

**ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE**

**Fakulta elektrotechnická**

**Katedra radioelektroniky**



Diplomová práce

Hodnocení kvality obrazu v systémech s vysokým  
dynamickým rozsahem

Image Quality Assessment in High Dynamic Range  
Systems

**Květen 2015**

**Autor práce:**

**Bc. Jan Oravec**

**Vedoucí práce:**

**Ing. Lukáš Krasula**

České vysoké učení technické v Praze  
Fakulta elektrotechnická  
katedra radioelektroniky

## ZADÁNÍ DIPLOMOVÉ PRÁCE

Student: **Bc. Jan Oravec**

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

Název tématu: **Hodnocení kvality obrazu v systémech s vysokým dynamickým rozsahem**

Pokyny pro vypracování:

Podejte přehled metod pro snímání a reprodukci obrazu s vysokým dynamickým rozsahem HDR (High Dynamic Range). Zaměřte se zejména na pokročilé algoritmy pro mapování tónů a metody pro subjektivní a objektivní hodnocení kvality snímků po aplikaci těchto algoritmů. Provedte subjektivní test na vybrané sadě snímků a ověřte na ní účinnost zvolených objektivních metod.

Seznam odborné literatury:

[1] Reinhard, E., Ward, G., Pattanaik, S., Debevec, P., Heidrich, W., and Myszkowski, K., High Dynamic Range Imaging: Acquisition, Display, and Image-Based Lighting, CA: Morgan Kaufmann, 2010.

[2] Keelen, B. W., Handbook of Image Quality, Marcel Dekker, 2002.

Vedoucí: Ing. Lukáš Krasula

Platnost zadání: do konce zimního semestru 2015/2016



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

prof. Ing. Pavel Ripka, CSc.  
děkan

V Praze dne 3. 9. 2014

# Poděkování

Rád bych poděkoval svému vedoucímu Ing. Lukáši Krasulovi za pravidelné konzultace, trpělivost a ochotu, kterou mi v průběhu zpracování diplomové práce věnoval. Díky patří všem, kteří se podíleli na hodnocení testovacích obrazů. Na závěr bych chtěl poděkovat svým blízkým za trpělivost a veškerou podporu v období tvorby.

# Čestné prohlášení

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

V Kralupech nad Vltavou dne 4. 5. 2015

.....

Bc. Jan Oravec

# **Abstrakt**

V úvodu této diplomové práce jsou popsány metody pro snímání a reprodukci obrazu s vysokým dynamickým rozsahem HDR (High Dynamic Range). Je zde kladen důraz na algoritmy pro mapování tónů – byly vybrány čtyři pokročilé algoritmy, jenž byly detailně popsány. V této práci byl současně podán přehled metod pro hodnocení kvality obrazu. Ze subjektivních metod byla vybrána jedna, u které se předpokládalo, že poskytne nejspolehlivější výsledky v dané aplikaci. Na základě této metody byl proveden subjektivní test a následně bylo vybráno několik objektivních metrik, jejichž účinnost byla ověřena vzhledem k subjektivním výsledkům.

## **Klíčová slova**

Obrazy s vysokým dynamickým rozsahem (HDR), mapování tónů (TMO), hodnocení kvality obrazu, subjektivní testy, objektivní metriky

# **Abstract**

In the introduction of this master thesis, methods for capture and reproduction of images with high dynamic range (HDR) are described. Special attention is paid to the tone mapping algorithms – four advanced algorithms were selected and described in detail. An overview of image quality assessment methods is also provided in this thesis. One subjective method, which was supposed to ensure the most reliable results in the given application, was selected and based on this method, a subjective test was conducted. Further on, several objective metrics were selected and their performances were compared with respect to the subjective results.

## **Keywords**

High dynamic range images (HDR), tone mapping operators (TMO), image quality assesment, subjective tests, objective metrics

# Seznam zkratek

ACR	Absolute Category Rating
AGGD	Asymetric Gaussian Distribution
BIQA	Blind Image Quality Assesment
BRISQUE	Blind Referenceless Image Spatial Quality Evaluator
BT	Bradley-Terry model
CAM02	Color Apearance Model
CAT02	Chromatic Adaption Transform
CB	Completely Blind
CCD SR	Charged-coupled Device Super Dynamic Range
CIE	International Commission on Illumination
CS	Contourlet Transform and Singular Value Decomposition
DA	Distortion Aware
DCR	Degradation Category Rating
DFB	Directional Filter bank
DMOS	Difference Mean Opinion Score
DRIM	Dynamic Range Independent Image Quality Assessment
DSCQS	Double Stimulus Continuous Quality Scale
DSIS	Double Stimulus Impairment Scale
DU	Distortion Unaware
FR	Full Reference
GGD	General Gaussian Distribution
GM	Gradient Magnitude
GND	Gradual Neutral Density
HDR	High Dynamic Range
HPE	Hunt-Pointer-Estévez
iCAM	image Color Appearance Model
JAN	Joint Adaptive Normalization
LDR	Low Dynamic Range
LMS	Long Medium Short
LOG	Laplacian of Gaussian
LVS	lidský vizuální systém
MATLAB	Matrix Laboratory
MSCN	Mean-Subtracted Contrast-Normalized
MVG	Multivariate Gaussian Model
NIQE	Natural Image Quality Evaluator
NR	No Reference

NSS	Natural Scene Statistics
OECF	Opto Electronic Conversion Function
PC	Pair Comparison Method
SC	Stimulus Comparison
SDSCE	Simultaneous Double Stimulus for Continous Evaluation
SS	Single Stimulus
SSCQE	Single Stimulus Continuous Quality Evaluation
SSIM	Structural Similarity
SVD	Singular-Value Decomposition
SVR	Support Vector Regression
TMO	Tone Mapping Operators
TMQI	Tone-mapped Image Quality Index



# Obsah

<b>1</b>	<b>Úvod</b> .....	<b>1</b>
<b>2</b>	<b>Snímání obrazu s vysokým dynamickým rozsahem</b> .....	<b>2</b>
2.1	Použití přechodového filtru .....	2
2.2	Modifikace snímacího čipu .....	2
2.3	Specializované snímací zařízení .....	3
2.4	Metoda HDR – snímání vícenásobnou expozicí .....	3
2.4.1	Rekonstrukce HDR snímku .....	4
2.4.2	Převodní charakteristika digitálního fotoaparátu .....	4
<b>3</b>	<b>Algoritmy pro mapování tónů</b> .....	<b>6</b>
3.1	Dragovo logaritmické mapování .....	6
3.1.1	Převod jasu na vnímaný jas .....	7
3.1.2	Nastavení kontrastu .....	7
3.1.3	Algoritmus .....	8
3.1.4	Gamma korekce .....	9
3.1.5	Dragův operátor – shrnutí .....	9
3.2	iCAM06 .....	9
3.2.1	Vstupní data .....	9
3.2.2	Rozklad obrazu .....	10
3.2.3	Bilaterální filtr – základní a detailní vrstva .....	10
3.2.4	Chromatická adaptace .....	11
3.2.5	Komprese tónů .....	12
3.2.6	Detailní vrstva – Stevensův efekt .....	13
3.2.7	IPT transformace .....	14
3.2.8	Úprava IPT .....	14
3.2.9	Výsledný mapovaný obraz .....	15
3.3	Reinhard .....	15
3.3.1	Algoritmus .....	16
3.3.2	Počáteční mapování jasu .....	16
3.3.3	Ztmavování a zesvětlování .....	18
3.3.4	Reinhardův operátor – shrnutí .....	19
3.4	Snížení dynamického rozsahu inspirované fyziologií fotoreceptorů - Reinhard a Devlinová ....	20
3.4.1	Algoritmus .....	20
3.4.2	Kontrast .....	20
3.4.3	Intenzita .....	21
3.4.4	Barevná a světelná adaptace .....	22
3.4.5	Operátor podle Reinharda a Devlinové – shrnutí .....	23
<b>4</b>	<b>Hodnocení kvality obrazu</b> .....	<b>24</b>
4.1	Metody subjektivního hodnocení .....	24
4.1.1	Standard ITU-R BT.500 .....	24
4.1.2	Standard ITU-T P.910 .....	26
4.2	Metody objektivního hodnocení .....	27
<b>5</b>	<b>Vybrané metody objektivního hodnocení</b> .....	<b>28</b>
5.1	TMQI – objektivní hodnocení kvality operátorů pro mapování tónů .....	28
5.1.1	Strukturální similarita .....	28
5.1.2	Aplikace algoritmu strukturální similarity .....	30
5.1.3	Statistická přirozenost .....	31
5.1.4	Model hodnocení kvality .....	32
5.2	NIQE – hodnocení kvality obrazu nezávislého na zobrazení obrazu .....	33
5.3	BIQA – slepé hodnocení využívající spojení statistiky magnitudy gradientu a Laplaceových příznaků .....	36

5.3.1	GM a LOG příznaky.....	36
5.3.2	Normalizace JAN .....	37
5.3.3	Vyhodnocení příznaků.....	38
5.3.4	Modely metody.....	39
5.4	CS – univerzální hodnocení kvality obrazu pomocí contourlet transformace a singulární dekompozice.....	40
5.4.1	Contourlet transformace .....	40
5.4.2	SVD a singulární křivka .....	41
5.4.3	Hodnotící indexy .....	42
5.5	DRIM – hodnocení kvality nezávisle na dynamickém rozsahu .....	42
5.5.1	Typy zkreslení podle prahu detekce .....	42
5.5.2	Ukázka hodnocení metody DRIM .....	44
<b>6</b>	<b>Porovnávání TMO.....</b>	<b>46</b>
6.1	Výsledky subjektivních testů .....	46
6.1.1	Souhrn výsledků porovnávání TMO .....	50
6.2	Vyhodnocení objektivních testů.....	50
6.2.1	Hodnocení TMQI .....	50
6.2.2	Hodnocení NIQE .....	52
6.2.3	Hodnocení BIQA.....	53
6.2.4	Hodnocení CS.....	54
6.2.5	Hodnocení DRIM .....	55
6.3	Účinnost objektivních metod .....	56
6.3.1	Hodnocení účinnosti objektivních metod .....	57
<b>7</b>	<b>Závěr .....</b>	<b>60</b>
	<b>Apendix .....</b>	<b>61</b>
	<b>Obsah přiloženého DVD .....</b>	<b>67</b>
	<b>Použitá literatura.....</b>	<b>68</b>
	<b>Seznam obrázků .....</b>	<b>73</b>
	<b>Seznam tabulek.....</b>	<b>74</b>

# 1 Úvod

Digitální obraz si rychle našel svou cestu do přístrojů, které každodenně využíváme. S obrazem v digitální podobě se setkáváme na každém kroku ve svých mobilních telefonech, tabletech, obrazovkách, televizích a dalších zobrazovacích zařízeních. Kvalita digitálního obrazu už není pouze houbou za maximálním rozlišením. Do popředí se dostává věrné zobrazení scény a s ním spojená reprodukce obrazu s vysokým dynamickým rozsahem (HDR).

Tato diplomová práce nejprve popisuje snímání HDR obrazu, se kterým úzce souvisí jejich reprodukce. HDR obrazy nelze zobrazit na standardních zobrazovacích zařízeních kvůli vyššímu dynamickému rozsahu HDR obrazu, než jsou zobrazovače schopny zobrazit. HDR obraz je zapotřebí převést do zobrazitelné podoby LDR obrazu (Low Dynamic Range). Od LDR obrazu se očekává zachování detailů ve všech světelných podmínkách scény obrazu. K tomuto účelu slouží metody pro mapování tónů TMO (Tone Mapping Operators), jejichž výsledky jsou různé. Jelikož existuje mnoho TMO, práce se zaměřuje na ty pokročilejší. Každý operátor poskytuje mnoho způsobů vykreslení LDR obrazu díky nastavení jeho parametrů. Proto bylo testováno více nastavení parametrů operátorů na HDR snímcích. Vzniklé obrazy následně posloužily jako podklad pro subjektivní testy realizované na skupině pozorovatelů.

Na základě subjektivních testů provedených na pozorovatelích byla stanovena kvalita LDR obrazů. Jelikož jsou subjektivní testy časově náročné, proto je dnešním trendem navrhování a hledání objektivní metody hodnocení kvality HDR obrazu, která se bude shodovat s názory pozorovatelů. Doposud nebyla objevena metoda, jež by našla shodu mezi objektivními metodami a subjektivními metodami. Existuje metoda, která odpovídá subjektivnímu vnímání? Cílem práce je najít odpověď na tuto otázku.

Práce je rozdělena na pět hlavních částí. První část popisuje metody snímání HDR obrazu. Ve druhé části je probrána problematika převodu snímků do nižšího dynamického rozsahu. Byl vybrán Dragův operátor [1], operátor iCAM06 [2], Reinhardův operátor [3] a operátor Reinhard-Devlin [4]. Ve třetí části byly probrány standardy ITU-R BT.500 a ITU-T P.910 [5] pro subjektivní posouzení kvality mapovaných obrazů. Čtvrtá část je zaměřena na objektivní metody hodnocení TMQI [6], NIQE [7], BIQA [8], CS [9] a DRIM [10]. V páté části jsou zpracovány výsledky subjektivních a objektivních testů a vyhodnocení účinnosti objektivních metod.

## 2 Snímání obrazu s vysokým dynamickým rozsahem

Technologie HDR (High Dynamic Range) [11] slouží k pořizování fotografií s vyšším dynamickým rozsahem, než je možno dosáhnout klasickým způsobem fotografování. Zpočátku je třeba si položit základní otázku – proč je třeba zvyšovat dynamický rozsah a má-li toto výraznější význam.

Většina obrazů je 8-bitových a každá ze tří barevných složek představuje rozsah jasů od 0 do 255. Pro světelně složitější scény je tento rozsah nedostačující a dochází ke ztrátě detailů. Typickým příkladem je focení západu slunce nebo jiného světelného zdroje. Výsledná fotografie je zpravidla přeexponovaná v místě světelného zdroje a zbytek scény ztrácí detaily. Jak zachytit scénu v plném dynamickém rozsahu? V následujících kapitolách bude rozebráno několik technik řešících zmíněné problémy.

### 2.1 Použití přechodového filtru

Přechodový filtr GND (Gradual Neutral Density) [12] dokáže ztmavit polovinu fotografované scény, zatímco druhou ponechá beze změn. Přechod je pozvolný a při správném použití není na fotografii pozorovatelný. Typickým příkladem je fotografování krajiny s oblohou, kde použijeme tmavou část filtru na oblohu, která se svým jasnem přiblíží ke zbytku scény, čímž zvýšíme její dynamický rozsah (Obr. 2.1.1). Taková úprava však může být použita pouze na scénu, kde je rozložení jasů lineární s jedním přechodem.




Obr. 2.1.1 Scéna vyfotografovaná s přechodovým filtrem a bez něj [12]

### 2.2 Modifikace snímacího čipu

Modifikací snímacího čipu lze taktéž dosáhnout většího dynamického rozsahu. Tyto čipy používají například fotoaparáty značky Fuji – Super CCD SR [13]. Na první pohled se liší svou plochou snímacích buněk osmiúhelníkového tvaru. Každá buňka se

skládá ze dvou různě citlivých fotodiód. Větší fotodióda zachycuje tmavé a normální úrovně jasů, sekundární fotodióda zachycuje jasnější úrovně.




Obr. 2.2.1 Super CCD [13]

### 2.3 Specializované snímací zařízení

Výrobce JAI přišel na trh s dalším možným řešením snímání HDR. Jedná se o kameru<sup>1</sup> s dělicím hranolem a dvěma CCD snímači, které se dají individuálně kalibrovat. Jeden může zachycovat například detaily ve světlejších oblastech scény a druhý snímač zachytí identický obraz s důrazem na tmavší detaily. Takto je kamera schopna snímat dynamický rozsah více jak 20 bit na pixel.

### 2.4 Metoda HDR – snímání vícenásobnou expozicí

Metoda snímání scény s vysokým dynamickým rozsahem používá více rozdílně exponovaných snímků, které je poté nutno dále zpracovat [11]. Vysokého rozsahu se dosáhne vícenásobným nasnímáním scény, kdy se pomocí nastavení různé délky expozice ovlivňuje množství světla dopadajícího na snímač. Tím se získá série fotografií, z nichž podexponované snímky (kratší čas expozice) nesou informaci o částech scény s vysokým jasnem, zatímco přexponované snímky (delší čas expozice) zajišťují detaily v tmavých místech.



Obr. 2.4.1 Vícenásobná expozice jedné scény

Vzhledem k tomu, že tvorba HDR obrazu vyžaduje sérii totožně umístěných snímků, byl použit stativ, aby se zamezilo pohybu fotoaparátu. Ideální je, pokud se ve scéně nevyskytují pohyblivé objekty. Po konečném složení snímků může výsledný

<sup>1</sup> JAI. *JAI introduces HDR camera with GigE Vision interface* [online]. [cit. 2015-04-14]. Dostupné z: <http://www.jai.com/en/newsevents/news/jai-hdrcamera-withgige-interface>

obraz v případě výskytu pohybujících se lidí obsahovat neostré objekty, tzv. duchy. Případ neostrého objektu je zobrazen na mapovaném obrazu na Obr. 2.4.2. Rozmazání kouře z komínu bylo způsobeno vícenásobnou expozicí a také expozicí dlouhou až 20 s.



**Obr. 2.4.2** HDR snímek, příklad rozmazání kouře v oblasti komínu

Při snímání se nejprve nastaví citlivost a clona automatickou fotoaparátu. Následně se zmrazí citlivost, clona, autofokus a exponuje se série snímků po jednotlivých krocích. Snímky, které byly použity v této práci pro uskutečnění všech testů, jsou v appendixu na konci této práce.

#### **2.4.1 Rekonstrukce HDR snímku**

Pokud je k dispozici série fotografií, může se přistoupit k vlastnímu převodu do HDR snímku. Ten se skládá z rekonstrukce mapy jasů dané scény a následného mapování jasů do zobrazitelného formátu.


Pro rekonstrukci mapy jasů je důležitá převodní charakteristika digitálního fotoaparátu, neboť nám říká, jaký jas zaznamenává snímač fotoaparátu při daném jasu scény. Z inverzní funkce a hodnot jasů pixelů ze všech snímků se dá odvodit kompletní mapa osvětlení čipu, přičemž se využívá váhování jasů obrazu – jasy blízké saturaci mají menší váhu. Nutno podotknout, že při sčítání snímků dochází též k potlačení časově proměnného šumu, což vede ke zkvalitnění výsledku.

#### **2.4.2 Převodní charakteristika digitálního fotoaparátu**


Pro měření optické převodní charakteristiky fotoaparátu (OECF) se používá testovací obrazec Daneš Picta DCG2 podle normy ISO 14524 [14]. Na Obr. 2.4.3 je znázorněna sekvence nasnímaných fotografií. Odečtou se průměrné jasy jednotlivých terčků na všech snímcích. Převodní charakteristika je dána závislostí logaritmu expozice  $\log_{10}H/H_0$  a jasu.  $H_0$  je vztažná úroveň expozice  $H_0 = 1 \text{ lx}\cdot\text{s}$ . Expozice  $H_i \text{ [lx}\cdot\text{s]}$  pro každý jednotlivý terčik je dána vztahem

$$H_i = E_i \cdot t_{\text{exp}}, \quad (2.1.1)$$

kde  $t_{\text{exp}}$  [s] značí dobu expozice a  $E_i$  [lx] příslušnou hodnotu osvětlení od daného terčíku.



**Obr. 2.4.3** Sekvence snímků pro měření převodní charakteristiky



**Obr. 2.4.4** Převodní charakteristika fotoaparátu Nikon D70 pro kanály R, G a B

### 3 Algoritmy pro mapování tónů

Samotný HDR obraz není možné zobrazit na běžných zobrazovacích zařízeních, proto se musí provést převod do zobrazitelného LDR (Low Dynamic Range) formátu. Pro převod do LDR obrazu slouží operátory pro mapování tónů (TMO – Tone Mapping Operators). Operátory lze rozdělit na dvě základní skupiny – globální a lokální.

Globální operátory přistupují k obrazovému bodu nezávisle na jeho okolí [11]. Stejná převodní charakteristika je použita pro celý obraz. Globální operátory jsou výpočetně nenáročné a hodí se i pro zpracování videa.

Lokální operátory zohledňují okolí obrazového bodu. Fungují podobně jako lidský vizuální systém a jsou schopny se adaptovat na jas v konkrétním místě ve scéně. Bývají zpravidla výpočetně náročnější a jsou náchylnější na vznik nepřírodných artefaktů v obraze.

Náplní této kapitoly je popis čtyř operátorů. Zástupcem globálních operátorů je Drago [1], Reinhard [3] a Reinhard-Devlin [4]. Reinhardův operátor má dvě varianty, globální i lokální. Čistě lokální operátor je iCAM06 [2].

