podmnožiny statistik z celkového seznamu statistik je založen na jejich filtrování, přičemž se kontroluje, zda statistiky patří do kombinace definované pomocí jednoho z algoritmů z předchozího kroku 5.1.4. Programově se to provádí načtením objektu JSON se seznamem vybraných rysů, načtením statistik z prvního kroku 5.1.1 a jejich dalším filtrováním.

V dalším kroku se k výběru koeficientů použije algoritmus SIMPLS. Je důležité poznamenat, že pro výpočet koeficientů pro sloučení do jednoho parametru je nutné provést analýzu PLS na nenormalizovaných datech. Rovněž výsledné koeficienty se použijí tak, jak jsou, bez připočtení celkové váhy na 1.

Pomocí vypočtených koeficientů pro vybrané rysy kvality a jejich statistik je možné je spojit do jednoho parametru. Název této kombinace je zvolen uživatelem.

Vzhledem k tomu, že výsledná kombinace je sloučena do jediného parametru, ztrácí analýza PLS jakýkoli význam. Proto v této práci budeme uvažovat pouze AUC každé kombinace a dobu jejího výpočtu, která je součtem doby výpočtu jejích jednotlivých složek. Při znalosti AUC a doby výpočtu pro každou kombinaci je možné porovnat různé kombinace a vybrat tu nejlepší pro danou úlohu.



# Kapitola 6

## Analýza rysů kvality

V podkapitole 6.1 jsou popsány vybrané algoritmy pro rysy kvality a pro extrakci obrazových kanálů.

Podkapitola 6.2 se zabývá použitými databázemi, včetně vlastní sady dat.

Podkapitola 6.3 popisuje použití vytvořených programů nad obrazy z databází a výsledky analýzy.

### 6.1 Algoritmy vybrané pro analýzu

Pro analýzu kombinací a výběr nejlepších z nich, které budou výsledným algoritmem pro odhad kvality obrazu lidské sítnice, byly vybrány dva seznamy algoritmů: algoritmy rysů kvality a algoritmy extrakce obrazového kanálu. Jejich kombinace budou představovat výchozí rysy kvality.

#### 6.1.1 Algoritmy rysů kvality

Algoritmy pro výpočet parametrů, které budou analyzovány v této práci:

1. *Cumulative Probability Of Blur Detection* - algoritmus pro hodnocení ostrosti obrazu na základě pravděpodobnosti detekce rozostření. Popsáno v 3.3.1.
2. *Difference Of Difference* - algoritmus pro hodnocení ostrosti obrazu založený na výpočtu rozdílů kontrastních přechodů. Popsáno v 3.3.1.
3. *Effective Number of Neighbours* - algoritmus pro hodnocení ostrosti obrazu založený na výpočtu efektivního počtu sousedních pixelů na Sobelově mapě. Popsáno v 3.3.1.
4. *Inherited Sharpness* - Algoritmus pro hodnocení ostrosti obrazu založený na výpočtu míry ostrosti na základě prostorové aktivity. Popsáno v 3.3.1.
5. *Wavelet Entropy L3 vs Wavelet Entropy L1* - algoritmus pro hodnocení rovnoměrnosti osvětlení a ostrosti obrazu založený na výpočtu poměru vlnkové entropie vysokofrekvenční úrovně k vlnkové entropii nízkofrekvenční úrovně. Popsáno v 3.3.1.
6. *Mean Intensity* - je průměrná hodnota intenzity pixelů v obraze. Jeden z parametrů osvětlení, popsáný v 3.3.1.

7. *Mean Intensity Centered* - je míra odchylky průměrné intenzity pixelů v obraze od centrální hodnoty 128. Jedná se rovněž o parametr osvětlení, který je variací předchozího parametru.
8. *Energy of Intensity* - je průměrná energie pixelů v obraze. Jedná se o míru osvětlení.
9. *Energy of Intensity Centered* - je míra odchylky průměrné energie pixelu v obraze od centrální hodnoty v  $128^2$ . Je to také parametr osvětlení, který je variací předchozího parametru.
10. *Variance of Intensity* - je průměrný rozptyl intenzity pro pixely v obraze. Je to jeden z parametrů světlosti popsáných v 3.3.1.
11. *Skewness of Intensity* - je šikmost histogramu intenzity pixelů obrazu. Jedná se o jeden z parametrů osvětlení, včetně homogenity osvětlení, popsáných v 3.3.1.
12. *Kurtosis of Intensity* - je kurtóza histogramu intenzity pixelů obrazu. Je jedním z parametrů osvětlení, včetně homogenity osvětlení, popsáných v 3.3.1.
13. *Number of Pixels in X third* - procentuální poměr počtu pixelů v určité třetině histogramu k celkovému počtu pixelů. Bude zkoumána změna první (intenzita 0-85), druhá (intenzita 86-170) a třetí (intenzita 171-255) třetiny histogramu. Používá se jako měřítko kvality osvětlení, včetně homogenity osvětlení ve spojení s některými kanály.

### 6.1.2 Algoritmy extrakce obrazových kanálů

Algoritmy pro extrakci kanálů, které budou analyzovány v této práci:

1. Kanál obrazu ve stupních šedi.
2. Barevné kanály R,G a B.
3. Saturační kanály barev R,G a B.
4. Kanál relativní váhy barev R,G a B.

Celkem bude použito 10 možných kanálů. Podívejme se na ně podrobněji.

#### Kanál obrazu ve stupních šedi


Program vypočítá kanál stupňů šedi obrazu převodem hodnot z jednotlivých kanálů R, G a B na hodnotu vnímané intenzity. Převod je popsán následujícím vzorcem:

$$I_{pix} = 0.299 * R + 0.587 * G + 0.114 * B \quad (6.1)$$

kde:

- $I_{pix}$  - intenzita pixelu.
- $R, G, B$  - červený, zelený a modrý kanál, resp.

Příklad kanálu ve stupních šedi pro standardní obrázek [24] je na 6.1.




(a) Původní obrázek      (b) Kanál ve stupních šedi

Obrázek 6.1: Příklad kanálu ve stupních šedi [24].

### Kanály R,G and B

Extrakce určitého barevného kanálu se provádí pomocí izolací jedné nebo druhé barvy. Příklady barevných kanálů pro standardní obrázek [24] jsou na 6.2.



(a) Původní obrázek      (b) Červený kanál



(c) Zelený kanál      (d) Modrý kanál

Obrázek 6.2: Příklady barevných kanálů [24].

## Saturační kanály

Kanály saturace slouží k vizualizaci stupně saturace jednotlivých barev v obrázku. Saturace se pro červenou barvu vypočítá takto:

$$Sat_R = \begin{cases} 0, & \text{pokud barva není dominantní,} \\ \frac{(R-B) \cdot (R-G)}{R^2}, & \text{pokud je barva dominantní.} \end{cases} \quad (6.2)$$


Podobně je tomu u zelené a modré barvy:

$$Sat_G = \begin{cases} 0, & \text{pokud barva není dominantní,} \\ \frac{(G-B) \cdot (G-R)}{G^2}, & \text{pokud je barva dominantní.} \end{cases} \quad (6.3)$$

$$Sat_B = \begin{cases} 0, & \text{pokud barva není dominantní,} \\ \frac{(B-G) \cdot (B-R)}{B^2}, & \text{pokud je barva dominantní.} \end{cases} \quad (6.4)$$

Všechny hodnoty jsou pak převedeny do rozsahu 0 až 255.

Příklady kanálů sytosti barev pro standardní obrázek [24] jsou na 6.3.



Obrázek 6.3: Příklady kanálů sytosti barev [24]. Poznámky - kan: kanál, syt: sytosti.

## Kanály relativní váhy

Kanál relativní váhy je vizualizací procentuálního podílu barvy na součtu všech složek. Vypočítá se podle následujícího vzorce:


$$Rel_R = \frac{R}{(R + G + B)} \quad (6.5)$$

$$Rel_G = \frac{G}{(R + G + B)} \quad (6.6)$$

$$Rel_B = \frac{B}{(R + G + B)} \quad (6.7)$$

Všechny hodnoty jsou pak převedeny do rozsahu 0 až 255.

Příklady kanálů relativní váhy barev pro standardní obrázek [24] jsou na 6.4.



Obrázek 6.4: Příklady kanálů relativní váhy barev [24]. Poznámky - kan: kanál, rel: relativní.

## 6.2 Databáze

Pro tuto práci byly vybrány dvě základní databáze a jedna modifikace, která spočívá ve snížení obrazového rozlišení. Celková analýza obrazových dat by měla přinést 4 soubory statistik ze všech databází, které budou postupně sloučeny.


### 6.2.1 EyeQ data set

*Eye-Quality (EyeQ) Assessment Dataset* je reanotovaná část sady dat *EyePACS Dataset*[7] pro určování kvality obrazu sítnice lidského oka pořízeného fundus kamerou. Tato datová sada obsahuje 28792 barevných snímků, které jsou hodnoceny ve třech stupních ('Good', 'Usable', 'Reject'). Kromě hodnocení kvality jsou u každého snímku uvedeny úrovně diabetické retinopatie, ale tyto informace nebudou použity, protože jsou mimo rozsah této studie. Tuto databázi představil Huazhu a kol. ve svém článku [13] a lze ji nalézt na *GitHub*[8].

Statistiky tříd kvality pro celý soubor dat jsou následující:

Třída kvality	Počet obrázků	Procentuální podíl	Mediánová hodnota
Good	16818	58.41%	0.7079
Usable	6434	22.35%	0.3041
Reject	5540	19.24%	0.0962

V tomto článku budou použité některé snímky z tohoto data setu, konkrétně 3047 snímků. Je třeba poznamenat, že informace o jednotlivých třídách, konkrétně jejich procentuální podíl a mediánová hodnota, budou pro analýzu převzaty z celé databáze EyeQ. Rozlišení snímků v této databázi se pohybuje od  $433 \times 289$  pixelů do  $3888 \times 2592$  pixelů, ale většina ( 90%) má rozlišení větší než *Full HD* ( $1920 \times 1280$ ). Příklady snímků z tohoto data setu:



Obrázek 6.5: Příklad anotací a obrázků v data setu EyeQ [13].

### 6.2.2 Vlastní data set

V tomto příspěvku bude také představen soubor dat obsahující snímky poskytnuté Fakultní Nemocnicí u Svaté Anny. Tato databáze obsahuje 566 barevných anotovaných snímků. Jsou zde uvedeny tři třídy kvality obrázků: 'Good', 'Usable', 'Reject'. Anotace byla provedena vyhodnocením bez referenčního snímku, s předchozím slovním určením očekávané klasifikace. Na anotování se podíleli tři lidé a poté byl pro každý obrázek stanoven průměrný *Mean Opinion Score* 3.2. Slovní popis klasifikací pro hodnotitele byl následující:

1. Good - neporušená ostrost, výskyt odlesků - do 5-10%, lehké nerovnoměrné osvětlení lze akceptovat (nezpůsobuje frustraci), přijatelné jsou i nižší úrovně kontrastu. To vše lze snížit/odstranit při následném zpracování. Lehká neostrost může být přijatelná, pokud pokrývá pouze do 10 procent plochy snímku a neovlivňuje hlavní struktury.
2. Usable - lehká neostrost, která nezpůsobuje frustraci, nebo odlesky do 15-20%, nerovnoměrné světlo na pozadí a nižší kontrast, které způsobují mírnou ztrátu detailů, mohou být přijatelné.


3. Reject - střední až velká ztráta detailů v důsledku výše popsaných účinků.

Statistiky tříd kvality pro celý soubor dat jsou následující:

Třída kvality	Počet obrázků	Procentuální podíl	Mediánová hodnota
Good	165	29.15%	0.8542
Usable	289	51.06%	0.4532
Reject	112	19.79%	0.0989

V této práci budou použity všechny snímky z této sady dat. Rozlišení snímků v této datové sadě je pro všechny snímky stejné a činí  $3888 \times 2592$  pixelů.

Příklady obrázků z tohoto data setu:



Obrázek 6.6: Příklady obrázků z vlastního data setu.

### 6.2.3 Snížení rozlišení jako předběžné zpracování databáze

Jako variantu předzpracování databáze představuje tato práce snížení rozlišení na  $800 \times 533$  pixelů pomocí standardních nástrojů poskytovaných v Java třídách pakagu *java.awt*. Tato úprava byla provedena jak pro data set *EyeQ*, tak pro náš vlastní data set. V analýze tak budou zkoumány 4 databáze.

## 6.3 Výsledky

### 6.3.1 První spuštění

Algoritmy definované v 6.1 tvoří 150 možných dvojic algoritmů pro výpočet parametrů a algoritmů pro extrakci obrazového kanálu. Celý soubor odvozených rysech kvality byl proveden na čtyřech databázích popsaných v 6.2. Všechny vypočtené statistiky pro každou datovou sadu si můžete prohlédnout v příložených materiálech v příslušných složkách.

Pro účely tohoto článku chceme zdůraznit průměrné hodnoty AUC pro konkrétní algoritmy rysů kvality. Tento průměr byl vypočten pro všechny kanály najednou. Byly získány následující data zobrazené v tabulkách 6.1 a 6.2.

V níže uvedených tabulkách a diagramech budou použity následující označení algoritmů:

- CPBD - Cumulative Probability of Blur Detection
- DoD - Difference of Difference

- ENoN - Effective Number of Neighbours
- EoI - Energy of Intensity
- EoIC - Energy of Intensity Centered
- IS - Inherited Sharpness
- KoI - Kurtosis of Intensity
- MI - Mean Intensity
- MIC - Mean Intensity Centered
- NoP1 - Number of Pixels in First Third
- NoP2 - Number of Pixels in Second Third
- NoP3 - Number of Pixels in Third Third
- SoI - Skewness of Intensity
- VoI - Variance of Intensity
- WL3vL1 - Wavelet Entropy L3 vs Wavelet Entropy L1

Tabulka 6.1: Průměrná AUC pro každý algoritmus v modifikacích data setu EyeQ. Poznámky - roz: rozlišení.