#### 3.1 Dragovo logaritmické mapování

Dragův operátor [1] vychází z vlastností lidského vizuálního systému (LVS), který je logaritmický. Odezvou LVS na jas objektu je vnímaný jas  $B$ . Vnímaný jas  $B$  je aproximován logaritmickou funkcí dle Weber-Fechnerova zákona vztahem

$$B = k_1 \cdot \ln \frac{L}{L_o}, \quad (3.1.1)$$

kde  $L_o$  představuje jas pozadí a  $k_1$  je konstanta. Dragův operátor vychází z upraveného vztahu

$$L_d = \frac{\log_b(L_w + 1)}{\log_b(L_{max} + 1)}. \quad (3.1.2)$$

$L_d$  je hodnota pixelu daná poměrem celkového jasu  $L_w$  a maximálního jasu  $L_{max}$ .  $L_w$  je zprůměrovaný jas HDR scény. Odvození  $L_w$  je uvedeno dále v této kapitole, viz vztah (3.1.6).  $L_{max}$  je maximální jas scény. Dynamický rozsah scény může být libovolně velký. Díky poměru  $L_w$  a  $L_{max}$  je zajištěno, že nejvyšší hodnoty budou odpovídat bílé barvě a další jasové hodnoty budou plynule odstupňovány.



### 3.1.1 Převod jasu na vnímaný jas

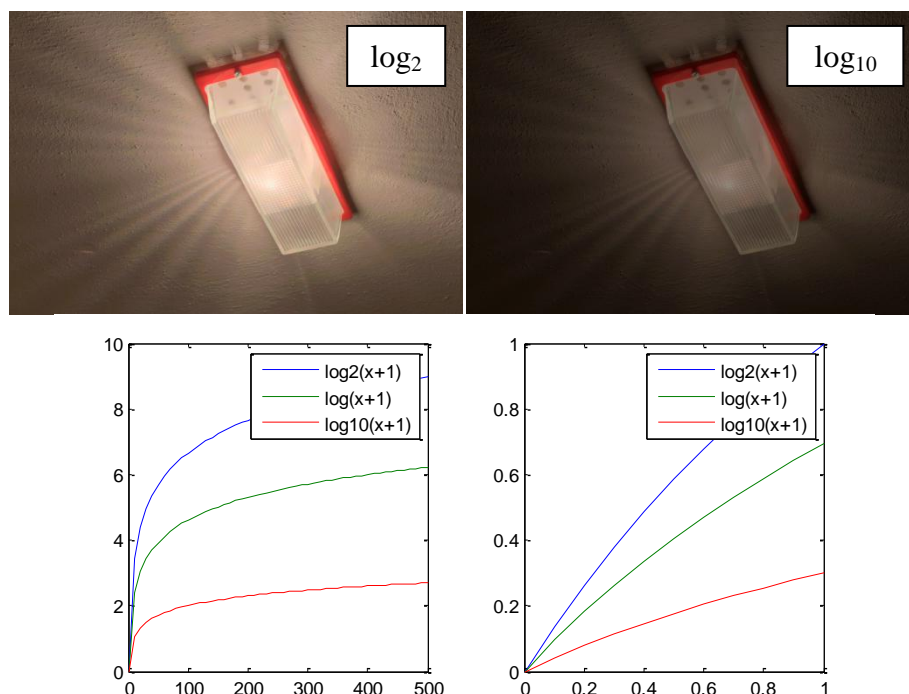
Celkový vnímaný jas výstupního obrazu závisí především na světelných podmínkách scény. Z tohoto důvodu je nutné najít koeficient, který stanoví vztah mezi jasem a vnímaným jasnem výstupního obrazu. Dragův operátor vychází z analogie nastavení automatické expozice fotoaparátů. Měření expozice může být maticové, celoplošné se zdůrazněným středem, středové nebo bodové. Operátor počítá váhovací koeficient, který je průměrem všech jasových hodnot scény v logaritmické rovině. Tumblin a Rushmeier [15] nazvali tento váhovací koeficient „world adaptation luminance“. Zde je uváděn jako  $L_{wa}$  a představuje celkový jas scény, na který se LVS adaptuje. Účelem je zachovat stejný dojem vnímaného jasu  $B$ .

### 3.1.2 Nastavení kontrastu

Dragův operátor využívá logaritmické komprese vstupních jasů, přičemž základ logaritmu je upravován pro každý pixel samostatně. Základ logaritmu  $b$  se nastavuje od 2 do 10, maximální a minimální hodnoty snímku jsou mírně potlačovány [15].

$$\log_b(x) = \frac{\log_{10}(x)}{\log_{10}(b)}. \quad (3.1.3)$$


Vliv rozdílných základů je demonstrován na Obr. 3.1.1. Funkce  $\log_2$  zajišťuje dobrý kontrast a viditelnost v tmavých oblastech, zatímco  $\log_{10}$  zajistí lepší kontrast ve světlých oblastech [1].




Obr. 3.1.1 Vliv funkce  $\log_2$  a  $\log_{10}$

Aby se mezi základy logaritmu přecházelo plynule a využily se výhody funkcí s rozdílnými základy, použije se Perlin-Hofferova [16] exponenciální funkce.

$$\text{bias}_b(t) = t^{\log(b)/\log(0,5)}. \quad (3.1.4)$$



Obr. 3.1.2 Vliv parametru  $b$ : a)  $b = 0,65$ , b)  $b = 0,75$ , c)  $b = 0,85$



Obr. 3.1.3 Parametr  $b$  nastavuje sklon funkce *bias*.

### 3.1.3 Algoritmus

Dosazením předchozích vztahů (3.1.4) a (3.1.4) do vztahu pro luminanci  $L_d$  získáme výslednou rovnici.

$$L_d = \frac{L_{dmax} \cdot 0,01}{\log_{10}(L_{wmax} + 1)} \cdot \frac{\log_b(L_w + 1)}{\log_{10} \left[ 2 + 8 \left( \left( \frac{L_w}{L_{wmax}} \right)^{\log_{10}(b)/\log_{10}(0,5)} \right) \right]}. \quad (3.1.5)$$

Maximální zobrazitelná jasová hodnota  $L_{dmax}$  je zadána uživatelem, typicky  $100 \text{ cd/m}^2$ . Hodnota  $L_{dmax}$  by měla odpovídat maximální zobrazitelné hodnotě displeje. Parametr  $b$  je mezi 0,6 a 0,9.  $L_w$  a  $L_{wmax}$  jsou hodnoty váhované koeficientem  $L_{wa}$ . Koeficient  $L_{wa}$  je vypočítán jako logaritmus střední hodnoty z jasů HDR snímku.

$$L_w = \frac{L_{-wa}}{(1 + b - 0,85)^5}, \quad (3.1.6)$$

$$L_{-wa} = \frac{L}{L_{wa}}, \quad (3.1.7)$$

$$L_{wmax} = \frac{L_{max}}{L_{wa}}. \quad (3.1.8)$$

### 3.1.4 Gamma korekce

Monitor je nelineární zobrazovací zařízení. Ke správnému zobrazení se doporučuje použít koeficient gamma korekce  $\gamma = 2,2$ . Dragův operátor používá převodní charakteristiku ze standardu ITU-R BT.709.

### 3.1.5 Dragův operátor – shrnutí

Dragův operátor je založen na lidském vizuálním systému. Byl navržen pro zobrazení obrazů s vysokým dynamickým rozsahem. Využívá vlastností logaritmického vizuálního vnímání za pomoci logaritmické funkce o různých základech. Funkce  $\log_2$  je uplatňována především v tmavých oblastech a funkce  $\log_{10}$  naopak komprimuje světlá místa v obraze. Pro operátor je doporučeno navíc aplikovat gamma korekci pro vizualizaci na zobrazovacích zařízeních. Operátor si klade malé nároky na výpočetní náročnost, lze jej použít i pro zpracování videí.

## 3.2 iCAM06

Metodu iCAM06 navrhl J. Kuang společně s dalšími autory[2]. Vychází z frameworku iCAM (image Color Appearance Model) [17] a snaží se napodobit LVS. Metoda je zástupcem lokálních operátorů, dokáže se adaptovat na jas v konkrétním místě ve scéně a zohledňuje své okolí.

### 3.2.1 Vstupní data

Do modelu vstupuje obraz s vysokým dynamickým rozsahem, typicky RGB obraz s plovoucí řádovou čárkou. RGB obraz je převeden pomocí transformační matice

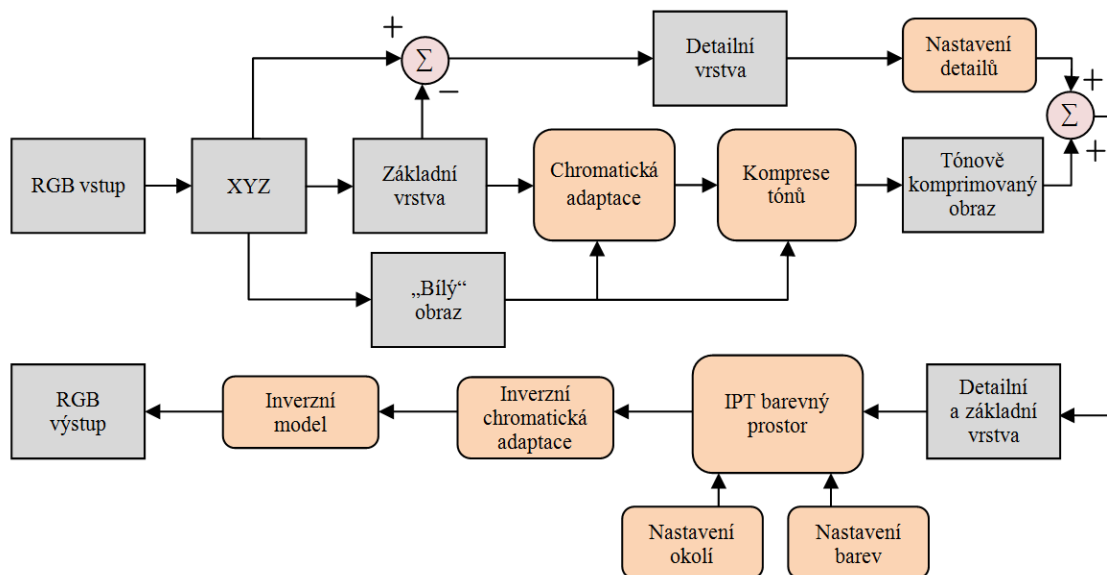
$$M_{sRGB} = \begin{bmatrix} 0,4124 & 0,2127 & 0,0193 \\ 0,3576 & 0,7152 & 0,1192 \\ 0,1805 & 0,0722 & 0,9504 \end{bmatrix} \quad (3.2.1)$$

do barevného prostoru XYZ dle normy CIE 1931

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = M_{sRGB} \begin{bmatrix} R \\ G \\ B \end{bmatrix}. \quad (3.2.2)$$

### 3.2.2 Rozklad obrazu

Barva je výsledkem vnímání LVS a nedá se měřit ani vyjádřit jako fyzikální veličina. Závisí na osvětlení a odrazivosti povrchu daného objektu. LVS je spíše citlivý na odrazivost danou strukturou předmětu a také na lokální změny kontrastu než na globální změny [2]. Z těchto dvou důvodů se obraz rozloží na dvě vrstvy – základní a detailní. Základní vrstva je tvořena rozostřeným obrazem vzniklým po aplikaci bilaterálního filtru. Na základní vrstvu se později aplikuje chromatická adaptace a komprese tónů, viz Obr. 3.2.1



Obr. 3.2.1 Model metody iCAM06

### 3.2.3 Bilaterální filtr – základní a detailní vrstva

Základní vrstva se získá použitím bilaterálního filtru. Tento filtr navrhl Durand a Dorsey [18]. Je to nelineární filtr, který zbaví obraz vysokých frekvencí a zároveň zachová hrany. Každý pixel se váhuje Gaussovým filtrem v prostorové doméně a Gaussovým filtrem v intenzitní doméně tak, aby klesaly váhy pixelů s velkými rozdíly intenzit. Obraz je rozmazáván, zatímco hrany jsou zachovány ostré bez náchylností na tzv. halo artefakty. Výstup bilaterálního filtru pro pixel  $s$  je vyjádřen vztahem

$$J_s = \frac{1}{k(s)} \sum_{p \in \Omega} f(p-s) g(I_p - I_s) I_p, \quad (3.2.3)$$

kde funkce  $k$

$$k(s) = \sum_{p \in \Omega} f(p-s) g(I_p - I_s), \quad (3.2.4)$$

slouží pro normování výstupu  $J_s$ ,  $f$  je Gaussova funkce v prostorové doméně a  $g$  je druhá Gaussova funkce v intenzitní doméně, která zabraňuje rozmazávání hran.  $I_s$  je

hodnota pixelu  $s$ ,  $\Omega$  je vybrané okolí daného pixelu a  $p$  jsou body uvnitř tohoto okolí,  $I_p$  je intenzita v bodě  $p$ .

Detailní vrstva se získá odečtením základní vrstvy od originálního obrazu.

### 3.2.4 Chromatická adaptace

Na základní vrstvu se aplikuje chromatická adaptace vycházející z CIECAM02 [19]. Je to lineární von Kriesova normalizace spektrálně zaostřených RGB obrazových signálů u signálů RGB adaptovaných na bílou, odvozených z Gaussova dolnopásmového adaptačního obrazu jednotlivých pixelů. Obraz je kvůli výpočetní náročnosti podvzorkován. Šířka Gaussova filtru je polovina kratší strany obrazu. Výpočet je dán následujícími vztahy.

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} = M_{CAT02} \begin{bmatrix} X \\ Y \\ Z \end{bmatrix}, \quad (3.2.5)$$

$$M_{CAT02} = \begin{bmatrix} 0,7328 & 0,4296 & -0,1624 \\ -0,7036 & 1,6975 & 0,0061 \\ 0,0030 & 0,0136 & 0,9834 \end{bmatrix}, \quad (3.2.6)$$

$$D = 0,3F \left[ 1 - \left( \frac{1}{3,6} \right) e^{\left( \frac{-(L_A - 42)}{92} \right)} \right]. \quad (3.2.7)$$

$$\begin{aligned} R_c &= \left[ \left( R_{D65} \frac{D}{R_w} \right) + (1-D) \right] R, \\ G_c &= \left[ \left( G_{D65} \frac{D}{G_w} \right) + (1-D) \right] G, \\ B_c &= \left[ \left( B_{D65} \frac{D}{B_w} \right) + (1-D) \right] B. \end{aligned} \quad (3.2.8)$$

Význam jednotlivých pojmů vyplývá z následujícího popisu. Provede se konverze CIE XYZ do RGB za pomoci transformační matice  $M_{CAT02}$ , která je definována v CIECAM02 [19].  $D$  je stupeň adaptace odvozený z jasové adaptace  $L_A$  (20 % z adaptace bílé barvy) a faktoru okolí  $F$ , který se pohybuje v rozmezí 0–1 ( $F = 1$  pro průměrné okolí,  $F = 0$  nejnižší stupeň adaptace, tedy bez adaptace). V praxi se nejčastěji používá 0,65–1. Stupeň  $D$  je násoben hodnotou 0,3, aby snížil desaturaci HDR obrazu. Chromatická adaptace také převádí globální bílý bod do bodu D65 definovaného podle normy CIE, který je kompatibilní s IPT barevným prostorem [20].

### 3.2.5 Kompresí tónů

Metoda iCAM06 vychází z funkcí modelující odezvy fotoreceptorů (tyčinek a čípků), tedy od skotopických úrovní až po úrovně fotopické.

Složky RGB jsou zpracovávány z pohledu fotopického vidění čípků. Výsledné složky RGB chromatické adaptace se převedou z prostoru CAT02 do prostoru HPE (Hunt-Pointer-Estévez) za pomoci transformačních matic  $M_{HPE}$  a  $M_{CAT02}^{-1}$

$$M_{HPE} = \begin{bmatrix} 0,38971 & 0,68898 & -0,07868 \\ -0,22981 & 1,18340 & 0,04641 \\ 0,0 & 0,0 & 1,0 \end{bmatrix}, \quad (3.2.9)$$

$$M_{CAT02}^{-1} = \begin{bmatrix} 1,096124 & -0,278869 & 0,182745 \\ 0,454369 & 0,473533 & 0,072098 \\ -0,009628 & -0,005698 & 1,015326 \end{bmatrix}, \quad (3.2.10)$$

$$\begin{bmatrix} R' \\ G' \\ B' \end{bmatrix} = M_{HPE} M_{CAT02}^{-1} \begin{bmatrix} R_C \\ G_C \\ B_C \end{bmatrix}. \quad (3.2.11)$$

Vypočítá se nelineární komprese

$$R'_a = \frac{400 \left( \frac{F_L R'}{Y_w} \right)^p}{27,13 + \left( \frac{F_L R'}{Y_w} \right)^p} + 0,1$$

$$G'_a = \frac{400 \left( \frac{F_L G'}{Y_w} \right)^p}{27,13 + \left( \frac{F_L G'}{Y_w} \right)^p} + 0,1, \quad (3.2.12)$$

$$B'_a = \frac{400 \left( \frac{F_L B'}{Y_w} \right)^p}{27,13 + \left( \frac{F_L B'}{Y_w} \right)^p} + 0,1$$

$$F_L = 0,2k^4(5L_A) + 0,1(1-k^4)^2(5L_A)^{\frac{1}{3}}, \quad (3.2.13)$$

$$k = \frac{1}{5L_A + 1} \quad (3.2.14)$$

Oproti CIECAM02 jsou vztahy poupraveny exponentem  $p$ , který reguluje odezvy fotoreceptorů [21]. Parametr  $p$  nabývá hodnot 0,6–0,85. Vyšší hodnota vytváří větší celkový kontrast. Výchozí hodnota je empiricky nastavena na 0,75.  $F_L$  se nazývá adaptační faktor.  $Y_w$  je jas lokálně adaptovaného bílého obrazu.

Předchozí vztahy byly zaměřeny na fotopické vidění čípků. Vztahy (3.2.12, 3.2.13, 3.2.14) jsou shodné i pro skotopické vidění tyčinek. Dále je upravena funkce odezvy tyčinek  $A_s$  dle Huntova modelu [23].

$$A_s = 3,05B_s \left[ \frac{400 \left( \frac{F_{LS}S}{S_w} \right)^p}{27,13 + \left( \frac{F_{LS}S}{S_w} \right)^p} \right] + 0,3, \quad (3.2.15)$$

$$F_{LS} = 3800j^2 \left( \frac{5L_{AS}}{2,26} \right) + 0,2(1-j^2)^4 \left( \frac{5L_{AS}}{2,26} \right)^{\frac{1}{6}}, \quad (3.2.16)$$

$$L_{AS} = 2,26L_A, \quad (3.2.17)$$

$$j = \frac{0,00001}{\left( \frac{5L_{AS}}{2,26} \right) + 0,00001}, \quad (3.2.18)$$

$$B_s = \frac{0,5}{\left\{ 1 + 0,3 \left[ \frac{5L_{AS}}{2,26} \frac{S}{S_w} \right]^{0,3} \right\}} + \frac{0,5}{\left\{ 1 + 5 \left[ \frac{5L_{AS}}{2,26} \right] \right\}}. \quad (3.2.19)$$

$F_{LS}$  je skotopický adaptační faktor,  $L_{AS}$  – skotopický jas,  $B_s$  – saturační faktor,  $S$  – jas jednotlivých pixelů chromaticky adaptovaného obrazu,  $S_w$  – hodnota  $S$  pro referenční bílou.

Výsledná odezva komprese tónů je dána součtem odezvy tyčinek a čípků

$$RGB_{TC} = RGB'_a + A_s. \quad (3.2.20)$$

### 3.2.6 Detailní vrstva – Stevensův efekt

Na detailní vrstvu je aplikován Stevensův efekt. Podle Stevense [24] s rostoucím jasem roste vnímaný kontrast. Jas je proto nastavován ve strmých přechodech obrazu (hranách), čímž se zdůrazní lokální kontrasty. Nastavení detailů ovlivňuje proměnný adaptační faktor  $F_L$  ve vztahu

$$Details_a = Details^{(F_L+0,8)^{0,25}}. \quad (3.2.21)$$

### 3.2.7 IPT transformace

V další fázi modelu iCAM se převedou komprimované signály RGB zpět do CIE XYZ obrazu a jsou kombinovány s detailní vrstvou. Mapovaný obraz je poté konvertován do IPT prostoru, kde  $I$  představuje jasový kanál,  $P$  se blíží červenozelenému kanálu a  $T$  modrozlutému kanálu.