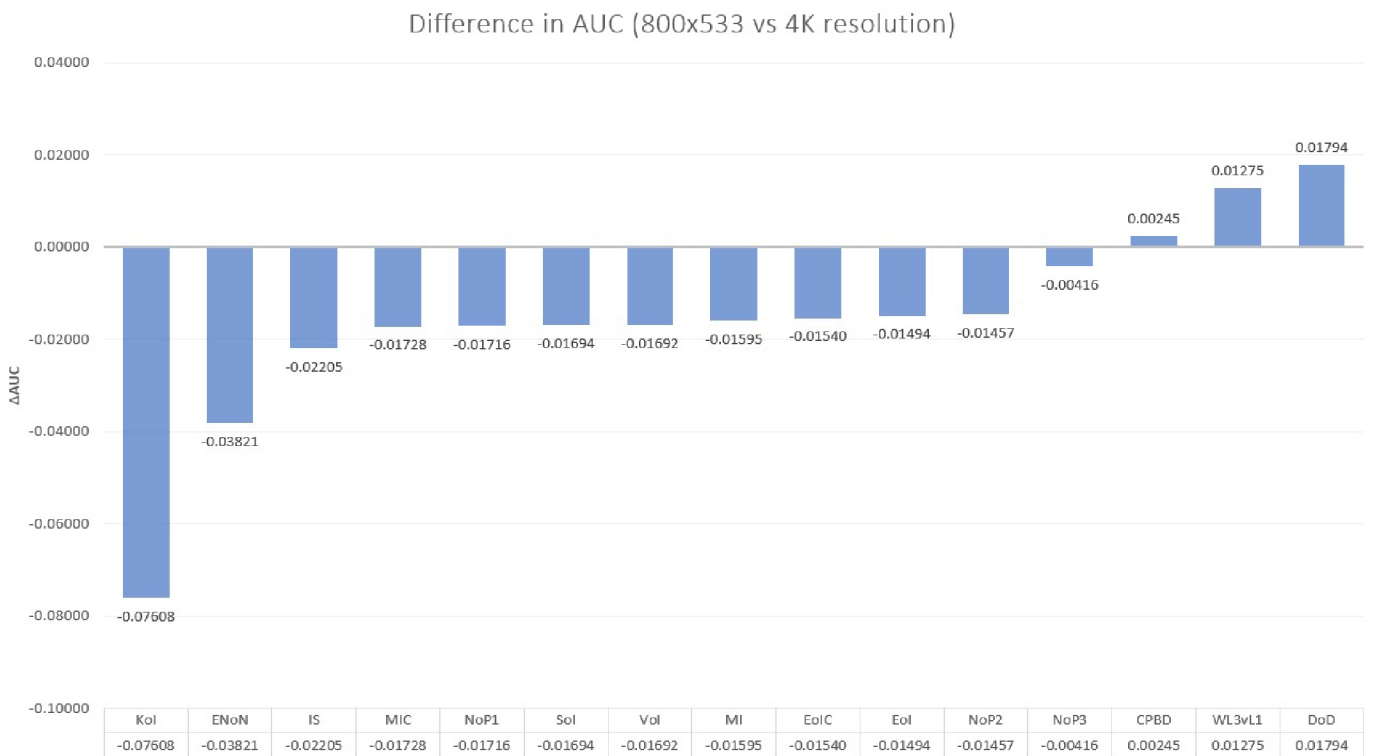
Algoritmus	AUC s plným roz.	AUC s sníženým roz.
CPBD	0.54826	0.55071
DoD	0.58120	0.59914
ENoN	0.58811	0.54989
EoI	0.66083	0.64589
EoIC	0.66543	0.65003
IS	0.5798	0.55777
KoI	0.64076	0.56468
MI	0.66431	0.64837
MIC	0.64358	0.62630
NoP1	0.64795	0.63079
NoP2	0.63026	0.61569
NoP3	0.57749	0.57334
SoI	0.56029	0.54334
VoI	0.62500	0.60807
WL3vL1	0.53163	0.54438




Tabulka 6.2: Průměrná AUC pro každý algoritmus v modifikacích vlastního data setu. Poznámky - roz: rozlišení.

Algoritmus	AUC s plným roz.	AUC s sníženým roz.
CPBD	0.57477	0.57274
DoD	0.57328	0.61218
ENoN	0.60077	0.56504
IoI	0.58801	0.58876
IoIC	0.59930	0.60106
IS	0.55602	0.56412
KoI	0.55734	0.57871
MI	0.59639	0.59240
MIC	0.59867	0.59455
NoP1	0.60054	0.59059
NoP2	0.59616	0.58901
NoP3	0.52601	0.52209
SoI	0.54415	0.55916
VoI	0.61017	0.62647
WL3vL1	0.53052	0.54741

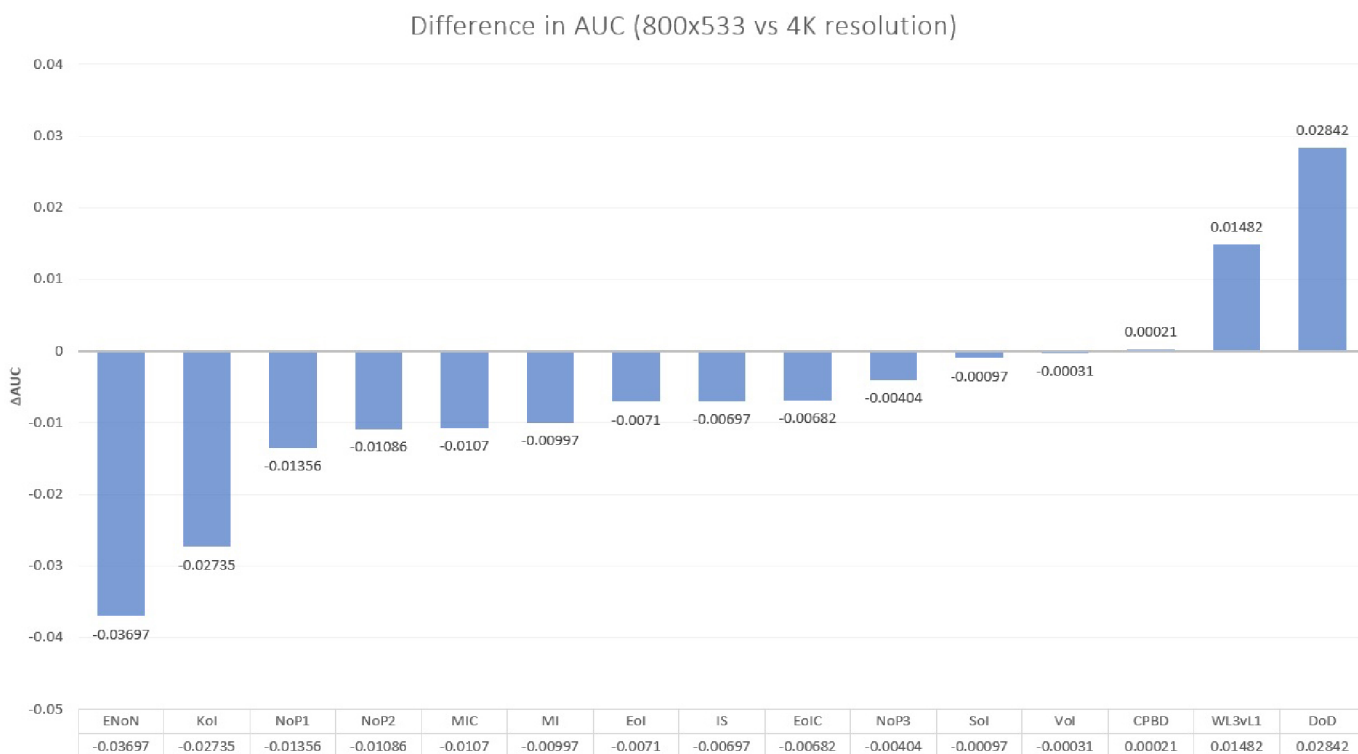
Na základě získaných dat je možné vyhodnotit vliv komprese obrazu na účinnost jednotlivých algoritmů. Odečtením průměrné AUC algoritmů získané na souboru dat se sníženým rozlišením od průměrné AUC získané na souboru dat s plným rozlišením získáme míru nárůstu/poklesu výkonnosti v závislosti na použití tohoto druhu předzpracování. Výpočtem tohoto rozdílu získáme diagramy 6.7,6.8 a spojenou verzi 6.9.



Obrázek 6.7: Rozdíl v průměrných hodnotách AUC pro data set EyeQ.



Obrázek 6.8: Rozdíl v průměrných hodnotách AUC pro vlastní data set.



Obrázek 6.9: Spojené údaje o rozdílech v průměrných hodnotách AUC z vlastního data setu a EyeQ.


Jak je vidět z diagramu spojených hodnot 6.9, některé algoritmy mají lepší výkonnost na obrázcích s nižším rozlišením. Je třeba poznamenat, že tyto tři algoritmy: Cumulative Probability of Blur Detection, Difference of Difference, Wavelet Entropy L3 vs Wavelet Entropy L1 - tak či onak hodnotí ostrost obrazu. Zjevný efekt zlepšení celkového výkonu algoritmu lze vysvětlit přítomností šumu v původních obrazech.

## Šum


V původních, vysoce kvalitních snímcích se nezdá, že se objevuje šum, který lze zase velmi snadno považovat za okraje překrývajících se jednotlivých struktur na snímku. Nejjednodušší způsob, jak se vypořádat se šumem, je použít filtr, který má však jeden problém: může mít destruktivní vliv na čistotu struktur, které šumem nejsou. Snížení rozlišení obrazu zase funguje zhruba jako filtr - vypočítá průměrnou hodnotu na nějakém segmentu, ale pak se tato průměrná hodnota jednoduše aplikuje na jeden výsledný pixel, aniž by ovlivnila sousední pixely. Tímto způsobem lze nejjednodušeji odfiltrout vysokofrekvenční šum a přitom zachovat jasné hrany struktur lidského oka. Je však třeba poznamenat, že pozitivní účinek snížení rozlišení bude přítomen, pokud komprese nepoškodí struktury oka, jako jsou například cévy, v obraze. Na následujících snímcích je možné vidět vliv na detekci hran na strukturách v obraze v závislosti na rozlišení fotografie. Hrany na snímku byly detekovány pomocí Cannyho detektoru.




(a) Původní obrázek




(b) 2592x2592



(c) 1280x1280



(d) 720x720



(e) 533x533

Obrázek 6.10: Cannyho mapa hran pro různá rozlišení.

Tak lze vysvětlit pozitivní vliv snížení rozlišení na algoritmy, které určují ostrost obrazu. Proto se v případě analýzy reálných snímků, které tak či onak budou obsahovat šum, doporučuje jejich minimálně dvojnásobná, nejlépe čtyřnásobná komprese.

## Rozdíl v anotacích

Samostatně je nutné zdůraznit významný rozdíl ve výsledcích zobrazených v diagramech 6.7 a 6.8, mezi oběma anotacemi v obou použitých databázích. Z těchto údajů nelze posoudit rozdíl v kvalitě anotace mezi oběma data sety, ale lze s jistotou říci, že algoritmus, který by plně vyhovoval klasifikaci jedné z databází, by měl zjevně výrazně horší výkon, pokud by se vnitřní koeficienty neměnily. Proto se táto práce zaměří na nalezení nejuniverzálnější kombinace parametrů, která bude mít v průměru nejvyšší efektivitu, přičemž bude mít dvě sady koeficientů pro data set EyeQ a pro vlastní data set.

### 6.3.2 Sloučení výsledků

Jakmile jsem měl data o účinnosti předzpracování v 6.3.1, mohl jsem sloučit databáze s jejich modifikacemi způsobem popsaným v 4.3.3 a 5.1.3. Sloučení bylo provedeno s využitím dat ze sloučených hodnot o rozdílu výkonnosti mezi sníženým rozlišením a plným rozlišením, které jsou uvedeny v 6.9. Pro další výběr kombinací budou tedy použity algoritmy Cumulative Probability of Blur Detection, Difference of Difference, Wavelet Entropy L3 vs Wavelet Entropy L1 spolu s předzpracováním a ostatní algoritmy bez předzpracování. Příslušné výsledky lze vidět v doplňkovém materiálu k práci s klíčovým slovem "Merged".

### 6.3.3 Vybrané kombinace

Kombinace byly vybrány na základě dvou sad statistik a jejich vypočtených koeficientů AUC a PLS. V práci byly zvažovány následující kombinace:

- *Top 5 AUC* - top 5 nejlepších rysů kvality vybraných na základě jejich hodnot AUC.
- *Top 10 AUC* - top 10 nejlepších rysů kvality vybraných na základě jejich hodnot AUC.
- *Top 20 AUC* - top 20 nejlepších rysů kvality vybraných na základě jejich hodnot AUC.
- *Top 30 AUC* - top 30 nejlepších rysů kvality vybraných na základě jejich hodnot AUC.
- *Top 90% PLS* - soubor rysů kvality s nejvyššími koeficienty analýzy PLS, jejichž souhrnná váha je nejméně 90%.
- *Fastest 90% AUC* - soubor rysů kvality, který je nejrychlejší kombinací s celkovou váhou koeficientů PLS alespoň 90%.
- *All Features* - vše 150 rysů kvality jako jediná kombinace.