Nejprve se převede obraz z prostoru XYZ do prostoru LMS, na který se aplikuje exponenciální komprese a poté následuje konverze do prostoru IPT

$$\begin{bmatrix} L \\ M \\ S \end{bmatrix} = M_H^{D65} \begin{bmatrix} X_C \\ Y_C \\ Z_C \end{bmatrix}, \quad (3.2.22)$$

$$M_H^{D65} = \begin{bmatrix} 0,4002 & 0,7075 & -0,0807 \\ -0,2280 & 1,1500 & 0,0612 \\ 0,0000 & 0,0000 & 0,9184 \end{bmatrix}, \quad (3.2.23)$$

$$\begin{aligned} L' &= L^{0,43} \\ M' &= M^{0,43}, \\ S' &= S^{0,43} \end{aligned} \quad (3.2.24)$$

$$\begin{bmatrix} I \\ P \\ T \end{bmatrix} = M_{IPT} \begin{bmatrix} L' \\ M' \\ S' \end{bmatrix}, \quad (3.2.25)$$

$$M_{IPT} = \begin{bmatrix} 0,4000 & 0,4000 & 0,2000 \\ 4,4550 & -4,8510 & 0,3960 \\ 0,8056 & 0,3572 & -1,1628 \end{bmatrix}. \quad (3.2.26)$$

### 3.2.8 Úprava IPT

Složky IPT se upraví podle Hunta [25], aplikuje se gamma korekce a Huntův efekt. Složky  $P$  a  $T$  jsou zdokonaleny na základě Huntovu efektu. Sytost se zvětšuje s narůstajícím jasnem, proto se jas zvýší v místech, kde jsou barvy sytější. Složky  $P$  a  $T$  jsou funkcí adaptačního faktoru  $F_L$  a platí

$$P = P \left[ (F_L + 1)^{0,2} \left( \frac{1,29C^2 - 0,27C + 0,42}{C^2 - 0,31C + 0,42} \right) \right], \quad (3.2.27)$$

$$T = T \left[ (F_L + 1)^{0,2} \left( \frac{1,29C^2 - 0,27C + 0,42}{C^2 - 0,31C + 0,42} \right) \right]. \quad (3.2.28)$$



Vnímaný kontrast narůstá, pokud se oblasti obrazu mění od temné přes střední až po světlé. Tento efekt je aplikován na jasový kanál  $I$ . Je předvídan za pomoci funkce  $I^\gamma$ .


$$I_a = I^\gamma . \quad (3.2.29)$$

Hodnota  $\gamma$  odpovídá 1,5 pro tmavé snímky, 1,25 pro šeré a 1,0 pro světlé.

### 3.2.9 Výsledný mapovaný obraz

Vzniklé tři atributy prostoru IPT byly upraveny podle Stevensova a Huntova jevu. IPT obraz se pak převede do CIE XYZ obrazu následovaný inverzní chromatickou adaptací. Inverzní charakteristický model přetransformuje XYZ hodnoty do hodnot RGB. Nalezne se maximální hodnota v obrazu, podle níž se mapují obrazy v závislosti na rozsahu zobrazovacího zařízení.

Metoda iCAM06 je tvořena propracovaným modelem, který zpracovává obraz ve dvou rovinách – v základní a detailní. Dále je na ni aplikovaná chromatická komprese a komprese tónů. Metoda využívá Stevensova a Huntovu jevu k přiblížení vnímání mapovaného obrazu LVS.



Obr. 3.2.2 Mapovaný obraz metodou iCAM06

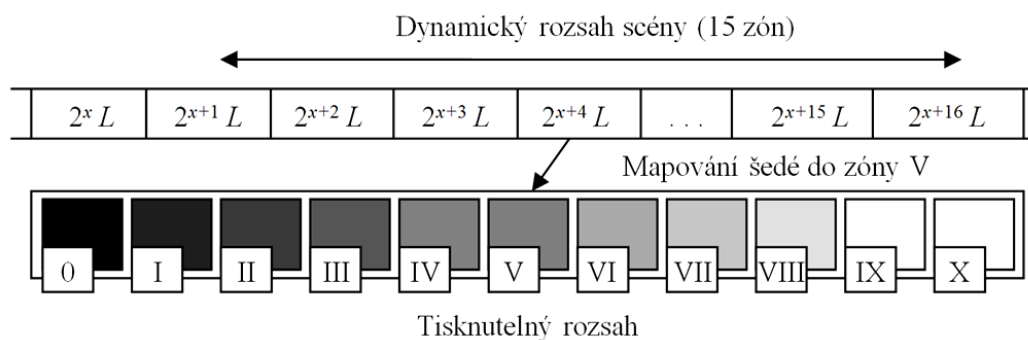
## 3.3 Reinhard

Většina operátorů pro mapování tónů má problémy s nežádoucími artefakty jako tzv. ringing nebo saturace světlých míst a nebraly v úvahu obsah scény, vyobrazené

prostředí a pozorovací podmínky. Na tuto problematiku se zaměřili E. Reinhard, M. Stark, P. Shirley, J. Ferwerda a využili poznatků z klasické fotografie [3]

### 3.3.1 Algoritmus

Metoda je založena na zónovém systému [26]. Zóna je definována římskou číslicí (0-X) vyjadřující rozsah jasů scény tisknutelných barev. Zóna 0 představuje černou barvu, zóna X představuje bílou barvu. Vzdálenost následující zóny je dvojnásobek předchozí intenzity. V reálu se musíme vypořádat s větším dynamickým rozsahem scény, než který dokážeme vytisknout nebo zobrazit na monitoru. Z pohledu fotografa je navíc důležité rozlišovat dynamický rozsah, při kterém jsou detaily rozlišitelné. Na Obr. 3.3.1 je zobrazeno jedenáct tisknutelných zón. Musí se provést škálování, aby se mohlo zobrazit celé rozpětí dynamického rozsahu.



Obr. 3.3.1 Zónový systém

### 3.3.2 Počáteční mapování jasu

Stanoví se tonální rozsah výstupního obrazu [24], jenž vychází z klíčové hodnoty dané scény. Tento pojem pochází z oblasti fotografie. Scéna s vysokou klíčovou hodnotou obsahuje převážně světlé tóny a malé množství tmavých tónů vykresluje detaily. Analogicky lze vysvětlit scénu s nízkou nebo střední klíčovou hodnotou.

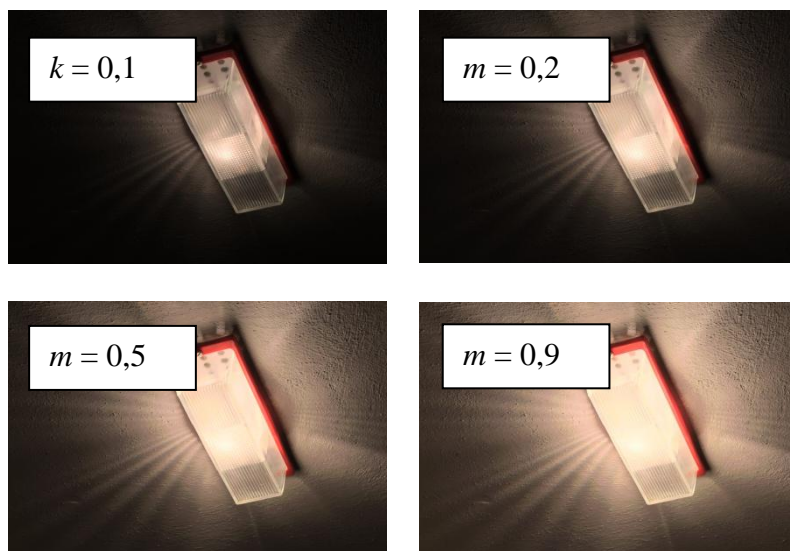
Podobně jako u mnoha barevných reprodukčních metod, LVS vnímá celkový jas scény jako logaritmický průměr všech jasů obsažených ve scéně. Celkový adaptační jas  $\bar{L}_w$  je vyjádřen vztahem

$$\bar{L}_w = \frac{1}{N} \exp \left( \sum_{x,y} \log(\delta + L_w(x,y)) \right). \quad (3.3.1)$$

$L_w(x,y)$  je celkový jas pixelu HDR obrazu.  $N$  je počet pixelů obrazu a  $\delta$  je malá hodnota, která zabraňuje singularitě způsobené přítomností černých pixelů. Celkový jas pixelu  $L_w(x,y)$  se vypočítá jako

$$L(x,y) = \frac{\alpha}{L_w} L_w(x,y). \quad (3.3.2)$$

Parametr  $\alpha$  se nastavuje a zároveň závisí na klíčové hodnotě obrazu. Nazývá se také klíčová hodnota, protože s ní úzce souvisí. Parametr  $\alpha$  nabývá hodnot od 0 do 1, přičemž nižší hodnoty odpovídají obrazům s tmavou tonalitou, hodnota 0,18 odpovídá 18% odrazivosti šedé barvy a vyšší hodnoty odpovídají obrazům se světlou tonalitou. Závislost klíčové hodnoty (parametru  $\alpha$ ) je znázorněna na Obr. 3.3.2.



**Obr. 3.3.2** Vliv klíčové hodnoty pro různé tonality obrazu: a) tmavá, b) střední (šedá), c) světlá, d) světlejší


Některé scény mají hlavní obsah obrazu soustředěn ve středních tónech a zároveň malé množství detailů ve světlých tónech (slunce, obloha apod.). Kvůli tomuto problému byl upraven vztah (3.3.2) převodní křivky [26]

$$L_d(x, y) = \frac{L(x, y)}{1 + L(x, y)} \quad (3.3.3)$$

a byl dále upraven do vztahu

$$L_d(x, y) = \frac{L(x, y) \left( 1 + \frac{L(x, y)}{L_{white}^2} \right)}{1 + L(x, y)}, \quad (3.3.4)$$

aby se daly lépe kontrolovat vysoké jasy a bylo možné je ztmavit. Kontrola vysokých jasů je patrná na Obr. 3.3.3.




**Obr. 3.3.3** Kontrola vysokých jasů. Na obrázku vpravo je lépe vidět struktura krytu.

$L_{white}$  je nejnižší jas, který bude mapován na bílou barvu. Pokud bude nastavena hodnota  $L_{white}$  jako maximální jasová hodnota ve scéně, neprojeví se ztmavení vysokých jasů.

### 3.3.3 Ztmavování a zesvětlování

Vztah (3.3.4) je dostatečný pro řadu případů. Operátor si ale neporadí s obrazy s velmi vysokými dynamickými rozsahy, konkrétně v oblastech s vysokým kontrastem. Při reprodukci se vytrácí detaily, proto se používá funkce ztmavování a zesvětlování (dodge a burning). Tato metoda má opět původ v klasické fotografii. Ztmavením (zakrytím) snížíme dobu expozice oblastí, kterou chceme u negativu zesvětlit [26].

Problematickou oblastí je například písmo na papíře, které se vytrácí, viz Obr. 3.3.4.



**Obr. 3.3.4** Aplikace funkce zesvětlení a ztmavení

Operátor využívá funkci odvozenou z Blommaertova modelu [28]. Funkce vychází z kruhově symetrického Gaussova jádra

$$R_i(x, y, s) = \frac{1}{\pi(\alpha_i s)^2} \exp\left(-\frac{x^2 + y^2}{(\alpha_i s)^2}\right). \quad (3.3.5)$$

Tento profil pracuje s různým měřítkem  $s$  v bodech obrazu  $(x, y)$ . Konvolucí jasu daného pixelu a Gaussova profilu získáme odezvu  $V_i(x, y, s)$

$$V_i(x, y, s) = L(x, y) * R_i(x, y, s). \quad (3.3.6)$$

Kvůli malým rozměrům nejmenšího Gaussova profilu, který je o něco málo větší než jeden pixel, je zapotřebí zpřesnit odezvu  $V(x, y, s)$  chybovou funkcí

$$V(x, y, s) = \frac{V_1(x, y, s) - V_2(x, y, s)}{2^\phi \frac{\alpha}{s^2} + V_1(x, y, s)}. \quad (3.3.7)$$

kde  $V_1$  je střed,  $V_2$  okolí definované vztahy (3.3.5, 3.3.6),  $\alpha$  je výše zmíněná klíčová hodnota a  $\phi$  je parametr ostření. Vztah (3.3.7) se počítá za účelem stanovení rozsahu okolí pro každý pixel a nalezení měřítka  $s_m$  odpovídajícího rozměru. Pokud platí

$$|V(x, y, s_m)| < \varepsilon, \quad (3.3.8)$$

pak  $\varepsilon$  je prahová úroveň a  $V_1$  se dosadí do jmenovatele vztahu (3.3.7) místo  $L(x, y)$ . Vztah

$$L_d(x, y) = \frac{L(x, y)}{1 + V_1(x, y, s_m(x, y))}. \quad (3.3.9)$$

představuje výsledný lokální operátor pro ztmavování a zesvětlování. V případě tmavého bodu ve světlé oblasti, kde je splněno  $L < V_1$ , se sníží jas  $L_d$ , čímž se zvýší kontrast daného pixelu vůči světlému okolí. Výsledkem je zachování detailů ve světlých oblastech. Analogicky by fungovalo zesvětlení bodu na tmavém podkladu. Parametr  $s_m$  nastavuje rozsah vlivu na okolí pixelu. Je třeba najít vhodný rozsah, aby se v obraze neprojevovaly nežádoucí artefakty, například temné kruhy ve světlých oblastech, viz Obr. 3.3.5.



**Obr. 3.3.5** Parametr  $s$  ovlivňuje okolí s prudkými přechody. Efekt je patrný na levém obrázku kolem světla lampy.

### 3.3.4 Reinhardův operátor – shrnutí

Erik Reinhard vyvinul operátor pro mapování tónů, který je poměrně jednoduchý a není výpočetně náročný. Algoritmus vychází ze zkušeností z klasické fotografie. První část algoritmu vychází z tónového charakteru obrazu (celkového jasu – klíčové hodnoty). Druhá část algoritmu zahrnuje lokálně chovající se metodu. Díky tomu lze ztmavit nebo zesvětlit problematické oblasti obrazu a tím nepřijdeme o detaily obrazu.

### 3.4 Snížení dynamického rozsahu inspirované fyziologií fotoreceptorů - Reinhard a Devlinová

V počítačové grafice je běžnou úlohou mapování digitálních obrazů s vysokým dynamickým rozsahem do nižšího dynamického rozsahu zařízení typu monitor a tiskárna. Tato úloha je podobná procesu, který se děje v LVS. Adaptace nastává ve fotoreceptorech, které se přizpůsobují jasu scény. Výsledkem autorů Reinharda a Devlinové [4] je rychlý a praktický algoritmus s intuitivními parametry, jež nastavují celkovou intenzitu, kontrast, světelnou a barevnou adaptaci.

#### 3.4.1 Algoritmus

Operátor byl inspirován LVS [4]. Zaměřil se především na vlastnosti fotoreceptorů (tyčinek a čípků). Každý fotoreceptor se adaptuje na spektrum světla, které přijímá, nebo je adaptován na dominantní spektrum scény. Operátor používá světelnou adaptaci vycházející z interpolace mezi intenzitou pixelu a průměrnou intenzitou scény. Světelná adaptace je doménou především tyčinek. Barevná adaptace čípků vychází z interpolace trichromatických složek RGB. Funkce intenzity je popsána vztahem

$$V = \frac{I}{I + \sigma(I_a)} V_{\max}, \quad (3.4.1)$$

$$\sigma(I_a) = (fI_a)^m. \quad (3.4.2)$$

Potenciál  $V$  je produkován čípků, které jsou závislé na intenzitě  $I$ , [29]. Konstanta  $\sigma(I_a)$  popisuje stav dlouhodobé adaptace fotoreceptorů adaptační úrovně  $I_a$ . Parametr  $f$  ovlivňuje intenzitu a parametr  $m$  ovlivňuje kontrast.

#### 3.4.2 Kontrast

Pokud uživatel nezadá hodnotu parametru  $m$ , vypočítá se parametr  $m$  v závislosti na tonalitě určené klíčovou hodnotou  $k$  dané scény

$$m = 0.3 + 0,7k^{1,4}. \quad (3.4.3)$$

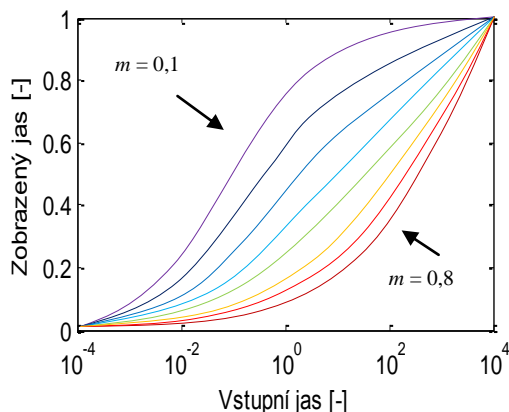
Klíčová hodnota  $k$  je stanovena poměrem logaritmů jasů [30]

$$k = \frac{(L_{\max} - L_{av})}{(L_{\max} - L_{\min})}, \quad (3.4.4)$$


kde  $L_{\max}$ ,  $L_{\min}$  je maximální, resp. minimální jasová hodnota a  $L_{av}$  je průměr všech jasů. Celkový jas  $L$  je definován intenzitami třech RGB kanálů

$$L = 0,2125I_r + 0,7154I_g + 0,0721I_b. \quad (3.4.5)$$

Pokud bude chtít uživatel zasáhnout do nastavení parametru  $m$ , může ho zadat ručně [4]. Parametr  $m$  dosahuje rozumných výsledků v rozmezí od 0,3 do 1. Parametr ovlivňuje tvar kompresní křivky. Se zmenšující hodnotou parametru se tvar křivky mění na „s“ tvar.



**Obr. 3.4.1** Tvar převodní charakteristiky v závislosti na parametru  $m$




**Obr. 3.4.2** Parametr  $m$  ovlivňuje kontrast.

### 3.4.3 Intenzita

Parametrem  $f$  se nastavuje intenzita. Reinhard a Devlinová [4] zjistili, že nejlepších výsledků dosahuje operátor při nastavení  $f = 1$ . Jelikož je rozsah nastavení parametru veliký a nastavení je neintuitivní, parametr byl upraven do exponenciální funkce

$$f = e^{(-f)}. \quad (3.4.6)$$

Parametr  $f$  ovlivňuje celkovou intenzitu obrazu. Výchozí hodnota je 0. Praktická hodnota parametru se nachází mezi  $-8$  a  $8$ . Vyšší hodnotou parametru docílíme světlejšího výsledného obrazu, nižší hodnotou parametru dosáhneme tmavšího obrazu (Obr. 3.4.3). Přestože má parametr  $f$  podobný tvar jako parametr  $k$ , byl zachován z důvodů rozdílných vizuálních výsledků.

Obr. 3.4.3 Parametr  $f'$  ovlivňuje intenzitu.

### 3.4.4 Barevná a světelná adaptace

Barevná adaptace [4] vychází ze vztahu (3.4.1), který je použit zvlášť pro jednotlivé RGB kanály


$$I_a = cI_{r|g|b} + (1-c)L. \quad (3.4.7)$$

Parametr  $c$  se pohybuje v rozmezí 0 až 1. Pokud se rovná 1, bude operátor zpracovávat RGB kanály nezávisle na váženém jasu  $L$  (3.4.5) a dojde k barevné korekci. Pokud bude parametr 0 (výchozí nastavení), bude úroveň adaptace stejná pro všechny RGB kanály dle vztahu (3.4.5).

Světelná adaptace umožňuje ovlivňovat, zda bude adaptace pixelu závislá na vlastní intenzitě  $I_{r|g|b}$  nebo na celkové průměrné intenzitě RGB kanálu  $L_{r|g|b}^{av}$

$$I_a = aI_{r|g|b} + (1-a)L_{r|g|b}^{av}. \quad (3.4.8)$$

Parametr  $a$  je v rozmezí 0 až 1. Pokud se rovná 1 (výchozí nastavení), bude adaptace založena na intenzitě pixelu  $I_{r|g|b}$ . Pokud bude parametr 0, bude adaptace vycházet z celkové průměrné intenzity  $L_{r|g|b}^{av}$ .