Pro další analýzu bylo vybráno celkem šest kombinací z každé databáze a také kombinace ze všech možných atributů kvality. Tím jsme získali soubor 13 kombinací.

### 6.3.4 Analýza kombinací

Pro každou ze 13 kombinací byly pomocí regrese PLS vypočteny dvě sady koeficientů: na základě výsledků získaných ze souboru dat EyeQ a na základě výsledků získaných z našeho

vlastního souboru dat. To bylo provedeno za účelem analýzy každé sady rysů kvality v adaptovaném pod data set stavu. Vypočtené koeficienty umožňují agregovat dříve vypočtené statistiky jednotlivých rysů kvality do statistik pro celé kombinace.

Jejich AUC byla vypočtena nad získanými statistikami následovně: pro kombinace agregované na koeficientech s nejlepší adaptací pro anotace EyeQ byla AUC vypočtena výhradně pro obrázky data setu EyeQ a podobným způsobem pro vlastní data set. Výsledné hodnoty AUC jsou uvedeny v následující tabulce.

Tabulka 6.3: AUC pro kombinaci s koeficienty pro databáze EyeQ a vlastní databáze.

Kombinace	AUC pro EyeQ	AUC pro Own
All features	0.90319	0.94171
Own Top 5 AUC	0.71054	0.73527
Own Top 10 AUC	0.83604	0.80674
Own Top 20 AUC	0.84969	0.85740
Own Top 30 AUC	0.86037	0.86502
Own Top 90 PLS	0.82958	0.76287
Own Fastest 90 PLS	0.83132	0.71514
EyeQ Top 5 AUC	0.79759	0.74518
EyeQ Top 10 AUC	0.81543	0.75121
EyeQ Top 20 AUC	0.82957	0.81436
EyeQ Top 30 AUC	0.85259	0.83887
EyeQ Top 90 PLS	0.73366	0.72878
EyeQ Fastest 90 PLS	0.73366	0.72878

Poté byla vypočtena průměrná hodnota AUC pro každou kombinaci a relativní doba výpočtu: doba výpočtu pro všechny vlastnosti kvality byla brána jako 100%. Získané výsledky jsou uvedeny v následující tabulce, seřazené podle AUC.

Tabulka 6.4: Průměrná AUC pro každou kombinaci pro všechna data sety s relativním časem.

Kombinace	AUC	Čas výpočtu (relativní)	Počet rysů kvality
All features	0.92245201456	100.00%	150
Own Top 30 AUC	0.86269827746	23.42%	30
Own Top 20 AUC	0.85354503247	19.41%	20
EyeQ Top 30 AUC	0.84572764649	10.84%	30
EyeQ Top 20 AUC	0.82196727739	3.45%	20
Own Top 10 AUC	0.82138986484	17.80%	10
Own Top 90 PLS	0.79622295223	4.10%	28
EyeQ Top 10 AUC	0.78332129802	1.70%	10
Own Fastest 90 PLS	0.77322934309	4.09%	29
EyeQ Top 5 AUC	0.77138641044	0.85%	5
EyeQ Top 90 PLS	0.73122001524	1.34%	10
EyeQ Fastest 90 PLS	0.73122001524	1.34%	10
Own Top 5 AUC	0.72290889658	11.83%	5

Stojí za povšimnutí, že dvě kombinace *EyeQ Top 90 PLS* a *EyeQ Fastest 90 PLS* se ukázaly být naprosto stejné, i když jejich výběr byl původně odlišný.

Je vidět, že kombinace vybrané na datové sadě EyeQ byly výrazně rychlejší než kombinace vybrané na vlastní datové sadě. To lze vysvětlit tím, že v sadách rysů kvality vybraných pomocí EyeQ, převažují algoritmy pro výpočet kvality osvětlení, které jsou zase výrazně rychlejší z hlediska výpočetního času než algoritmy pro odhad ostrosti obrazu. Lze předpokládat, že při klasifikaci kvality obrazu ve vlastním data setu byla ostrost obrazu důležitějším faktorem, zatímco v klasifikaci data setu EyeQ naopak: větší roli hrála kvalita osvětlení.

Vzhledem k tomu, že maximální hodnota AUC, získaná pro kombinací všech možných rysů kvality (*All features*) nedosahuje hodnoty 0,95, mohu říci, že metoda kombinace atributů kvality do jednoho algoritmu není dokonalá a vyžaduje výrazné zlepšení.

Jako výsledné algoritmy tohoto článku budou vybrány dvě kombinace: *Own Top 30 AUC* a *EyeQ Top 20 AUC*. Důvodem tohoto rozhodnutí je skutečnost, že jedna kombinace má sice lepší vlastnosti klasifikátoru, ale je více než 6,5krát pomalejší než druhá. S ohledem na kontext práce, kdy bude algoritmus používán v automatizovaném oftalmologickém centru, je druhá kombinace mnohem vhodnější. Výsledné sady rysů kvality a jejich ROC křivky (4.1) a počet správně klasifikovaných obrazů jsou zobrazeny v 6.5, 6.6, 6.11, 6.12 pro *Own Top 30 AUC*, a v 6.7, 6.8, 6.13, 6.14 pro *EyeQ Top 20 AUC*.

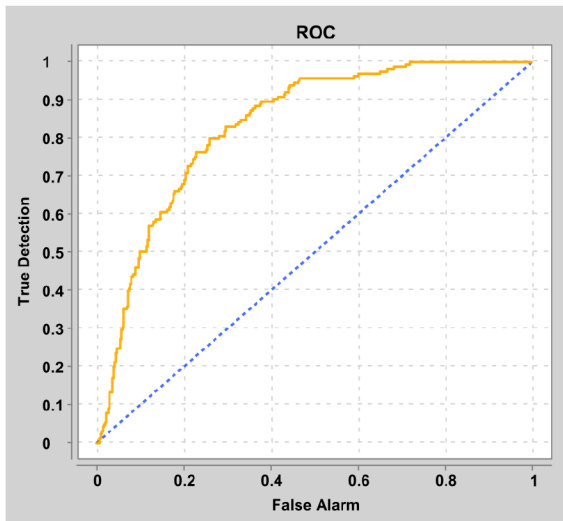
Tabulka 6.5: Seznam rysů kvality pro *Own Top 30 AUC*.