Obr. 3.4.4 Světelná adaptace, závislost na parametru  $a$ 

Vztahy pro barevnou a světelnou adaptaci jsou sloučeny do výsledného vztahu pro výpočet intenzity adaptační úrovně  $I_a$ .



$$I_a^{local} = cI_{r|glb} + (1-c)L, \quad (3.4.9)$$

$$I_a^{global} = cI_{r|glb} + (1-c)L^{av}, \quad (3.4.10)$$

$$I_a = aI_a^{local} + (1-a)L_a^{global}. \quad (3.4.11)$$

Zatímco parametry  $m$ ,  $f'$ ,  $c$ ,  $a$  jsou zvoleny jednou pro celý obraz,  $I_a$  a  $V$  jsou počítány pro každý pixel a barevný kanál zvlášť. Barevné kanály jsou pak odděleně normalizovány

$$(I_{r|glb} - L_{\min})(L_{\max} - L_{\min}). \quad (3.4.12)$$

### 3.4.5 Operátor podle Reinharda a Devlinové – shrnutí

Reinhard a Devlinová vytvořili operátor pro mapování tónů inspirovaný částí procesu, který nastává v LVS. Operátor se snaží aproximovat chování fotoreceptorů. Fotoreceptor se částečně přizpůsobuje spektru dopadajícího světla nebo dominantnímu spektru scény. Tento princip je nasimulován světelnou a barevnou adaptací algoritmu.

Operátor je řízen čtyřmi parametry  $m$ ,  $f'$ ,  $c$ ,  $a$ . Největší vliv na výsledný obraz mají první dva parametry ovládající kontrast a intenzitu. Parametry  $c$ ,  $a$  ovlivňují poměr mezi globální a lokální adaptací obrazu. Operátor dosahuje přijatelných výsledků, výhodou je rychlost zpracování obrazu a jeho nenáchylnost k rušivým, tzv. halo artefaktům. Bez uživatelského zásahu vychází výpočet z klíčové hodnoty obrazu inspirovaným Reinhardem [31].

## 4 Hodnocení kvality obrazu

Proces převodu HDR obrazu do LDR obrazu je ztrátovou kompresí a výsledek závisí na operátorech pro mapování tónu. Každý operátor mapuje obraz jiným algoritmem a dosahuje tak rozdílných výsledků. Výsledky jsou různé i z důvodu jiného nastavení parametrů v rámci jednoho operátoru. Vzhledem k tomu, že kvalitu obrazu ovlivňuje více faktorů, neexistuje jednotný postup při stanovení kvality obrazu. Kvalita obrazu se může hodnotit subjektivními či objektivními metodami [5]. Výběr metody závisí na časových možnostech pro vyhodnocení testovaných obrazů. Výsledky subjektivních metod jsou oproti objektivním metodám přirozenější pro lidské vnímání, na druhou stranu jsou však výrazně časově náročnější.


### 4.1 Metody subjektivního hodnocení

Existují standardy pro nejrůznější aplikace v oblasti multimediální techniky. Na subjektivní hodnocení kvality obrazu se nejvíce zaměřují standardy ITU-R BT.500 a ITU-T P.910. Standardy navrhuje pozorovací podmínky, kritéria pro pozorovatele, testovací materiál, hodnotící procedury a rozbor dat [5]. Standard ITU-R BT.500 má delší historii a byl navržen pro potřeby hodnocení televizního vysílání, zatímco standard ITU-T P.910 vznikl pro multimediální aplikace. Volba metody hodnocení daného standardu závisí na konkrétní situaci a potřebách testu.

#### 4.1.1 Standard ITU-R BT.500

##### DSCQS (Double Stimulus Continuous Quality Scale)


Metoda využívá páru referenčního a testovaného obrazu. Pár je za sebou zobrazen v různém sledu (např. po dobu 10 s). Pozorovatel neví, který obraz je referenční a který testovaný. U obou obrazů určí jejich kvalitu podle stupnice 0–100 (špatná – výborná). Metoda je vhodná pro případy, kdy pozorovatel nemá k dispozici původní nezkrácený obraz.



**Obr. 4.1.1** Schéma metody DSCQS a stupnice hodnocení

**DSIS** (Double Stimulus Impairment Scale)

U této metody je vždy ukázán nejprve původní obraz a poté testovaný obraz. Uživatel hodnotí pouze druhý testovaný obraz na pětistupňové škále. Metoda je vhodná například pro určení vlivu zkreslení původního obrazu.



**Obr. 4.1.2** Schéma metody DSIS a hodnocení

**SSCQE** (Single Stimulus Continuous Quality Evaluation)

Metoda je navržena pro hodnocení videa bez předvedení původního snímku. Uživatel hodnotí kontinuálně pomocí posuvníku (špatný – výborný). Výsledkem je časově závislé hodnocení videa.

**SDSCE** (Simultaneous Double Stimulus for Continuous Evaluation)

Metoda je obdobou předchozího testu SSCQE s tím rozdílem, že jsou vedle sebe promítána dvě videa zároveň.

**SS** (Single Stimulus)

Prezentován je pouze jeden obraz a pozorovatel udává hodnocení (špatný – výborný). Pozorovatel nemá možnost porovnání s původním obrazem. Metoda existuje ve dvou variantách. V první variantě je obraz prezentován pouze jednou v celé sekvenci. Typická zkouška se skládá ze tří zobrazení – šedá neutrální obrazovka, testovaný obraz, šedá obrazovka. Délka promítnutí těchto obrazovek je 3 s, 10 s a 10 s. Hodnocení může být zaznamenáno během testovaného snímku nebo šedé obrazovky. Ve druhé variantě se obraz vyskytuje vícekrát. Větší časová náročnost této varianty je kompenzována konzistentnějšími výsledky.

**SC** (Stimulus-comparison method)

Pozorovatel mezi sebou porovnává a hodnotí dva obrazy (indexuje). Existují tři typy hodnocení – slovní, nekategorické porovnávání a nekategorické rozhodnutí, viz Tab. 4.1.1.

**Tab. 4.1.1** Typy vyhodnocování metody SC

Typ hodnocení	Slovní porovnávání	Nekategorické porovnávání	Nekategorické rozhodnutí
<b>Popis hodnocení</b>	a) vnímatelné rozdíly (stejně, rozdílně) b) vnímatelné rozdíly (stejně, více, méně) *Hodnocení vyplývá z číselných rozdílů.	Forma I: vzdálenost na ose určuje rozdílnost obrazů  Forma II: označí např. kvalitu obou obrazů (posuzují se pak jejich rozdíly)	Hodnotitel označí bod na popsané ose.

#### 4.1.2 Standard ITU-T P.910

##### ACR (Absolute Category Rating)

Metoda je stejná jako SS (Single Stimulus). Prezentován je jen jeden obraz (video) a pozorovatel udává hodnocení (špatný – výborný). Pozorovatel vidí pouze testované video (obraz) bez reference a hodnotí celou sekvenci (špatný – výborný) v době zobrazení šedé. Oproti DSIS a DSCQS je tato metoda 2× až 4× rychlejší. Je nezbytné zopakovat stejné obrazy za stejných podmínek

A ~ 10 s	Hodnocení ≤ 10 s šedá	B ~ 10 s	Hodnocení ≤ 10 s šedá	C ~ 10 s	Hodnocení ≤ 10 s šedá
-------------	--------------------------	-------------	--------------------------	-------------	--------------------------

**Obr. 4.1.3** Schéma metody ACR

##### DCR (Degradation Category Rating)

Tato metoda je identická s metodou DSIS.

##### PC (Pair Comparison)

Metoda je založena na párovém porovnávání dvou obrazů. Pozorovatel rozhoduje, který ze dvou testovaných obrazů je z jeho pohledu lepší. Postupně jsou uváděny všechny možné kombinace testovaných obrazů. Po ohodnocení jednoho páru obrazů se promítne na 2 s šedá obrazovka. Metoda je velmi spolehlivá, musí se ale brát v potaz časová náročnost a se vzrůstajícím časem i klesající pozornost pozorovatele. Kratší varianta této metody obsahuje  $M$  snímků podle vztahu

$$M = \frac{N(N-1)}{2}. \quad (4.1.1)$$

$N$  je počet testovaných obrazů. V této variantě se vyskytuje každý pár pouze jednou nezávisle na pozici obrazu.

## 4.2 Metody objektivního hodnocení

Metody objektivního hodnocení se upřednostňují před metodami subjektivního hodnocení z důvodů časové nenáročnosti. Nevýhodou zůstává skutečnost, že doposud nevznikla žádná metrika, která by stoprocentně korelovala s názory pozorovatelů. Proto se stále vyvíjí objektivní metody a hledají se spojitosti se subjektivními metodami.

Na metody objektivního hodnocení obrazu lze pohlížet z hlediska různých kritérií použitelnosti [5]. Dělí se na plně referenční FR (Full Reference) a bezreferenční NR (No Reference). Pokud se bude porovnávat zkreslený obraz s původním obrazem, jedná se o metodu typu FR. V mnoha případech není k dispozici původní obraz. Například na internetových stránkách, sociálních sítích a v televizi se běžně setkáváme s obrazy, u kterých nevíme, jak originální obraz vypadal. Lze použít pouze metody typu NR. Dále se lze setkat s metodami, které jsou částečně referenční a vychází z obecného modelu, jenž byl natrénován z většího množství dat obrazů.

Dále existují metriky využívající parametry, které nebyly trénovány vzhledem k subjektivním výsledkům hodnocení OU (Opinion Unaware) a nejsou závislé na typu zkreslení DU (Distortion Unaware) nebo jsou naopak závislé na znalosti typu zkreslení DA (Distortion Aware). O metrikách, kterým stačí znát pouze testovaný obraz, se říká, že jsou typu CB (Completely Blind).

Pro srovnání kvality obrazů s nízkým dynamickým rozsahem (např. 8-bit) se používá spousta metrik [5]. Tyto metriky jsou plně referenční a je zapotřebí znát původní obraz. Problém nastává při porovnání obrazů, které mají rozdílný dynamický rozsah jako např. LDR a HDR obrazy. Pro tyto účely slouží jiné metriky popsané v následující kapitole o objektivních metodách.

## 5 Vybrané metody objektivního hodnocení

Kvůli časové náročnosti subjektivního hodnocení operátorů pro mapování tónů obrazů vznikly metody objektivního hodnocení (IQA – Image Quality Assessment).

Jak bylo uvedeno v předchozí kapitole, zmíněné metriky nejsou vhodné pro mapovaný obraz. V této kapitole jsou uvedeny čtyři metriky pro objektivní hodnocení mapovaného obrazu – TMQI [6], NIQE [7], BIQA [8], CS [9]. Dále je zmíněna metrika DRIM [10], která na rozdíl od ostatních metrik neposkytuje výsledek ve formě jediné hodnoty, ale ve formě mapy zkreslení. Pro mapovaný obraz jsou použitelné pouze bezreferenční metody (TMQI) nebo metody, jež jsou schopny vykompenzovat dynamický rozsah původního a mapovaného obrazu (DRIM). Metriky NIQE, BIQA a CS zastupují částečně referenční metriky.

Tato kapitola detailně popisuje vybrané objektivní metriky a jejich použitelnost bude testována v následující kapitole.

### 5.1 TMQI – objektivní hodnocení kvality operátorů pro mapování tónů

Hlavním cílem převodu HDR obrazu do nižší bitové hloubky je zachování similarity (podobnosti) a přirozeného vzhledu. Autoři H. Yeganeh a Z. Wang [6] navrhli metodu objektivního hodnocení (TMQI – Tone-mapped Image Quality Index) pro LDR obrazy s využitím HDR obrazů, které slouží jako reference. Metoda hodnocení je založena na dvou metodách objektivního hodnocení – strukturální similaritě SSIM (Structural Similarity [32]) a přirozenosti NSS (Natural Scene Statistics [33]).

#### 5.1.1 Strukturální similarita

Strukturální similarita  $S$  se snaží číselně vyjádřit, do jaké míry se podařilo vykreslit celou strukturu referenčního HDR obrazu [32]. Strukturální similarita se pohybuje v rozmezí 0 až 1. Čím více se LDR obraz podobá referenčnímu HDR obrazu, tím vyšších čísel strukturální similarita dosahuje.

Základním prvkem pro výpočet similarity je okno, které postupně snímá celý LDR obraz a porovnává jej s korespondujícím oknem HDR obrazu. Strukturální similarita vychází ze dvou lokálních oblastí (oken)  $x$ ,  $y$ . Oblasti  $x$  jsou vybírány z HDR obrazu a oblasti  $y$  jsou z LDR obrazu. Strukturální similarita je pak vyjádřena vztahem

$$S_{\text{local}}(x, y) = \frac{2\sigma_x' \sigma_y' + C_1}{\sigma_x'^2 + \sigma_y'^2 + C_1} \cdot \frac{\sigma_{xy} + C_2}{\sigma_{xy} + C_2}. \quad (5.1.1)$$

$\sigma_x'$  a  $\sigma_y'$  jsou lokální směrodatné odchylky a  $\sigma_{xy}'$  je křížová korelace mezi přidruženými oblastmi HDR a LDR obrazů,  $C_1$  a  $C_2$  jsou stabilizační konstanty.

První část vztahu (5.1.1.) porovnává intenzity oblastí signálů. Čím rozdílnější budou oblasti signálů HDR a LDR obrazu, tím nižší bude výsledný koeficient  $S_{\text{local}}$ . Algoritmus rozděluje intenzity signálů na významné a nevýznamné. Z tohoto důvodu byla zavedena lokální směrodatná odchylka  $\sigma$ , na kterou se aplikuje nelineární mapování, jehož výsledkem je  $\sigma'$ . Pohybuje se v rozmezí s malou významností ( $\sigma' = 0$ ) až po největší významnost ( $\sigma' = 1$ ).

$$\sigma' = \frac{1}{\sqrt{2\pi}\theta_\sigma} \int_{-\infty}^{\sigma} \exp\left[-\frac{(x-\tau_\sigma)^2}{2\theta_\sigma^2}\right] dx \quad (5.1.2)$$

Vztah pro  $\sigma'$  (5.1.2) je distribuční funkcí normálního (Gaussova) rozdělení.  $\sigma$  je amplituda sinusového podnětu,  $\tau_\sigma$  je modulační práh (střední hodnota) a  $\theta_\sigma$  je směrodatná odchylka ovlivňující strmost funkce. Bylo zjištěno, že poměr

$$k = \frac{\tau_s}{\theta_s} \quad (5.1.3)$$

je konstantní podle Crozierova zákona [34]. Konstanta  $k$  se nazývá koeficientem rozšíření. Typickými hodnotami  $k$  jsou 2, 3 a 4. Koeficient rozšíření  $k = 2$  odpovídá spolehlivosti přibližně 95 %.

Převrácená hodnota  $\tau_s$  se používá k vyjádření citlivosti kontrastu, který je funkcí prostorové frekvence CSF (Contrast Sensitivity Fiction [35]). Na základě experimentů byla stanovena převrácená hodnota  $\tau_s$  jako funkce prostorové frekvence  $f$  [36]

$$A(f) \approx 2,6(0,0192 + 0,114f) \exp\left[-(0,114f)^{1,1}\right], \quad (5.1.4)$$

která je vynásobena konstantou  $\lambda$

$$\tau_s(f) = \frac{1}{\lambda A(f)}. \quad (5.1.5)$$

Protože je uvažována amplituda sinusového podnětu, přepočítá se na efektivní hodnotu

$$\tau_\sigma(f) = \frac{\bar{\mu}}{\sqrt{2}\lambda A(f)}. \quad (5.1.6)$$

$\bar{\mu}$  se rovná např. 128. Hodnota vychází z hodnot 8-bitového obrazu (0–255). Podle Crozierova zákona bude  $\theta_\sigma$

$$\theta_\sigma(f) = \frac{\tau_\sigma(f)}{k}. \quad (5.1.7)$$

### 5.1.2 Aplikace algoritmu strukturální similarity

Vztah pro  $S_{\text{local}}$  (5.1.1) je aplikován na celý obraz a pomocí posouvání okna se projde celý prostor obrazu. V algoritmu je použito Gaussovo okno o velikosti  $11 \times 11$  bodů se směrodatnou odchylkou 1,5.

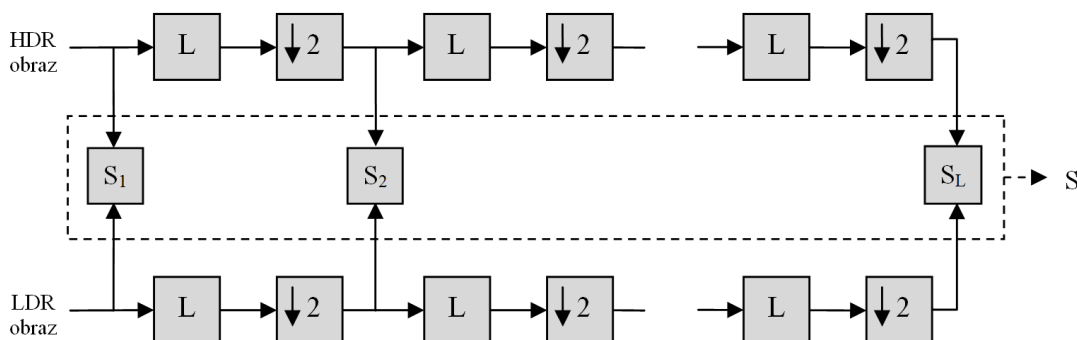
Rozpoznávání detailů v obrazu se odvíjí od vzdálenosti obrazu od pozorovatele. S narůstající vzdáleností klesá schopnost pozorovatele rozlišit detaily, proto byla zakomponována myšlenka víceúrovňového [37] a váhovaného zpracování [38]. Obraz projde nízkopásmovým filtrem a je podvzorkován. V implementovaném algoritmu se cyklus opakuje 5krát. Z každého cyklu získáme mapu a informaci o výsledku věrnosti obrazu  $S_1, S_2 \dots S_L$

$$S_l = \frac{1}{N_l} \sum_{i=1}^{N_l} S_{\text{local}}(x_i, y_i). \quad (5.1.8)$$

Similarita  $S_{\text{local}}$  je funkcí  $i$ -tého okna  $x_i$  (HDR obrazu) a  $y_i$  (LDR obrazu).  $N_l$  je počet oken v  $l$ -tém okně. Poté se sloučí všechny výsledky jednotlivých cyklů  $S_1, S_2 \dots S_L$  do jediného

$$S = \prod_{l=1}^L S_l^{\beta_l}. \quad (5.1.9)$$


$L$  je celkový počet stupňů a  $\beta_l$  je váhovací koeficient  $l$ -tého stupně. Postup je zachycen na Obr. 5.1.1.



**Obr. 5.1.1** Schéma přechodu na nižší měřítko

Kromě toho, že se strukturální similarita dá vyjádřit souhrnným číslem  $S$ , lze ji graficky znázornit. Na Obr. 5.1.2 je uveden příklad mapy strukturální similarity. Tmavé oblasti ukazují na detaily, které v LDR obrazu chybí. Nejvíce nedostatků detailů se nachází v oblasti žárovky lampičky, ve stínu vedle notebooku a na myši. Zajímavé je, že ve druhém stupni strukturální similarity se vyobrazení některých detailů „vylepšilo“. Vlivem změny rozlišení došlo ke spravení detailů v oblasti žaluzií. Posuzování kvality obrazu je závislé na rozlišení a s tím související vzdáleností obrazu od pozorovatele.





Obr. 5.1.2 Mapy jednotlivých stupňů strukturální similarity

### 5.1.3 Statistická přirozenost

Znakem kvalitně zpracovaného LDR obrazu není pouze podobnost s HDR obrazem, ale také přirozenost. Přirozenost je bohužel subjektivním vjemem a obtížně se stanovuje. Dá se popsat vlastnostmi obrazu jako je jas, kontrast, barevná reprodukce, viditelnost

a reprodukce detailů. Největší vliv na přirozenost mají první dvě zmíněné vlastnosti, jas a kontrast.

Na základě databáze 8-bitových šedotónových obrazů [39], [40] vytvořili H. Yeganeh a Z. Wang [5] statistický model. Histogram středních hodnot a směrodatných odchylek zprůměrovaných všech obrazů připomíná Gaussovu a Beta hustotu pravděpodobnosti

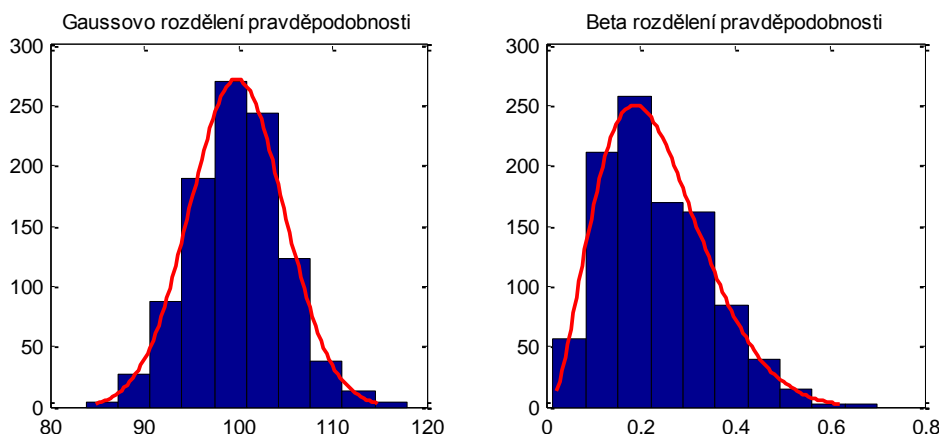
$$P_m(m) = \frac{1}{\sqrt{2\pi}\sigma_m} \exp\left[-\frac{m-\mu_m}{2\sigma_m^2}\right], \quad (5.1.10)$$

$$P_d(d) = \frac{(1-d)^{\beta_d-1} d^{\alpha_d-1}}{B(\alpha_d, \beta_d)}, \quad (5.1.11),$$

kde  $B(\alpha_d, \beta_d)$  je beta funkce. Pro konstanty platí:  $\mu_m = 115,94$ ;  $\sigma_m = 27,99$ ;  $\alpha_d = 4,4$ ;  $\beta_d = 10,1$ . Přirozenost  $N$  je vypočítána vztahem

$$N = \frac{1}{K} P_m P_d, \quad (5.1.12)$$

kde  $K = \max\{P_m P_d\}$  je normující faktor,  $N$  se tedy pohybuje v rozmezí 0 až 1.