Rys kvality	Obrazový kanál
Energy of Intensity	Saturation Channel R
Energy of Intensity Centered	Saturation Channel R
Variance of Intensity	Grayscale Channel
Difference of Differences	Relative Weight Channel B
Inherited Sharpness	Channel G
Number of Pixels in Second Third	Relative Weight Channel B
Variance of Intensity	Relative Weight Channel B
Mean Intensity	Saturation Channel R
Mean Intensity Centered	Saturation Channel R
Mean Intensity Centered	Relative Weight Channel R
Difference of Differences	Relative Weight Channel G
Energy of Intensity	Relative Weight Channel R
Energy of Intensity Centered	Relative Weight Channel R
Variance of Intensity	Relative Weight Channel R
Mean Intensity	Relative Weight Channel R
Mean Intensity	Relative Weight Channel G
Mean Intensity Centered	Relative Weight Channel G
Energy of Intensity	Relative Weight Channel G
Energy of Intensity Centered	Relative Weight Channel G
Number of Pixels in First Third	Relative Weight Channel B
Effective Number of Neighbours	Relative Weight Channel G
Number of Pixels in Second Third	Relative Weight Channel G
Number of Pixels in First Third	Relative Weight Channel G
Difference of Differences	Channel R
Number of Pixels in First Third	Relative Weight Channel R
Effective Number of Neighbours	Channel G
Effective Number of Neighbours	Channel B
Number of Pixels in Second Third	Relative Weight Channel R
Difference of Differences	Grayscale Channel
Difference of Differences	Relative Weight Channel R


Tabulka 6.6: Počet správně klasifikovaných obrazů, pomoci *Own Top 30 AUC*.

Třídy EyeQ data setu	Počet obrázků	Počet správně klasifikovaných
Good	2029	1802
Usable	444	324
Reject	574	428
Celkem	3047	2554
Třídy vlastního data setu	Počet obrázků	Počet správně klasifikovaných
Good	165	132
Usable	289	248
Reject	112	92
Celkem	566	472






(a) Klasifikátor "Perfektní vs. horší třídy"




(b) Klasifikátor "Použitelný vs. horší třídy"

Obrázek 6.11: Křivky ROC pro *Own Top 30 AUC*. Koeficienty pro vlastní data set.



(a) Klasifikátor "Good vs. horší třídy"



(b) Klasifikátor "Usable vs. horší třídy"


Obrázek 6.12: Křivky ROC pro *Own Top 30 AUC*. Koeficienty pro EyeQ data set.

Tabulka 6.7: Seznam rysů kvality pro *EyeQ Top 20 AUC*.


Rys kvality	Obrazový kanál
Mean Intensity Centered	Relative Weight Channel G
Variance of Intensity	Saturation Channel G
Energy of Intensity	Saturation Channel G
Energy of Intensity Centered	SaturationChannelG
Energy of Intensity	Relative Weight Channel G
Energy of Intensity Centered	Relative Weight Channel G
Number of Pixels in First Third	Relative Weight Channel R
Mean Intensity	Saturation Channel G
Mean Intensity Centered	Saturation Channel G
Kurtosis of Intensity	Saturation Channel G
Variance of Intensity	Relative Weight Channel B
Energy of Intensity Centered	Grayscale Channel
Number of Pixels in First Third	Relative Weight Channel G
Number of Pixels in Third Third	Channel R
Energy of Intensity	Channel R
Energy of Intensity Centered	Channel R
Mean Intensity	Channel R
Difference of Differences	Channel R
Number of Pixels in Second Third	Relative Weight Channel G
Number of Pixels in First Third	Channel R

Tabulka 6.8: Počet správně klasifikovaných obrazů, pomoci *EyeQ Top 20 AUC*.

Třídy EyeQ data setu	Počet obrázků	Počet správně klasifikovaných
Good	2029	1779
Usable	444	352
Reject	574	380
Celkem	3047	2511
Třídy vlastního data setu	Počet obrázků	Počet správně klasifikovaných
Good	165	134
Usable	289	237
Reject	112	82
Celkem	566	489




(a) Klasifikátor "Perfektní vs. horší třídy"




(b) Klasifikátor "Použitelný vs. horší třídy"

Obrázek 6.13: Křivky ROC pro *EyeQ Top 20 AUC*. Koeficienty pro vlastní data set.



(a) Klasifikátor "Good vs. horší třídy"



(b) Klasifikátor "Usable vs. horší třídy"

Obrázek 6.14: Křivky ROC pro *EyeQ Top 20 AUC*. Koeficienty pro EyeQ data set.

Tyto sady parametrů budou sestaveny do dvou samostatných programů pro klasifikaci obrazu, pro každou sadu jeden program. Každý program bude mít v sobě dvě možné sady koeficientů, které jsou zodpovědné za anotaci z různých data setu. Tím byl dokončen úkol vývoje a implementace algoritmu pro hodnocení kvality obrazu sítnice.

### 6.3.5 Nedostatky metod

Největší nevýhodou, na kterou jsem narazil, bylo to, že některé rysy kvality, které měly téměř stejně vysoké hodnoty koeficientu AUC nebo PLS, nemělo smysl vybírat v kombinaci dohromady. Bylo to proto, že při vysoké korelaci mezi nimi vznikala situace, kdy každý z nich správně klasifikoval stejnou část snímků. Když se tedy zkombinoval jeden z těchto rysů kvality, přidání druhého nemělo žádný významný pozitivní vliv. Bohužel výběrové algoritmy popsané v 5.1.4 nejsou na tyto typy situací citlivé. V důsledku toho bychom se v budoucích pracích měli zaměřit na algoritmy, které tuto nevýhodu nemají. Teoreticky to umožní vytvářet rychlejší kombinace, bez "dvojčat".

#### Možné řešení

Jedním z možných řešení této situace je výběr nejkvalitnějších rys kvality na základě výběru "nejlepšího pokrytí". Tato metoda spočívá v určení nejlepšího souboru rysů kvality pomocí AUC a jeho následném použití k určení souborů snímků, které lze pomocí těchto souborů příznaků správně klasifikovat. Po určení souborů správně klasifikovaných snímků je možné vybrat kombinaci, která má největší celkový soubor správně klasifikovaných snímků. Tímto způsobem bude mít kombinace "nejlepší pokrytí".

Tento přístup umožňuje vyloučit "dvojčata" jednotlivých algoritmů, čímž se zabrání přítomnosti neefektivních rysů kvality v kombinacích. Analýza tohoto způsobu výběru nejlepší sady rysů kvality přesahuje rámec této práce, ale je možná na datech získaných v průběhu této práce.

# Kapitola 7

## Závěr

Výsledkem této práce bylo nalezení dvou kombinací parametrů, které se nyní používají jako dva algoritmy pro klasifikaci kvality obrazu lidské sítnice. Jeden je přesnější a druhý rychlejší.

Vedlejším výsledkem bylo porovnání dvou možných přístupů k výběru rysů kvality pro konečné algoritmy odhadu kvality obrazu. Ačkoli použití algoritmu PLS k porovnání různých algoritmů není špatný nápad, oproti prostému porovnání AUC nemá žádné jasné výhody. Metoda relativní účinnosti také není praktická při výběru z velkého počtu rysů kvality, protože konečná váha koeficientů může být rozložena mezi celou velkou řadou algoritmů. Výběr 90% z celkové váhy tak povede k poměrně velkým kombinacím, které nejsou časově efektivní.