**Obr. 5.1.3** Histogramy – a) Gaussova křivka, b) Beta křivka

#### 5.1.4 Model hodnocení kvality

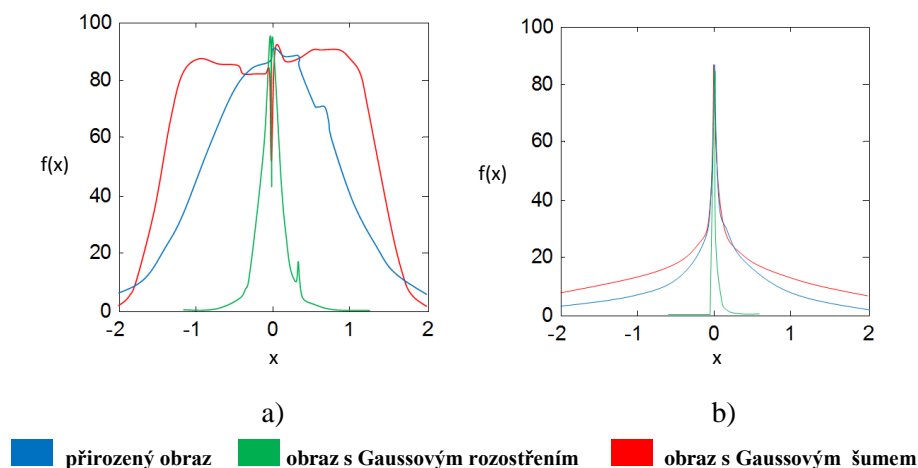
Složky  $S$  a  $N$  hodnotí rozdílné aspekty kvality obrazu. Mohou být použity zvlášť i dohromady. V praxi se více uplatní hodnocení komplexní složkou  $Q$

$$Q = aS^\alpha + (1-a)N^\beta, \quad (5.1.13)$$

kde  $a$  je parametr v rozmezí od 0 do 1 a pomocí něhož se nastavuje poměr váhy mezi  $S$  (strukturální similaritou) a  $N$  (přirozeností).  $\alpha$  a  $\beta$  nastavují citlivost  $S$  a  $N$ .

## 5.2 NIQE – hodnocení kvality obrazu nezávislého na zkreslení obrazu

Metoda NIQE (Natural Image Quality Evaluator) autorů A. Mittala a kolektivu [7] vznikla za účelem hodnocení obrazů bez původního obrazu (NR) a typu zkreslení (DU). Metoda vychází z předchozích autorových poznatků metody BRISQUE (Blind Referenceless Image Spatial Quality Evaluator [41]), která je trénována na databázi obsahující jen určitá zkreslení. Metoda NIQE je typu OU (Opinion Unaware). Nevychází tedy z natrénovaných dat od pozorovatelů, ale je založena na charakteristikách přirozené scény, souboru příznaků odvozených z přirozeného modelu (Natural Scene Statistics [42]) a mapování na vícerozměrný Gaussův model MVG (Multivariate Gaussian Model). Každé zkreslení lze vyjádřit statisticky [43]. Podle tvaru histogramu (hustoty pravděpodobnosti) lze odhadnout typ zkreslení, viz Obr. 5.2.1.



Obr. 5.2.1 a) MSCN koeficienty, b) párové koeficienty

Kvalita obrazu je vyjádřena vzdáleností mezi příznaky modelu MVG z testovaného obrazu a příznaky modelu přirozenosti MVG ze souboru vzorových obrazů.

Vypočítají se koeficienty střední hodnoty kontrastu MSCN (Mean-Subtracted Contrast-Normalized).

Úpravou vstupního obrázku  $I$  se získá  $\hat{I}$ . Nejprve se odečte od obrazu jeho střední hodnota  $\mu$  a obraz je normován směrodatnou odchylkou  $\sigma$  reprezentující kontrast.

$$\hat{I}(i, j) = \frac{I(i, j) - \mu(i, j)}{\sigma(i, j) + 1}. \quad (5.2.1)$$

Proměnné  $i$  a  $j$  jsou prostorové indexy určující pozici bodu. Střední hodnota  $\mu$  a směrodatná odchylka  $\sigma$  se vypočítají podle vztahů

$$\mu(i, j) = \sum_{k=-K}^K \sum_{l=-L}^L w_{k,l} I(i+k, j+l), \quad (5.2.2)$$

$$\sigma(i, j) = \sqrt{\sum_{k=-K}^K \sum_{l=-L}^L w_{k,l} |I(i+k, j+l) - \mu(i, j)|^2}. \quad (5.2.3)$$

Konstanty  $K = L = 3$  vymezují okolí Gaussovy váhovací funkce  $w_{k,l}$ . Lokální změny v obrazu zachycuje vztah

$$\delta(b) = \sum_{(i,j) \in \text{blok}_b} \sigma(i, j). \quad (5.2.4)$$

Obraz je rozdělen na bloky  $96 \times 96$  bodů. Bloky jsou označeny indexem  $\text{blok}_b = 1, 2, \dots, B$ . Směrodatná odchylka  $\delta$  ukazuje na lokální změny struktury v obrazu. Algoritmus uvažuje lokální směrodatné odchylky  $\delta > 0,75 \delta_{\max}$ . Dále tedy operuje s bloky s výraznými změnami v obraze.

Spočítají se párové koeficienty sousedních bodů modelující korelaci MCSN koeficientů. Párové koeficienty se počítají ve čtyřech rovinách – horizontální, vertikální, hlavní a vedlejší diagonální:

$$H(i, j) = \hat{I}(i, j) \hat{I}(i, j+1), \quad (5.2.5)$$

$$V(i, j) = \hat{I}(i, j) \hat{I}(i+1, j), \quad (5.2.6)$$

$$D_1(i, j) = \hat{I}(i, j) \hat{I}(i+1, j+1), \quad (5.2.7)$$

$$D_2(i, j) = \hat{I}(i, j) \hat{I}(i, j-1). \quad (5.2.8)$$

Histogramy jsou tvořeny MSCN koeficienty a párovými koeficienty. Gaussova distribuční funkce (GGD – General Gaussian Distribution [45]) je mapována na MCSN obrazy

$$f(x; \alpha, \sigma^2) = \frac{\alpha}{2\beta\Gamma\left(\frac{1}{\alpha}\right)} \exp\left[-\left(\frac{|x|}{\beta}\right)^\alpha\right]. \quad (5.2.9)$$

Asymetrická Gaussova distribuční funkce (AGGD – Asymmetric Gaussian Distribution [46]) je přizpůsobena každému párovému koeficientu,

$$f(x; \nu, \sigma_l^2, \sigma_r^2) = \begin{cases} \frac{\nu}{(\beta_l + \beta_r) \Gamma\left(\frac{1}{\nu}\right)} \exp\left[-\left(\frac{-x}{\beta_l}\right)^\nu\right] & \forall x < 0 \\ \frac{\nu}{(\beta_l + \beta_r) \Gamma\left(\frac{1}{\nu}\right)} \exp\left[-\left(\frac{x}{\beta_r}\right)^\nu\right] & \forall x \geq 0 \end{cases} \quad (5.2.10)$$

kde

$$\beta_l = \sigma_l \sqrt{\frac{\Gamma\left(\frac{1}{\nu}\right)}{\Gamma\left(\frac{3}{\nu}\right)}}, \quad \beta_r = \sigma_r \sqrt{\frac{\Gamma\left(\frac{1}{\nu}\right)}{\Gamma\left(\frac{3}{\nu}\right)}} \quad (5.2.11)$$

$$\quad (5.2.12)$$

Poslední parametr  $\eta$  je popsán rovnicí

$$\eta = (\beta_r - \beta_l) \frac{\Gamma\left(\frac{2}{\nu}\right)}{\Gamma\left(\frac{1}{\nu}\right)}. \quad (5.2.13)$$

Každý vypočítaný blok má nyní čtyři parametry (příznaky)  $\eta, \nu, \sigma_l^2, \sigma_r^2$  ke čtyřem párovým koeficientům a parametry  $\alpha, \sigma^2$  k MSCN koeficientům. Dohromady vznikne 18 příznaků, viz Tab. 5.2.1.

**Tab. 5.2.1** Příznaky pro jeden stupeň

Označení příznaku	Popis příznaku	Výpočetní procedura
f <sub>1</sub> –f <sub>2</sub>	Tvar, rozptyl	Mapování GGD na MSCN koeficienty
f <sub>3</sub> –f <sub>6</sub>	Tvar, střední hodnota, levý rozptyl, pravý rozptyl	Mapování AGGD na H párový koeficient
f <sub>7</sub> –f <sub>10</sub>	Tvar, střední hodnota, levý rozptyl, pravý rozptyl	Mapování AGGD na V párový koeficient
f <sub>11</sub> –f <sub>14</sub>	Tvar, střední hodnota, levý rozptyl, pravý rozptyl	Mapování AGGD na D <sub>1</sub> párový koeficient
f <sub>15</sub> –f <sub>18</sub>	Tvar, střední hodnota, levý rozptyl, pravý rozptyl	Mapování AGGD na D <sub>2</sub> párový koeficient

Rysem modelu je vícestupňové zpracování, kterého využívá i metoda TMQI. Aplikuje se dolnopásmový filtr a následně je obraz podvzorkován na poloviční rozlišení. Na

rozdíle od metody TMQI se pracuje pouze se dvěma stupni. Počet příznaků se zdvojnásobí na 36. Výsledný vztah metody NIQE

$$D(v_1, v_2, \Sigma_1, \Sigma_2) = \sqrt{(v_1 - v_2)^T \left( \frac{\Sigma_1 + \Sigma_2}{2} \right)^{-1} (v_1 - v_2)}. \quad (5.2.14)$$

je vypočítán ze středních hodnot vektorů  $v$  a kovariančních matic  $\Sigma$  přirozeného modelu MVG a modelu MVG testovaného obrazu.

### 5.3 BIQA – slepé hodnocení využívající spojení statistiky magnitudy gradientu a Laplaceových příznaků

Metodu BIQA (Blind Image Quality Assessment) navrhli autoři W. Xue, X. Mou, L. Zhang, A. C. Bovik a X. Feng [8]. Hodnotí kvalitu zkraslených obrazů bez ohledu na původní obraz (NR). Současné modely vychází z informací z některých transformačních domén, jako je diskrétní kosinova transformace, vlnková transformace apod. Metoda BIQA vychází z vlastností (příznaků) obrazu. Zabývá se lokálním kontrastem, který nese informaci o struktuře obrazu. Příznaky jsou reprezentovány magnitudou gradientu GM (Gradient Magnitude) spolu s Laplaciánem Gaussovy odezvy LOG (Laplacian of Gaussian). Pomocí normalizace JAN (Joint Adaptive Normalization) jsou normalizovány výstupy GM a LOG příznaků, aby byly porovnatelné s příznaky jiných obrazů.

#### 5.3.1 GM a LOG příznaky

Diskontinuity představující hrany v obraze dávají informaci o struktuře obrazu. Jsou modelovány GM a LOG funkcemi. Hrany jsou detekovány pomocí Laplaceova operátoru (Laplacián –  $\nabla^2$ ), který vychází z druhých parciálních derivací [8]. Pro jasovou funkci  $f(x, y)$  je Laplacián nulový tam, kde je velikost gradientu maximální. Jelikož je aproximace druhou derivací citlivá na šum, je použito konvoluce s vyhlazujícím Gaussovým jádrem.

Gradientní magnituda  $G_I$  je definována lineární konvolucí obrazu  $I$  a Gaussovým jádrem  $h_d$  aplikovaným podél osy  $x$  a  $y$  [8]

$$G_I = \sqrt{(I * h_x)^2 + (I * h_y)^2}. \quad (5.3.1)$$

Gaussov filtr je v horizontálním a vertikálním směru definován jako

$$h_d(x, y | \sigma) = \frac{\partial}{\partial d} g(x, y | \sigma) = -\frac{1}{2\pi\sigma^2} \frac{d}{\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right), \quad d \in \{x, y\}, \quad (5.3.2)$$

kde  $\sigma$  je směrodatná odchylka. Laplacián Gaussovy odezvy  $L_I$  je definován konvolucí

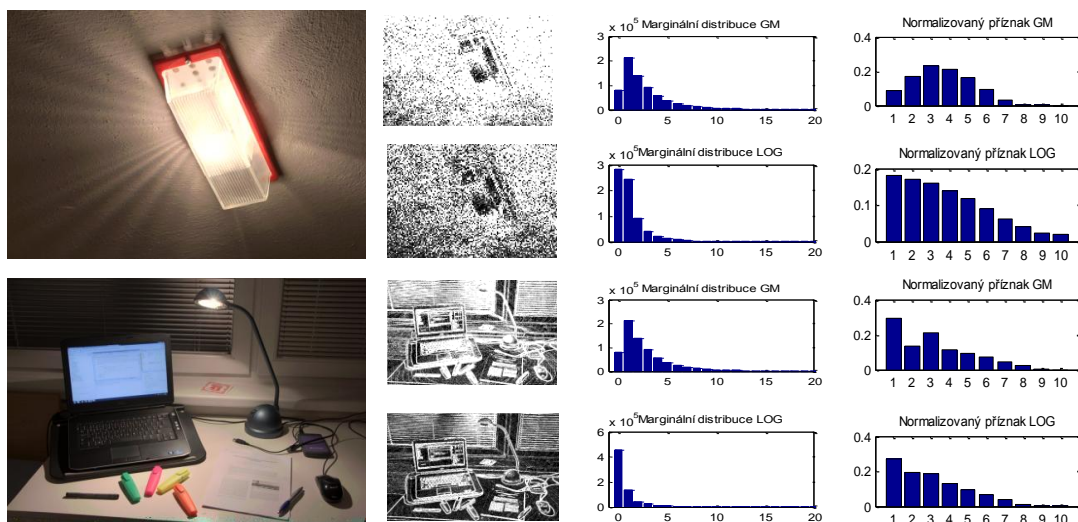
$$L_I = I * h_{LOG}, \quad (5.3.3)$$

kde je Gaussova odezva Laplaciánu

$$\begin{aligned}
 h_{LOG}(x, y|\sigma) &= \frac{\partial^2}{\partial x^2} g(x, y|\sigma) + \frac{\partial^2}{\partial y^2} g(x, y|\sigma) = \\
 &= \frac{1}{2\pi\sigma^2} \frac{x^2 + y^2 - 2\sigma^2}{\sigma^4} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right)
 \end{aligned} \tag{5.3.4}$$

### 5.3.2 Normalizace JAN

Produkty GM a LOG jsou na Obr. 5.3.1 [8]. Na prvním obrázku se světlem se nachází více GM a LOG příznaků než na druhém obrázku s lampičkou. Z tohoto důvodu není vhodné použít marginální distribuci příznaků. Metoda BIQA rozkládá obraz na dva kanály – kanál GM a kanál LOG a normalizuje je metodou JAN (Joint Adaptive Normalization).



**Obr. 5.3.1** Marginální distribuce GM a LOG příznaků před a po normalizaci JAN

Příznaky jsou spolu normalizovány

$$F_I(i, j) = \sqrt{G_I^2(i, j) + L_I^2(i, j)}. \tag{5.3.5}$$

Normalizační faktor je spočítán pro každý bod v obraze  $(i, j)$

$$N_I(i, j) = \sqrt{\sum_{(l, k) \in \Omega_{i, j}} \omega(l, k) F_I^2(l, k)}. \tag{5.3.6}$$

kde  $\Omega_{i, j}$  je okno se středem v  $(i, j)$ ,  $\omega(l, k)$  je váhová funkce splňující podmínku

$$\sum_{l, k} \omega(l, k) = 1. \tag{5.3.7}$$

Příznaky GM a LOG jsou poté normalizovány jako

$$\bar{G}_I = \frac{G_I}{(N_I + \varepsilon)} \quad (5.3.8)$$

$$\bar{L}_I = \frac{L_I}{(N_I + \varepsilon)} \quad (5.3.9)$$

kde  $\varepsilon$  je malá kladná konstanta ošetřující nestabilitu, pokud je  $N_I$  malý.

### 5.3.3 Vyhodnocení příznaků

Normalizované příznaky  $G_I$  se kvantují do  $M$  stupňů  $\{g_1, g_2, \dots, g_M\}$  a příznaky  $L_I$  do  $N$  stupňů  $\{l_1, l_2, \dots, l_N\}$ . Dále je označováno  $\bar{G}_I(i, j)$  jako  $G$  a  $\bar{L}_I(i, j)$  jako  $L$  [8]. Funkce pravděpodobnosti normalizovaných příznaků  $G$  a  $L$  je označena

$$K_{m,n} = P(G = g_m, L = l_n), \quad m = 1, \dots, M; n = 1, \dots, N. \quad (5.3.10)$$

Marginální pravděpodobnost příznaků je vypočítána

$$\begin{cases} P_G(G = g_m) = \sum_{n=1}^N K_{m,n} \\ P_L(L = l_n) = \sum_{m=1}^M K_{m,n} \end{cases} \quad (5.3.11)$$

Definuje se závislost  $D_{m,n}$  mezi GM a LOG příznaky

$$D_{m,n} = \frac{K_{m,n}}{P(G = g_m) \times P(L = l_n)}. \quad (5.3.12)$$

Pokud je  $D_{m,n} = 1$  pro všechna  $m$  a  $n$ , jsou na sobě nezávislé. Přesná závislost  $G = g_m$  na  $L$  je definována

$$Q_G(G = g_m) = P(G = g_m) \cdot \frac{1}{N} \sum_{n=1}^N D_{m,n}. \quad (5.3.13)$$

Obdobně je definována závislost  $L = l_n$  na  $G$

$$Q_L(L = l_n) = P(L = l_n) \cdot \frac{1}{M} \sum_{m=1}^M D_{m,n}. \quad (5.3.14)$$

Jelikož platí

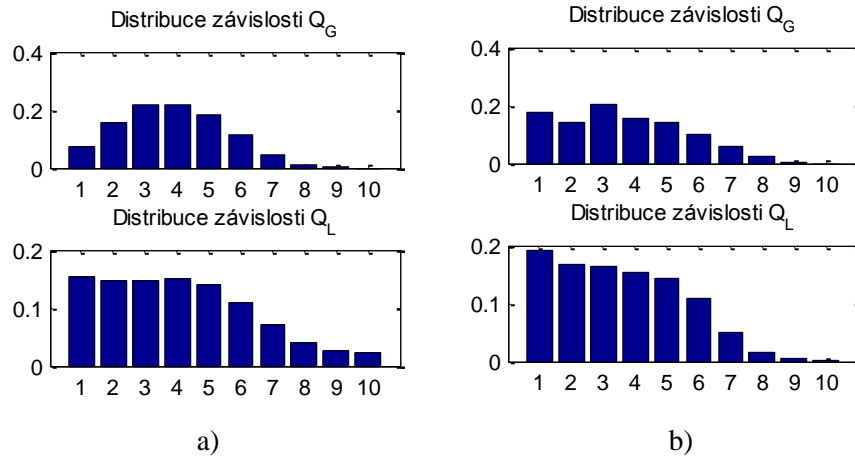
$$\sum_n Q_G(G = g_m) = \sum_m Q_L(L = l_n) = 1. \quad (5.3.15)$$

Lze přepsat závislosti  $Q_G$  a  $Q_L$  do vztahů



$$Q_G(G = g_m) = \frac{1}{N} \sum_{n=1}^N \frac{P(G = g_m, L = l_n)}{P(L = l_n)} = \frac{1}{N} \sum_{n=1}^N P(G = g_m | L = l_n). \quad (5.3.16)$$

$$Q_L(L = l_n) = \frac{1}{M} \sum_{m=1}^M \frac{P(G = g_m, L = l_n)}{P(G = g_m)} = \frac{1}{M} \sum_{m=1}^M P(L = l_n | G = g_m). \quad (5.3.17)$$



**Obr. 5.3.2** Distribuční funkce nezávislosti mezi normalizovanými GM a LOG příznaky, a) světlo, b) lampička

### 5.3.4 Modely metody

Metoda BIQA pracuje se třemi typy regresních modelů [8], které byly natrénovány pomocí marginálních distribucí  $P_G$  a  $P_L$  (model M1) nebo závislostí  $Q_G$  a  $Q_L$  (model M2) nebo kombinací  $P_G$ ,  $P_L$ ,  $Q_G$  a  $Q_L$  (model M3).