Samostatně se nám také podařilo identifikovat společnou nevýhodu obou přístupů: pravděpodobnost vícenásobné volby "duplicitních" algoritmů. Metody popsané v této práci nejsou na takovou situaci citlivé, což je činí méně efektivními v úloze výběru nejefektivnější, ale nejmenší kombinace. Jedním z možných řešení by byl výběr nejkvalitnějších rysů kvality na základě výběru "nejlepšího pokrytí", jak je popsáno v 6.3.5. Toto rozšíření přidává do algoritmu kroky, které zabraňují výběru "dvojčat", což vede k výběru nejlepších kombinací.

Porovnáním výkonnosti jednotlivých algoritmů na snímcích se sníženým rozlišením, byl vytvořen seznam algoritmů rysů kvality, které jsou citlivé na přítomnost šumu v obraze. Pokud máte fotografie s vysokým rozlišením (4K), doporučuji před výpočtem následujících parametrů snížit rozlišení vstupních obrázků: Cumulative Probability of Blur Detection, Difference of Difference, Wavelet Entropy L3 vs Wavelet Entropy L1. Doporučená komprese je 2-4 násobná, protože při této úrovni komprese budou detaily struktury oka stále v pořádku, ale množství šumu se výrazně sníží. Snížením počtu pixelů, které je třeba zpracovat, se také výrazně zvýší rychlost výpočtu.

# Literatura

- [1] ABDEL HAMID, L., EL RAFEI, A., EL RAMLY, S., MICHELSON, G. a HORNEGGER, J. Retinal image quality assessment based on image clarity and content. *Journal of Biomedical Optics*. Zář 2016, sv. 21. DOI: 10.1117/1.JBO.21.9.096007.
- [2] BURNINGHAM, N., PIZLO, Z. a ALLEBACH, J. P. Image Quality Metrics. In: *Encyclopedia of Imaging Science and Technology*. John Wiley & Sons, Ltd, 2002. DOI: <https://doi.org/10.1002/0471443395.img038>. ISBN 9780471443391. Dostupné z: <https://onlinelibrary.wiley.com/doi/abs/10.1002/0471443395.img038>.
- [3] CHO, Y.-J. a KANG, S. *Emerging Technologies for Food Quality and Food Safety Evaluation*. CRC press, 2011. ISBN 1439815240.
- [4] DAVIS, H., RUSSELL, S., BARRIGA, E., ABRAMOFF, M. a SOLIZ, P. Vision-based, real-time retinal image quality assessment. In: Zář 2009, s. 1 – 6. DOI: 10.1109/CBMS.2009.5255437.
- [5] DEPT, O. ARIC Grading Protocol. *F.P.R.C. Visual Sciences of the University of Wisconsin–Madison*. 1995.
- [6] DRAHANSKÝ, M., ORSÁG, F., DOLEŽEL, M. a AL. et. *Biometrie*. 1. vydání. Computer Press, s.r.o, 2011. 294 s. ISBN 978-80-254-8979-6. Dostupné z: <https://www.fit.vut.cz/research/publication/9468>.
- [7] *EyePACS Assessment Dataset* [online]. Kaggle, 2015 [cit. 2022-04-26]. Dostupné z: <https://www.kaggle.com/c/diabetic-retinopathy-detection>.
- [8] *Eye-Quality (EyeQ) Assessment Dataset* [online]. Fu, Huazhu, ř 2019 [cit. 2022-04-26]. Dostupné z: <https://github.com/HzFu/EyeQ>.
- [9] FAIRCHILD, M. D. Color Appearance Models. Munsell Color Science Laboratory Rochester Institute of Technology, USA. 2013, sv. 2.
- [10] FERZLI, R. a KARAM, L. J. A No-Reference Objective Image Sharpness Metric Based on the Notion of Just Noticeable Blur (JNB). *IEEE Transactions on Image Processing*. 2009, sv. 18, č. 4, s. 717–728. DOI: 10.1109/TIP.2008.2011760.
- [11] FORACCHIA, M., GRISAN, E. a RUGGERI, A. Luminosity and contrast normalization in retinal images. *Medical Image Analysis*. 2005, sv. 9, č. 3, s. 179–190. DOI: <https://doi.org/10.1016/j.media.2004.07.001>. ISSN 1361-8415. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1361841504000556>.

- [12] FRANGI, A. F., NIESSEN, W. J., VINCKEN, K. L. a VIERGEVER, M. A. Multiscale vessel enhancement filtering. In: WELLS, W. M., COLCHESTER, A. a DELP, S., ed. *Medical Image Computing and Computer-Assisted Intervention — MICCAI'98*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1998, s. 130–137. ISBN 978-3-540-49563-5.
- [13] FU, H., WANG, B., SHEN, J., CUI, S., XU, Y. et al. Evaluation of Retinal Image Quality Assessment Networks in Different Color-Spaces. In: říjen 2019, s. 48–56. DOI: 10.1007/978-3-030-32239-7\_6. ISBN 978-3-030-32238-0.
- [14] GAO, X., LU, W., TAO, D. a LIU, W. Image quality assessment and human visual system. *Proceedings of SPIE - The International Society for Optical Engineering*. Červenec 2010, sv. 7744. DOI: 10.1117/12.862431.
- [15] HELMENSTINE, A. M. *Structure and Function of the Human Eye*. [online]. ThoughtCo., prosinec 2019 [cit. 2022-11-18]. Dostupné z: <https://www.thoughtco.com/how-the-human-eye-works-4155646>.
- [16] *Methodologies for the subjective assessment of the quality of television images*. Standard. Geneva, CH: International Telecommunication Union, leden 2012.
- [17] KUMAR, J., CHEN, F. a DOERMANN, D. Sharpness estimation for document and scene images. In: *Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012)*. 2012, s. 3292–3295.
- [18] KÖHLER, T., BUDAI, A., KRAUS, M., ODSTRČILIK, J., MICHELSON, G. et al. Automatic no-reference quality assessment for retinal fundus images using vessel segmentation. In: červen 2013, s. 95–100. DOI: 10.1109/CBMS.2013.6627771.
- [19] LIANG, J. a WILLIAMS, D. R. Aberrations and retinal image quality of the normal human eye. *J. Opt. Soc. Am. A*. Optica Publishing Group. Nov 1997, sv. 14, č. 11, s. 2873–2883. DOI: 10.1364/JOSAA.14.002873. Dostupné z: <https://opg.optica.org/josaa/abstract.cfm?URI=josaa-14-11-2873>.
- [20] LIAO, W.-H. A Sharpness Measure for Image Quality Assessment Using Average Effective Number of Neighbors. In: *2013 Conference on Technologies and Applications of Artificial Intelligence*. 2013, s. 152–157. DOI: 10.1109/TAAI.2013.40.
- [21] LV, X., QIN, M., CHEN, X. a WEI, G. No-reference image quality assessment based on statistics of convolution feature maps. *AIP Conference Proceedings*. 2018, sv. 1955, č. 1, s. 040034. DOI: 10.1063/1.5033698.
- [22] MARZILIANO, P., DUFAUX, F., WINKLER, S. a EBRAHIMI, T. Perceptual blur and ringing metrics: application to JPEG2000. *Signal Processing: Image Communication*. 2004, sv. 19, č. 2, s. 163–172. DOI: <https://doi.org/10.1016/j.image.2003.08.003>. ISSN 0923-5965. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0923596503000924>.
- [23] NARVEKAR, N. D. a KARAM, L. J. A No-Reference Image Blur Metric Based on the Cumulative Probability of Blur Detection (CPBD). *IEEE Transactions on Image Processing*. 2011, sv. 20, č. 9, s. 2678–2683. DOI: 10.1109/TIP.2011.2131660.