Je dán model příznaků a výsledky hodnocení DMOS (Difference Mean Opinion Score) trénovacích obrazů (např. LIVE database [48], CSIQ database [49], TID2008 [50]). Z trénovacích obrazů je naučena regresní funkce k namapování příznaků obrazu do výsledků DMOS. Metoda BIQA využívá vektorů regresní funkce  $\varepsilon$ -SVR (Support Vector Regression [51]).

Jsou dána trénovací data  $\{(x_1, y_1), \dots, (x_k, y_k)\}$ , kde  $x_i$ ,  $i = 1, \dots, k$ , je vektor příznaků a  $y_i$  je výsledek DMOS hodnocení. Vstupní vektor

$$f(x) = \langle \omega, x \rangle + b, \quad (5.3.18)$$

kde  $\omega$  je váhovací vektor,  $b$  je parametr sklonu. Výsledná regresní funkce je definována

$$f(x) = \sum_{i=1}^k t_i k(x_i, x) + b, \quad (5.3.19)$$

kde  $k$  je jádro funkce

$$k(x_i, x) = \exp\left[-\gamma |x_i - x|^2\right], \quad (5.3.20)$$

$\gamma$  je parametr přesnosti. Výsledná odhadovaná kvalita po regresi  $Q_p$

$$Q_p = \beta_1 \left( \frac{1}{2} - \frac{1}{\exp(\beta_2(Q - \beta_3))} \right) + \beta_4 Q + \beta_5, \quad (5.3.21)$$

je dána regresními parametry modelu  $\beta_1, \beta_2, \beta_3, \beta_4$  a  $\beta_5$ .


## 5.4 CS – univerzální hodnocení kvality obrazu pomocí contourlet transformace a singulární dekompozice

Metodu CS (Contourlet Transform and Singular Value Decomposition) navrhli autoři Q. Sang, X. Wu, Ch. Li a Y. Lub [9]. Většina algoritmů objektivního hodnocení vyžaduje proces trénování nebo učení. Metoda CS je nezávislá na předchozích procesech a není závislá ani na znalosti původního obrazu (NR) a zkreslení (DU). Lze ji tedy zařadit mezi kompletně slepé metody. Vychází z příznaků odvozených z contourlet transformace obrazu (Contourlet Transform) a singulární dekompozice SVD (Singular Value Decomposition). Algoritmus se skládá ze tří kroků – contourlet transformace, rozkladu na singulární čísla a hodnocení.


Metoda vychází z předchozích poznatků IQA metod [52], [53] využívajících k hodnocení singulární hodnoty zkresleného a referenčního obrazu s tím rozdílem, že nemusí znát původní obraz. Metoda CS si klade za cíl nalézt singulární křivku, která přináší informaci o zkreslení obrazu a z ní následně vytvořit IQA model. Výsledkem metody CS jsou dva hodnotící indexy  $CS_S$  a  $CS_K$ .

### 5.4.1 Contourlet transformace

Algoritmus hledá vysoké frekvence (detekce hran) v obraze za pomoci contourlet transformace [54]. Aplikuje se postup Laplaceovy pyramidy (LP) [55], která nalezne body nespojitosti v jednotlivých subpásmech a následně je použita banka směrových filtrů DFB (Directional Filter bank) [56]. LP rozkládá obraz do radiální řady subpásem, každý Laplaceův produkt je rozložen pomocí DFB do směrového subpásma [9]. Schéma obrysové transformace je znázorněno na Obr. 5.4.1.



**Obr. 5.4.1** Schéma obrysové transformace



Obr. 5.4.2 Rozložení obrazu pomocí DFB

### 5.4.2 SVD a singulární křivka

Singulární rozklad obrazu  $A$  vychází ze součinu matic

$$A = USV^T, \quad (5.4.1)$$

kde  $U$  a  $V$  jsou ortogonální matice  $UTU = I$ ,  $VTV = I$ .  $I$  je jednotková matice a  $S$  je diagonální matice


$$S = \begin{bmatrix} S_1 & 0 \\ 0 & 0 \end{bmatrix}, \quad S_1 = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r), \quad (5.4.2)$$

kde  $r$  je hodnota matice obrazu  $A$ . Diagonála matice představuje singulární čísla, sloupce matice  $U$  jsou levé singulární vektory a sloupce matice  $V$  jsou pravé singulární vektory obrazu  $A$ .

Aplikací SVD na strukturální obraz (např. Obr. 5.4.2), jehož hodnoty jsou v rozmezí od 30 do 100, vznikne singulární vektor  $B$

$$B = (\beta_1, \beta_2, \dots, \beta_N) = (\sigma_{l+1}, \sigma_{l+2}, \dots, \sigma_{l+N}), \quad (5.4.3)$$

kde  $\sigma_l$  jsou singulární čísla. Na Obr. 5.4.3 jsou vykresleny vektory pro dva druhy zkreslení a různé velikosti. Čím je zkreslení větší, tím je graf strmější.



Obr. 5.4.3 SVD křivky obrazů s různým zkreslením

### 5.4.3 Hodnotící indexy

Singulární křivka je funkcí vektoru  $B$ . První index je charakterizován plochou pod křivkou vektoru  $B$ . Spočte se plocha pod křivkou vymezenou vektory  $B$  a osami, která definuje hodnotící index

$$CS_s = \sum_{i=1}^N [B(i)] = \sum_{i=1}^N (\beta_i), \quad (5.4.4)$$

kde  $N$  je počet singulárních čísel a  $B$  je vektor, jehož hodnoty jsou v rozmezí od 30 do 100. Druhý index je určen aproximací lineární funkce

$$f(i) = ki + 100, \quad (5.4.5)$$

kde  $k$  určuje sklon úsečky závislý na zkreslení obrazu, tudíž měří kvalitu obrazu. Výsledný hodnotící index je definován jako

$$CS_k = \frac{\sum_{i=1}^N [B(i) - 100]}{\sum_{i=1}^N [i^2]} = \frac{\sum_{i=1}^N i(\beta_i - 100)}{\sum_{i=1}^N [i^2]}, \quad (5.4.6)$$

kde  $N$  je počet singulárních hodnot a  $B$  je vektor, jehož hodnoty jsou v rozmezí od 30 do 100.

## 5.5 DRIM – hodnocení kvality nezávisle na dynamickém rozsahu

Záměrem autorů T. O. Aydına, R. Mantiuka, K. Myszkowskiho a H. Seidela bylo vytvořit metodu objektivního hodnocení zaměřenou na obrazy s vysokým dynamickým rozsahem [10]. Vytvořili metodu DRIM (Dynamic Range Independent Image Quality Assessment). Metoda je založena na porovnávání testovaného obrazu s původním obrazem (FR). Výstupem metody je mapa zkreslení, jež zobrazuje tři kategorie zkreslení. Předností metody je porovnávání dvou obrazů nezávisle na jejich dynamickém rozsahu.

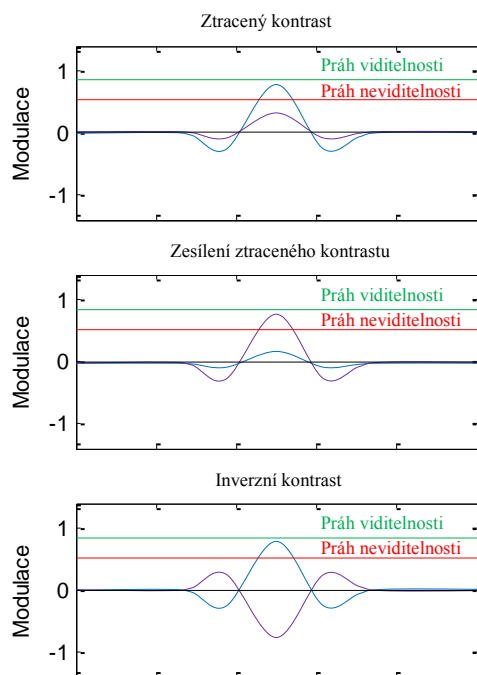
### 5.5.1 Typy zkreslení podle prahu detekce

Na Obr. 5.5.1 jsou zobrazeny tři kategorie zkreslení, které mohou nastat při mapování obrazu. Kategorie vychází podle zvoleného prahu detekce.

Prvním případem je ztráta kontrastu. Znamená to tedy, že kontrast, který byl v původním obrazu, není vidět v testovaném obrazu.

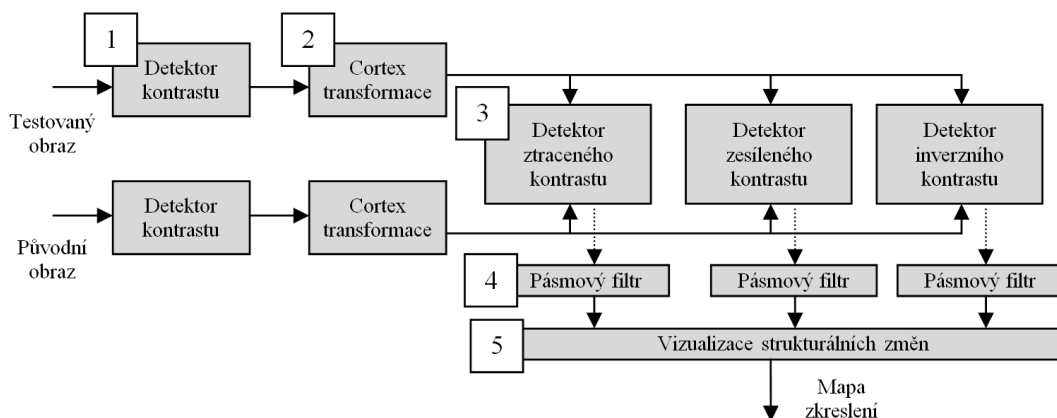
Druhým případem je zesílení kontrastu. Je to opačná situace prvního případu, kdy se v testovaném obrazu objeví kontrast, jenž se v původním obrazu nenacházel. Projevem může být zvýraznění nechtěných artefaktů obrazu.

Třetí případ zkreslení nastává, pokud je kontrast viditelný v obou obrazech, ale v testovaném obrazu má rozdílnou polaritu. Situace může nastat například při ořezání vyšších frekvencí (clipping) při mapování obrazu.



**Obr. 5.5.1** Klasifikace zkreslení dle změny kontrastu mezi původním (modře) a mapovaným obrazem (fialově)

Na Obr. 5.5.2 se nachází schéma metody DRIM. Metoda se skládá z pěti dílčích kroků. Aby se dala hodnotit zkreslení, musí se nejdříve určit, o který případ zkreslení se jedná. Do metody vstupují dva obrazy – testovací a původní. V prvním kroku se použije detektor kontrastu [57], odhadne se práh detekce a vytvoří se normalizovaná mapa. Amplitudy v normalizované mapě, které jsou rovny 1, odpovídají prahu detekce  $P_{det} = 75\%$ . Ve druhém kroku se aplikuje cortex transformace [58] s modifikací [59], čímž se rozdělí normalizovaná mapa do několika pásem s rozdílnou orientací a prostorovými pásmy.



**Obr. 5.5.2** Schéma metody DRIM

Doposud byly obrazy zpracovávány ve dvou rovinách, testované a referenční. Ve třetím kroku dochází k jejich porovnávání [10]. Spočítá se pravděpodobnost  $P^{k,l}$  každého prostorového pásma pro ztracený kontrast, zesílení neviditelného kontrastu a inverzního viditelného kontrastu

$$P_{loss}^{k,l} = P_{r/v}^{k,l} \cdot P_{t/i}^{k,l}, \quad (5.5.1)$$

$$P_{ampl}^{k,l} = P_{r/i}^{k,l} \cdot P_{t/v}^{k,l}, \quad (5.5.2)$$

$$P_{rev}^{k,l} = P_{r/v}^{k,l} \cdot P_{r/v}^{k,l} \cdot R^{k,l}, \quad (5.5.3)$$

kde  $k$  a  $l$  jsou prostorové indexy,  $r$  a  $t$  označují referenční (původní) a testovaný obraz,  $v$  a  $i$  je viditelný a neviditelný kontrast.  $R^{k,l}$  je váhovací koeficient.  $R^{k,l}$  se rovná jedné, pokud se liší polarita kontrastů původního a testovaného obrazu.

Kvůli nelineárním operacím při výpočtu pravděpodobností  $P^{k,l}$  mohou vzniknout příznaky, které nepatří do vybraného pásma. Z tohoto důvodu se ve čtvrtém kroku aplikuje cortex pásmový filtr  $B^{k,l}$

$$\hat{P}_{loss}^{k,l} = F^{-1} \left\{ F \left\{ P_{loss}^{k,l} \right\} \cdot B^{k,l} \right\}, \quad (5.5.4)$$

kteřý má za úkol odstranit nežádoucí příznaky.  $F$  a  $F^{-1}$  jsou 2D Fourierovy transformace a zpětné Fourierovy transformace.

V posledním pátém kroku se spočítá zkreslení jednotlivých pásem

$$P_{loss} = 1 - \prod_{k=1}^N \prod_{l=1}^M (1 - \hat{P}_{loss}^{k,l}), \quad (5.5.5)$$

$$P_{ampl} = 1 - \prod_{k=1}^N \prod_{l=1}^M (1 - \hat{P}_{ampl}^{k,l}), \quad (5.5.6)$$

$$P_{rev} = 1 - \prod_{k=1}^N \prod_{l=1}^M (1 - \hat{P}_{rev}^{k,l}). \quad (5.5.7)$$

### 5.5.2 Ukázka hodnocení metody DRIM

Výstupem metody je mapa tří kategorií zkreslení. Na Obr. 5.5.3 se nachází obraz pracovního stolu, který byl mapován metodou iCAM06. Největší ztráta kontrastu je patrná v oblasti žárovky lampičky, kde se nepovedlo optimálně vykreslit detaily žárovky. Naopak k zesílení kontrastu došlo v oblasti stínu notebooku a žaluzií. Převrácení kontrastu nastalo na rozhraní žárovky a stínítka světla, kde byla oblast přebuzena. K podobnému efektu došlo i na rozhraní obrazovky a rámu obrazovky. Dále došlo také ke zvýraznění artefaktů na rozhraní stínů notebooku a stolu.

Z Obr. 5.5.3 je patrné, že výstupem metody není jediná hodnota odhadu kvality, což omezuje její použití v kvantitativních experimentech vyžadujících zpracování velkého množství obrazu.



**Obr. 5.5.3** Mapy tří kategorií zkreslení: zelená – ztracený kontrast, modrá – zesílený kontrast, červená – inverzní kontrast


## 6 Porovnávání TMO

Pro subjektivní hodnocení byla vybrána metoda porovnávání obrazů PC. Výhodou metody je předpoklad konzistentnějších výsledků hodnocení oproti jiným metodám. Subjektivních testů se zúčastnilo 28 pozorovatelů. Prostředí pro subjektivní testy navrhl S. Zdvihal [60] v rámci diplomové práce. Testy byly provedeny na kalibrovaných monitorech s rozlišením  $1600 \times 1200$  pixelů. Před začátkem testu byla pozorovatelům vysvětlena daná problematika a bylo jim řečeno, aby zvolili obraz, který preferují.

Výsledkem hodnocení jsou data s preferovanými obrazy, z nichž se za pomoci Bradley-Terryho modelu [61] získá hodnocení na stupnici BT skóre. BT skóre je vypočítáno na základě procentuálních preferencí jednotlivých testovaných obrazů.


### 6.1 Výsledky subjektivních testů

Skupina pozorovatelů hodnotila šest motivů obrazů s různým nastavením parametrů vybraných čtyř operátorů pro mapování tónů. Přehled použitých motivů obrazů je zobrazen na Obr. 6.1.1 a Obr. 6.1.2. Obrazy s láhvemi [62], testovacími tabulkami [62] a venkovní kavárnou [63] byly převzaty z volně dostupných knihoven. Zbylé obrazy vznikly v rámci testování snímání HDR obrazu metodou snímání vícenásobnou expozicí. Kompletní přehled obrazů je v apendixu této práce.



**Obr. 6.1.1** Testované motivy – a) láhve [62], b) tabulky [63], c) lampička, d) světlo





**Obr. 6.1.2** Testované motivy – e) město, f) café [63]

Na Obr. 6.1.3 jsou vyobrazeny výsledky subjektivních testů, BT skóre a interval spolehlivosti. Na každém řádku jsou výsledky v rámci jednoho motivu obrazu,  $x$ -ová osa zobrazuje čísla po sobě jdoucích dvojic jednoho operátoru. Operátory skrývající se pod lichými čísly zpravidla dosahují lepších výsledků oproti sudým pozicím stejného operátoru, protože představují optimální nastavení parametrů. Při hledání optimálního nastavení se nejprve vycházelo z výchozího nastavení jednotlivých operátorů a následně byla zkoušena další nastavení. Pokud nebylo zobrazení LDR obrazu uspokojivé, hledala se jiná nastavení v celém rozsahu parametrů.

Druhý obrázek v řádku zobrazuje statistickou významnost. Pokud se překrývají intervaly spolehlivosti dvou vzorků, znamená to, že jsou vzájemně statisticky nevýznamné. Statisticky nevýznamné vzorky jsou označeny černým obdélníkem. Pro statisticky významné vzorky platí opak a jsou značeny bílým obdélníkem.

První motiv obsahuje zátiší s lahvemi. Většina uvedených operátorů si s ním poradila dobře, výjimkou byla druhá varianta Dragova operátoru. Drago má obecně tendenci posouvat barevné podání do světlých odstínů. Za povšimnutí stojí prkna, na kterých stojí všechny předměty. Většina pozorovatelů nepřikláněla váhu tomu, že jsou ve stínu a například Reinhard měl problémy s jejich kresbou. Pozorovatelům více záleželo na obsahu a vykreslení detailů uprostřed obrazu.

Na druhém motivu stojí dvě identické barevné testovací tabulky. Jedna tabulka je nasvícena, druhá je oddělena přepážkou a nachází se ve tmě. Zde si jednoznačně nejlépe poradil iCAM06, který se uměl vypořádat s velkým dynamickým rozsahem obou tabulek. Metoda je lokální, tudíž si dokáže selektivně vybrat expozici v různých místech obrazu. U ostatních operátorů byla vidět buď jedna tabulka, nebo obě dvě, ale se zkreslenými barvami.

Třetí motiv zachycuje pracovní stůl se spoustou zajímavých detailů, například lampičkou, monitorem notebooku nebo textem na dokumentu. V této situaci dokázal operátor Reinhard vykreslit nejlépe detaily světla lampičky, nicméně nejlepší celkový dojem zanechal operátor iCAM06, který si lépe poradil s textem na dokumentu a detaily na monitoru notebooku.

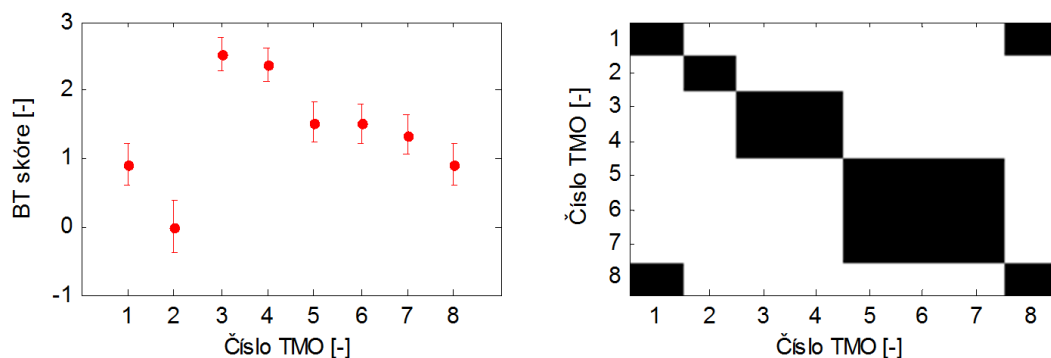
Na čtvrtém motivu svítí stropní světlo. Záměrem bylo postihnout obraz s velmi vysokým dynamickým kontrastem ve scéně. Tento motiv byl podle výsledků i ohlasů

nejkomplikovanější a pozorovatelé se ve svých preferencích velmi lišili. Hodně vzorků je statisticky nevýznamných, proto se nedá jasně stanovit, který operátor je subjektivně nejlepší.

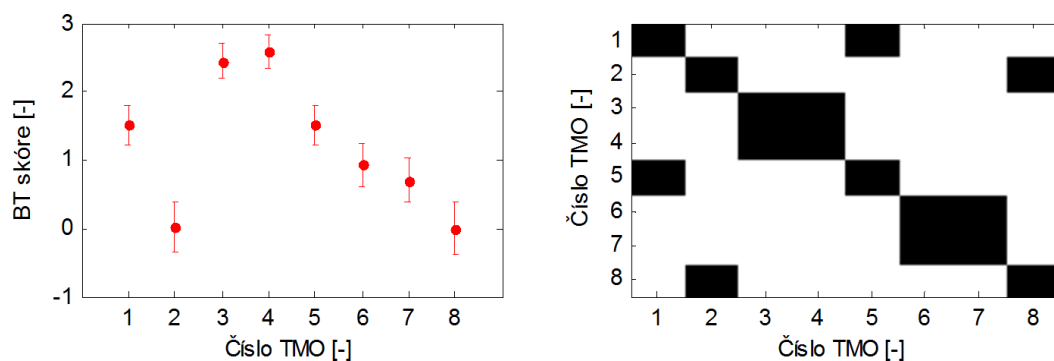
V pátém motivu je pohled na noční město s továrnou. Vykreslení motivu bylo problematické. Každý operátor zobrazoval oblohu v jiném podání, od zahnědlé přes modrou až černou. Nejlepších subjektivních výsledků dosáhl operátor Reinhard a iCAM06. Nejhůře si poradil operátor Reinhard-Devlin, který se s tímto motivem neuměl vypořádat. Obraz je přesevřený a noční obloha nepřírozně modrá.

Poslední obrázek ukazoval exteriér s kavárnou. Nejlépe byl hodnocen operátor Reinhard. Překvapivě si poradil i Dragův operátor, který svým světlým podáním působil na pozorovatele pozitivně. Naopak špatně skončil operátor iCAM06, který při nastavování parametrů a pokusu o zesvětlení zkrasoval barvy.

Motiv č. 1 – láhve



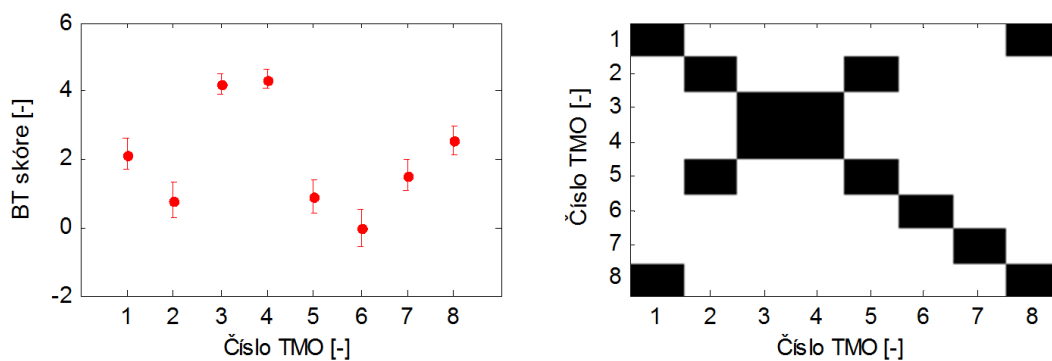
Motiv č. 2 – tabulky



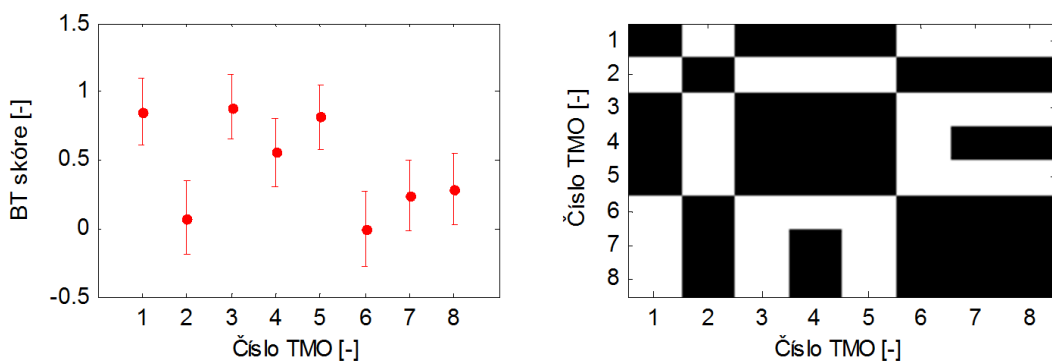
TMO: 1,2 – Drago, 3,4 – iCAM06, 5,6 – Reinhard, 7,8 – Reinhard-Devlin

**Obr. 6.1.3** Statistické výsledky a statistická významnost

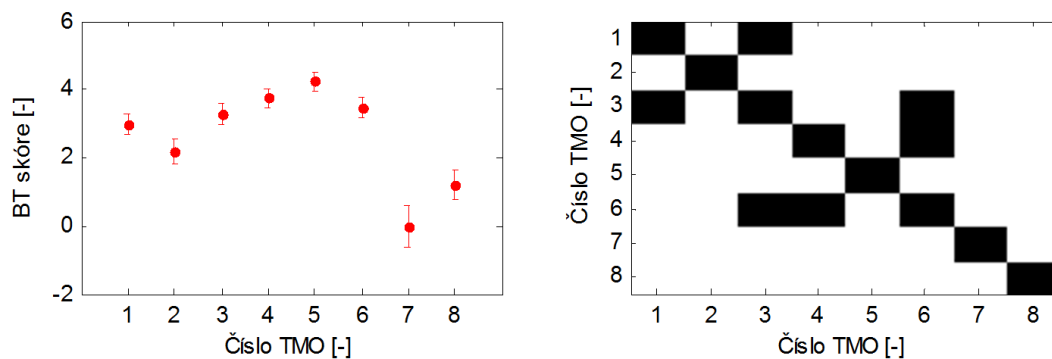
Motiv č. 3 – lampička




Motiv č. 4 – světlo



Motiv č. 5 – město



Motiv č. 6 – café



TMO: 1,2 – Drago, 3,4 – iCAM06, 5,6 – Reinhard, 7,8 – Reinhard-Devlin

**Obr. 6.1.4** Statistické výsledky a statistická významnost

### 6.1.1 Souhrn výsledků porovnávání TMO

Byly porovnávány čtyři operátory pro mapování tónů. Tři operátory byly globální a jeden lokální. Globální operátory zastupoval Drago, Reinhard a Reinhard-Devlin. Částečně lze považovat i Reinharda za lokální metodu, protože má dva druhy nastavení – globální i lokální. Jediným ryze lokálním operátorem byl iCAM06 a právě tento operátor byl preferován v nejvíce případech. Druhým nejpreferovanějším operátorem byl Reinhard, třetí byl Drago. Na posledním místě se umístil Reinhard-Devlin.

**Tab. 6.1.1** Souhrn výsledků pozorování TMO

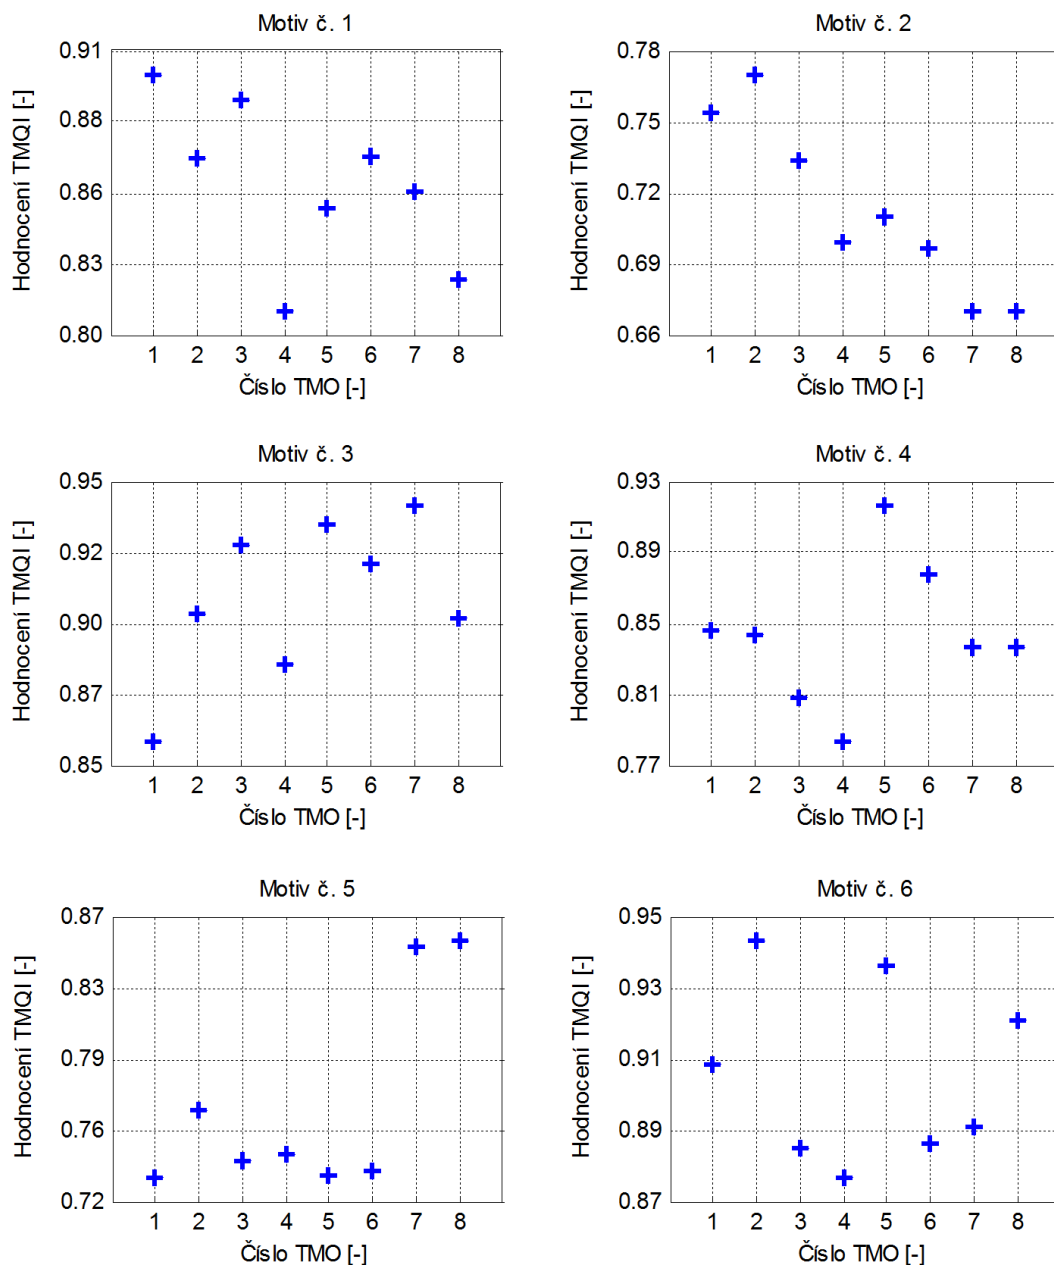
		TMO č. 1	TMO č. 2	TMO č. 3	TMO č. 4	TMO č. 5	TMO č. 6	TMO č. 7	TMO č. 8
Motiv č. 1	Pořadí	7	8	1	2	3	4	5	6
	BT skóre	0,900	0	<b>2,539</b>	2,368	1,532	1,511	1,350	0,900
Motiv č. 2	Pořadí	4	7	2	1	6	8	5	3
	BT skóre	2,131	0,798	4,210	<b>4,334</b>	0,907	0	1,535	2,536
Motiv č. 3	Pořadí	3	7	2	1	4	5	6	8
	BT skóre	1,504	0,026	2,447	<b>2,584</b>	1,504	0,926	0,708	0
Motiv č. 4	Pořadí	2	7	1	4	3	8	6	5
	BT skóre	0,851	0,076	<b>0,889</b>	0,555	0,813	0	0,244	0,281
Motiv č. 5	Pořadí	5	6	4	2	1	3	8	7
	BT skóre	2,984	2,174	3,267	3,750	<b>4,229</b>	3,457	0	1,203
Motiv č. 6	Pořadí	4	3	6	7	2	1	8	5
	BT skóre	1,534	1,759	0,334	0,098	2,116	<b>2,402</b>	0	0,447

## 6.2 Vyhodnocení objektivních testů

V předchozí kapitole pozorovatelé hodnotili mapované obrazy. Stejně obrazy byly použity pro hodnocení čtyř objektivních metrik – TMQI, NIQE, BIQA a CS. Vyhodnocení objektivních testů slouží jako podklad pro porovnání se subjektivními testy a ověření účinnosti objektivních testů.

### 6.2.1 Hodnocení TMQI

Metoda je speciálně navržena pro hodnocení HDR obrazů. Počítá komplexní index kvality Q, který je složen ze dvou složek hodnocení, strukturální similarity S a přirozenosti N. V tabulkách je uveden index kvality Q.

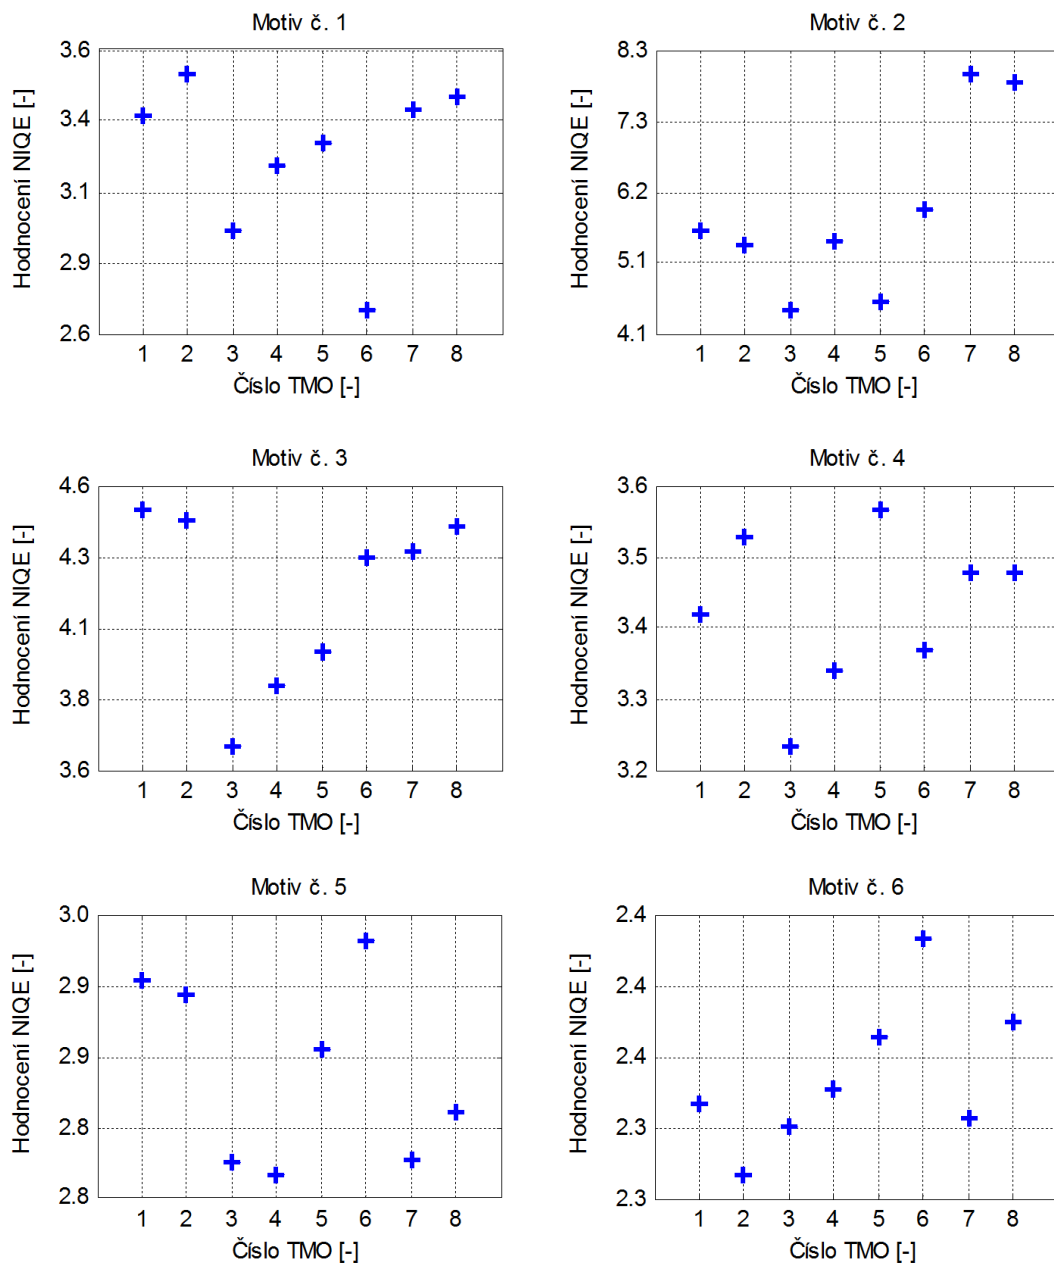


TMO: 1,2 – Drago, 3,4 – iCAM06, 5,6 – Reinhard, 7,8 – Reinhard-Devlin

**Obr. 6.2.1** Výsledky hodnocení TMQI

## 6.2.2 Hodnocení NIQE

Metoda vychází z předpokladů statistik známých typů zkreslení. Počítá index kvality odvozený z rozdílů přirozeného modelu MVG a modelu MVG testovaného obrazu.

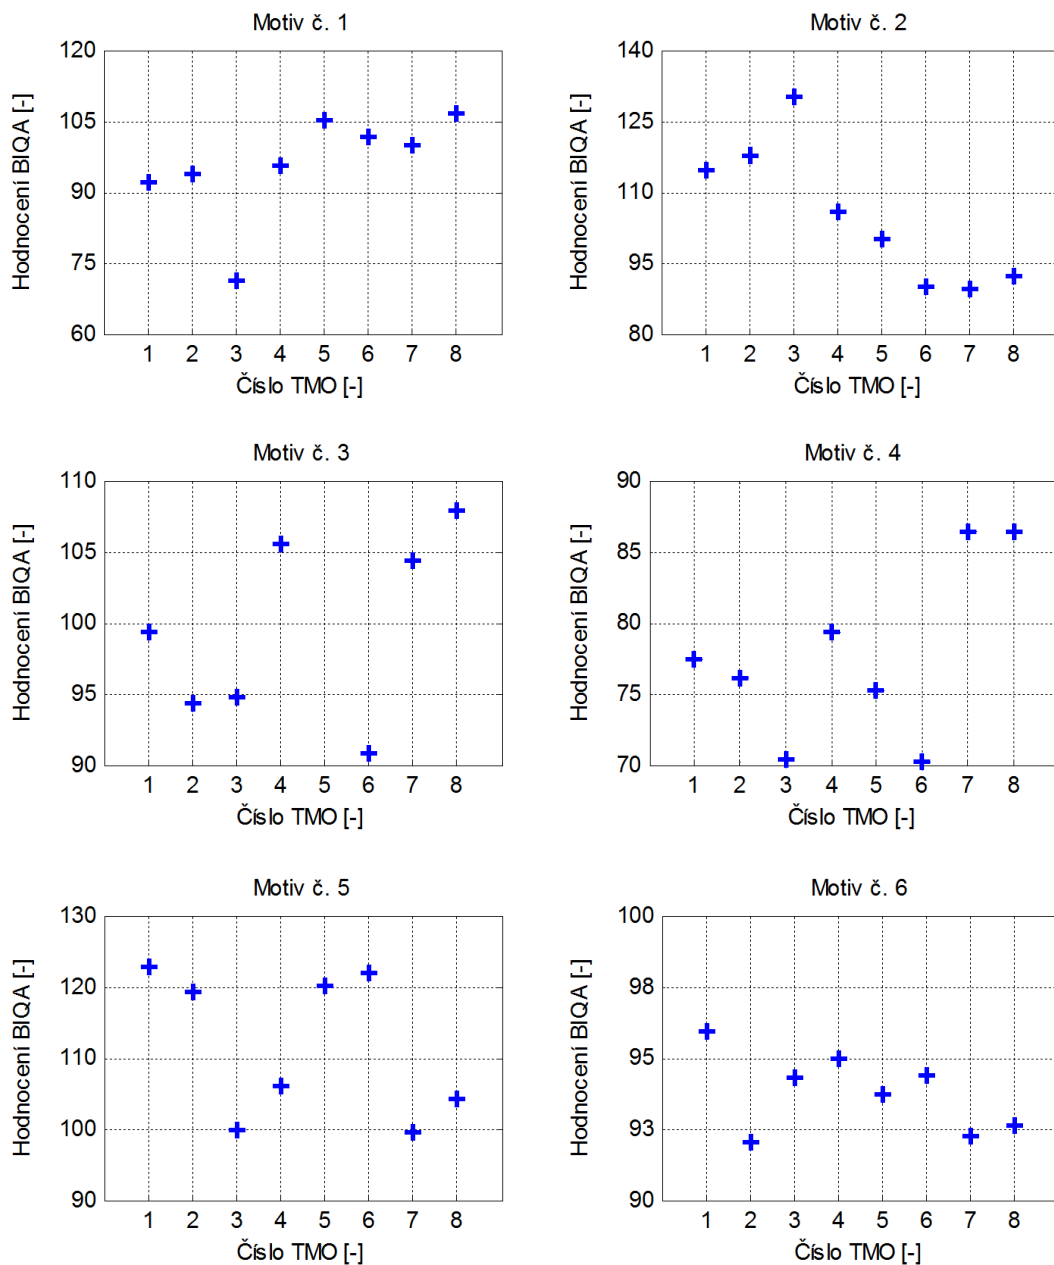


TMO: 1,2 – Drago, 3,4 – iCAM06, 5,6 – Reinhard, 7,8 – Reinhard-Devlin

**Obr. 6.2.2** Výsledky hodnocení NIQE

### 6.2.3 Hodnocení BIQA

V metodě jsou zmiňovány tři indexy hodnocení ( $M_1$ – $M_3$ ). Pro účely hodnocení byl použit index  $M_3$ , který dle autorů metody dosahuje nejlepších výsledků.