- [24] *The Pillars of Creation* [online]. National Aeronautics and Space Administration, únor 2018 [cit. 2022-05-01]. Dostupné z: <https://www.nasa.gov/image-feature/the-pillars-of-creation>.
- [25] NIRMALA, S., DANDAPAT, S. a BORA, P. Wavelet weighted blood vessel distortion measure for retinal images. *Biomedical Signal Processing and Control*. 2010, sv. 5, č. 4, s. 282–291. DOI: <https://doi.org/10.1016/j.bspc.2010.06.005>. ISSN 1746-8094. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1746809410000467>.
- [26] PRAHL, S. *Optical Absorption of Hemoglobin* [online]. OMLC, 1999 [cit. 2022-11-13]. Dostupné z: <https://omlc.org/spectra/hemoglobin/>.
- [27] PATTON, N., ASLAM, T., MACGILLIVRAY, T., DEARY, I., DHILLON, B. et al. Retinal image analysis: Concepts, applications and potential. *Progress in retinal and eye research*. Únor 2006, sv. 25, s. 99–127. DOI: 10.1016/j.preteyeres.2005.07.001.
- [28] PAULUS, J., MEIER, J., BOCK, R., HORNEGGER, J. a MICHELSON, G. Automated quality assessment of retinal fundus photos. *International journal of computer assisted radiology and surgery*. Listopad 2010, sv. 5, s. 557–64. DOI: 10.1007/s11548-010-0479-7.
- [29] PIRES DIAS, J. M., OLIVEIRA, C. M. a DA SILVA CRUZ, L. A. Retinal image quality assessment using generic image quality indicators. *Information Fusion*. 2014, sv. 19, s. 73–90. DOI: <https://doi.org/10.1016/j.inffus.2012.08.001>. ISSN 1566-2535. Special Issue on Information Fusion in Medical Image Computing and Systems. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1566253512000656>.
- [30] RYU, S. a SOHN, K. No-reference sharpness metric based on inherent sharpness. *Electronics Letters*. Listopad 2011, sv. 47, s. 1178 – 1180. DOI: 10.1049/el.2011.2222.
- [31] SOPHARAK, A., UYYANONVARA, B., BARMAN, S. a WILLIAMSON, T. Automatic Microaneurysm Detection from Non-dilated Diabetic Retinopathy Retinal Images. *Lecture Notes in Engineering and Computer Science*. Červenec 2011, sv. 2191.
- [32] STAAL, J., ABRÀMOFF, M., NIEMEIJER, M., VIERGEVER, M. a GINNEKEN, B. Ridge-Based Vessel Segmentation in Color Images of the Retina. *IEEE transactions on medical imaging*. Duben 2004, sv. 23, s. 501–9. DOI: 10.1109/TMI.2004.825627.
- [33] *Stavba oka* [online]. symptom.cz [cit. 2022-11-28]. Dostupné z: <https://www.symptom.cz/anatomie/oci/stavba-oka.jpg>.
- [34] STREIJL, R. C., WINKLER, S. a HANDS, D. S. Mean opinion score (MOS) revisited: methods and applications, limitations and alternatives. *Multimedia Systems*. 2014, sv. 22, s. 213–227.
- [35] WALSH, J. B. Hypertensive Retinopathy: Description, Classification, and Prognosis. *Ophthalmology*. 1982, sv. 89, č. 10, s. 1127–1131. DOI: [https://doi.org/10.1016/S0161-6420\(82\)34664-3](https://doi.org/10.1016/S0161-6420(82)34664-3). ISSN 0161-6420. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0161642082346643>.



- [36] WANG, Z., BOVIK, A., SHEIKH, H. a SIMONCELLI, E. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*. 2004, sv. 13, č. 4, s. 600–612. DOI: 10.1109/TIP.2003.819861.
- [37] WANG, Z. a SIMONCELLI, E. Reduced-reference image quality assessment using a wavelet-domain natural image statistic model. In: ROGOWITZ, B. E., PAPPAS, T. N. a DALY, S. J., ed. *Human Vision and Electronic Imaging X*. SPIE, 2005, sv. 5666, s. 149 – 159. DOI: 10.1117/12.597306. Dostupné z: <https://doi.org/10.1117/12.597306>.
- [38] *Blindness and vision impairment* [online]. The World Health Organization, říjen 2022 [cit. 2022-11-13]. Dostupné z: <https://www.who.int/news-room/fact-sheets/detail/blindness-and-visual-impairment>.
- [39] WOLD, H. Estimation of Principal Components and Related Models by Iterative Least Squares. *Journal of Multivariate Analysis - MA*. Leden 1966, sv. 1.
- [40] WOLD, H. Path models with latent variables: The NIPALS approach. *Quantitative sociology: International perspectives on mathematic and statistical modeling*. Prosinec 1975. DOI: 10.1016/B978-0-12-103950-9.50017-4.
- [41] WOLD, S. Personal memories of the early PLS development. *Chemometrics and Intelligent Laboratory Systems - CHEMOMETR INTELL LAB SYST*. Říjen 2001, sv. 58, s. 83–84. DOI: 10.1016/S0169-7439(01)00152-6.
- [42] WONG, C., LAMOUREUX, E., CHENG, C.-y., CHEUNG, C. M. G., TAI, E.-S. et al. Increased Burden of Vision Impairment and Eye Diseases in Persons with Chronic Kidney Disease — A Population-Based Study. *EBioMedicine*. Leden 2016, sv. 5. DOI: 10.1016/j.ebiom.2016.01.023.
- [43] YU, H., AGURTO, C., BARRIGA, S., NEMETH, S., SOLIZ, P. et al. Automated image quality evaluation of retinal fundus photographs in diabetic retinopathy screening. In: Duben 2012, s. 125–128. DOI: 10.1109/SSIAI.2012.6202469.
- [44] ZHU, X. a MILANFAR, P. Automatic Parameter Selection for Denoising Algorithms Using a No-Reference Measure of Image Content. *IEEE transactions on image processing : a publication of the IEEE Signal Processing Society*. Prosinec 2010, sv. 19, s. 3116–32. DOI: 10.1109/TIP.2010.2052820.