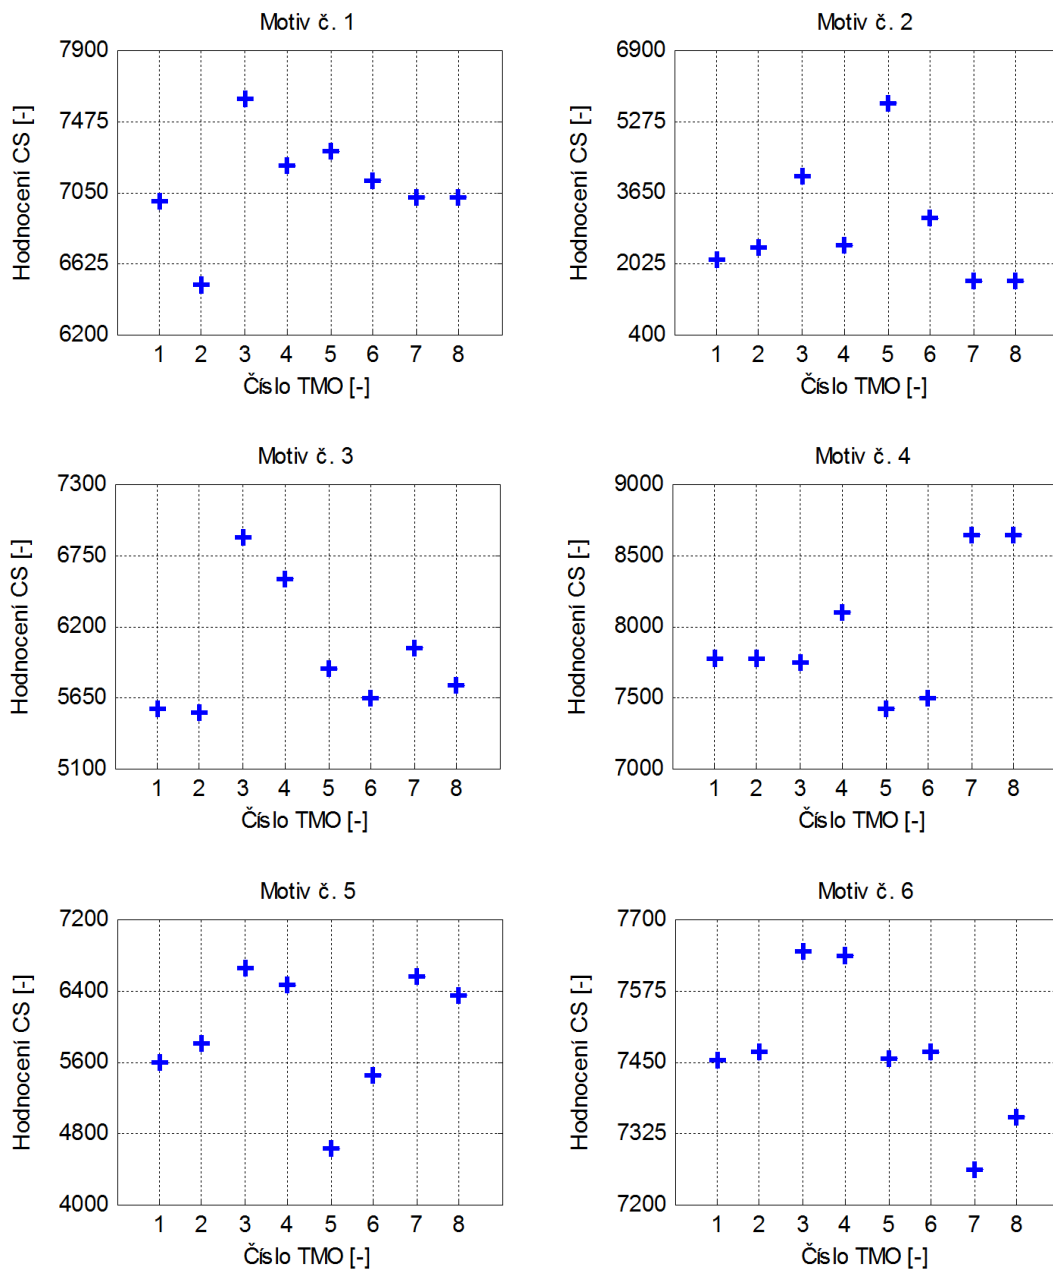


TMO: 1,2 – Drago, 3,4 – iCAM06, 5,6 – Reinhard, 7,8 – Reinhard-Devlin

**Obr. 6.2.3** Výsledky hodnocení BIQA

### 6.2.4 Hodnocení CS

Kompletně slepá metoda používá dva indexy hodnocení ( $CS_S$  a  $CS_k$ ). V následujících tabulkách je uveden index  $CS_k$ .




TMO: 1,2 – Drago, 3,4 – iCAM06, 5,6 – Reinhard, 7,8 – Reinhard-Devlin

**Obr. 6.2.4** Výsledky hodnocení CS

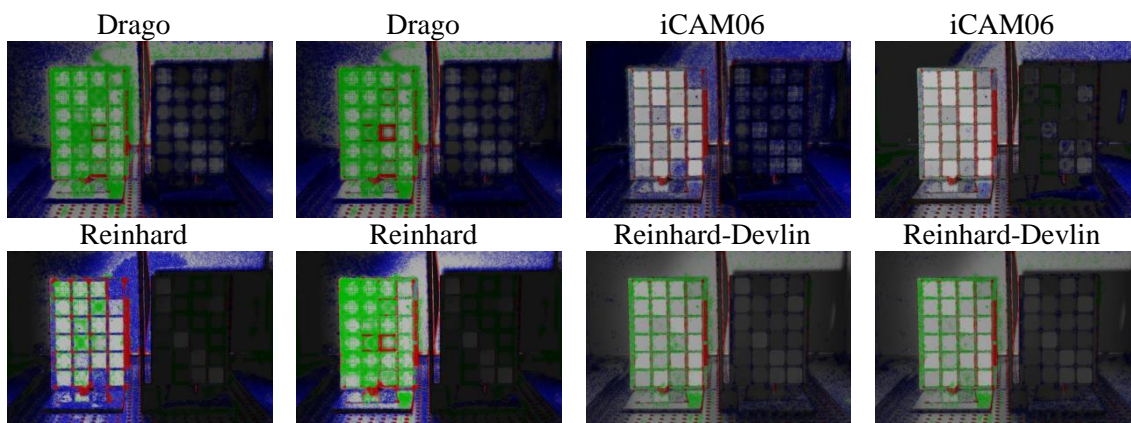


### 6.2.5 Hodnocení DRIM

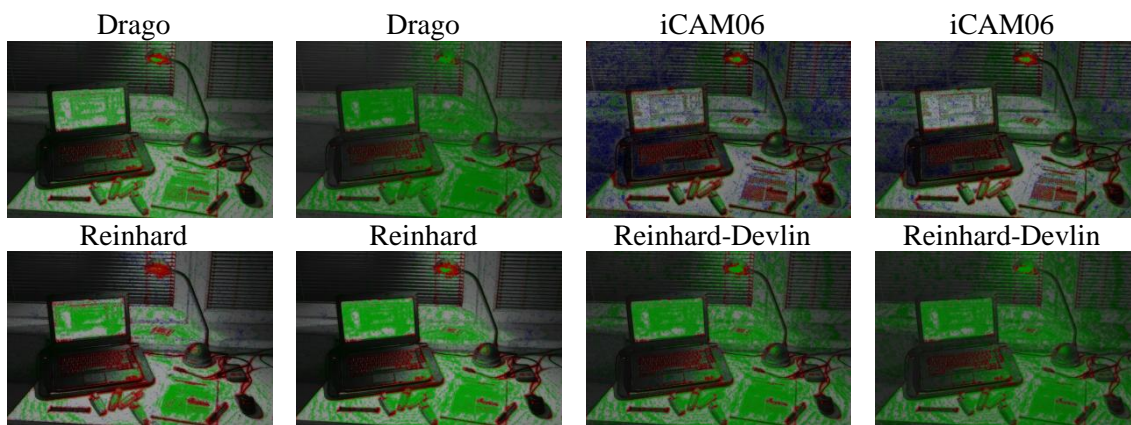
Výsledky této metody nepřináší konkrétní číslo. Záměrem autorů je hodnocení vizualizované na mapě zkreslení. Na první pohled je tak patrné, v jakých místech došlo ke změně kontrastu. V následujících obrázcích jsou zobrazeny výsledné mapy tří typů zkreslení – ztracený kontrast (zelená), zesílený kontrast (modrá), inverzní kontrast (červená).




Obr. 6.2.5 Hodnocení DRIM, motiv č. 1




Obr. 6.2.6 Hodnocení DRIM, motiv č. 2



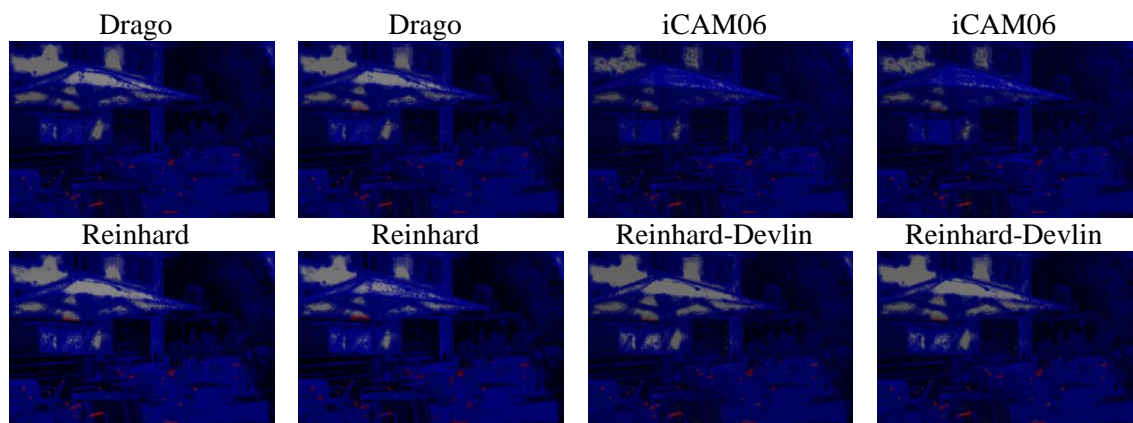
Obr. 6.2.7 Hodnocení DRIM, motiv č. 3



Obr. 6.2.8 Hodnocení DRIM, motiv č. 4



Obr. 6.2.9 Hodnocení DRIM, motiv č. 5



Obr. 6.2.10 Hodnocení DRIM, motiv č. 6

### 6.3 Účinnost objektivních metod

K ověření účinnosti objektivních metod je zapotřebí nalézt závislost mezi objektivními a subjektivní metodami. Pro ověření účinnosti byly vybrány tři korelační testy.

Spearmanův korelační koeficient [5] vyjadřuje korelaci mezi dvěma statistickými veličinami. V tomto případě se jedná o porovnávání subjektivní metody PC

a objektivního hodnocení. Výsledkem je bezrozměrné číslo z intervalu od  $-1$  do  $+1$  ukazující závislost mezi subjektivními a objektivními testy

$$\text{SRCC} = 1 - \frac{6 \sum_{i=1}^N d_i^2}{N(N^2 - 1)}, \quad (6.3.1)$$

kde  $d_i$  je rozdíl mezi hodnocením  $i$ -tého obrazu subjektivního a objektivního hodnocení.  $N$  je počet párů. Koeficient SRCC může být také označován písmenem  $\rho$ .

Další závislost lze hledat pomocí Kendallova korelačního koeficientu

$$\text{KRCC} = \frac{N_c - N_d}{\frac{1}{2}N(N-1)}, \quad (6.3.2)$$

kde  $N_c$  je počet správně určených (konkordantních) párů a  $N_d$  je počet špatně určených (diskordantních) párů.  $N$  je celkový počet párů. Pokud se všichni pozorovatelé neshodnou na preferenci obrazu v daném páru, je nežádoucí, aby korelační test bral do úvahy tento pár pro posuzování závislosti. Z tohoto důvodu vznikla modifikovaná verze Kendallova koeficientu [64], který posuzuje pouze statisticky významné páry, na kterých se shodli pozorovatelé při subjektivních testech. Modifikovaný Kendallův koeficient je pak počítán podle vztahu

$$\text{KRCC}_M = \frac{N_c - N_d}{M}. \quad (6.3.3)$$

$M$  je celkový počet párů. Kendallův koeficient je označován také písmenem  $\tau$ . Stejně jako v případě Spearmanova koeficientu je výsledkem bezrozměrné číslo z intervalu od  $-1$  do  $+1$ .

### 6.3.1 Hodnocení účinnosti objektivních metod

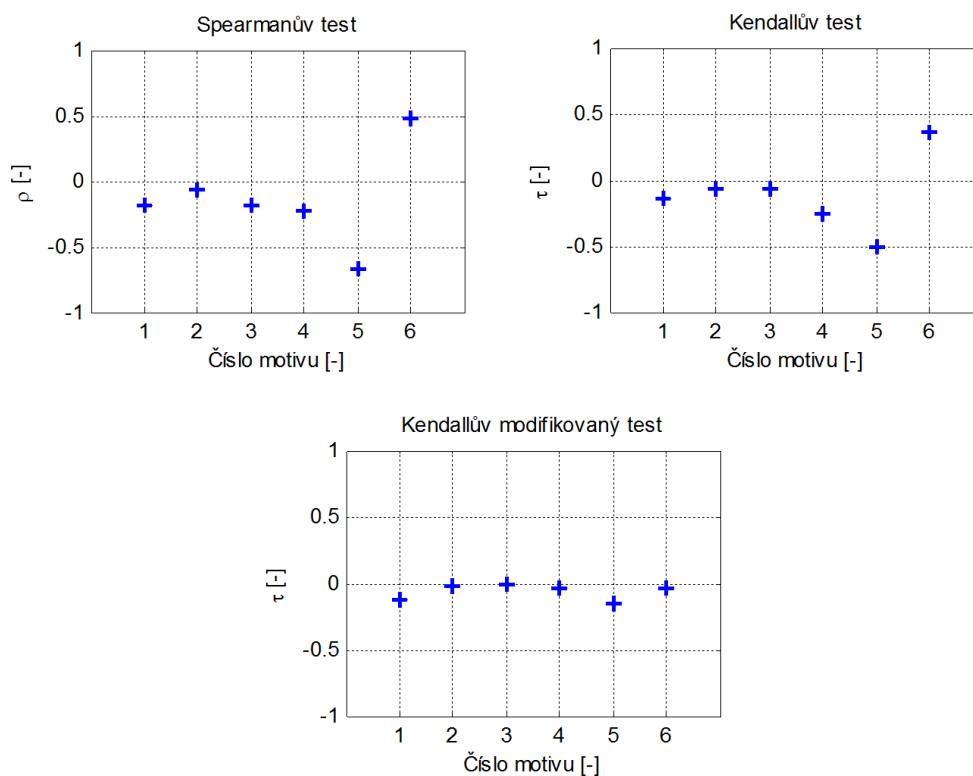
Na následujících obrázcích jsou zobrazeny výsledky tří typů testů porovnávajících objektivní metody s metodou PC. Výsledky Spearmanova a Kendallova testu pro jednotlivé motivy obrazů mají větší rozpětí a jsou si podobné. Oproti tomu modifikovaný Kendallův test přináší vyrovnanější výsledky a zohledňuje statisticky vzájemné páry.

Metoda TMQI je navržena přímo pro hodnocení HDR obrazů. Při testování metody se ale neprojevila žádná výrazná korelace se subjektivní metodou PC. Závislost se projevila pouze u posledního motivu s kavárnou.


Metoda NIQE kromě posledního motivu obrazu hodnoceného Spearmanovým a Kendallovým koeficientem nevykazovala žádnou závislost.

Metoda BIQA je mírně závislá téměř u všech motivů obrazů pro hodnocení modifikovaným Kendallovým testem. Spearmanův a Kendallův test odhalily závislost pro hodnocení motivu s testovacími tabulkami a nočním městem.

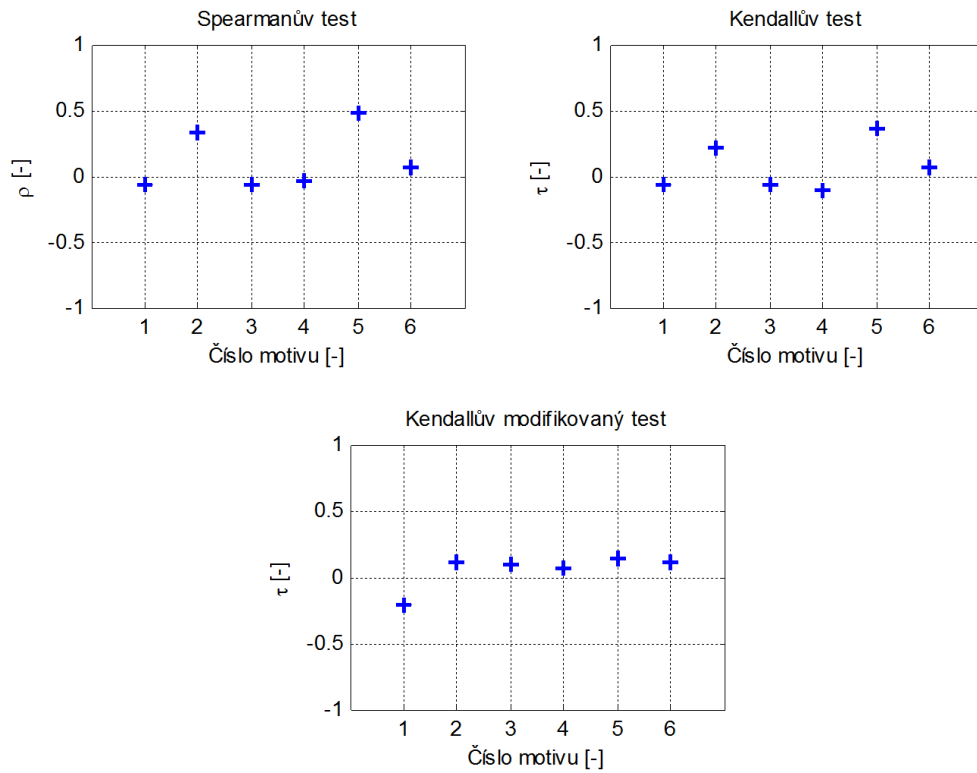
Na základě výsledků korelačních testů se ukázala metoda CS jako nejvhodnější. U hodnocení prvního motivu byla téměř stoprocentní a shodla se s názory pozorovatelů.



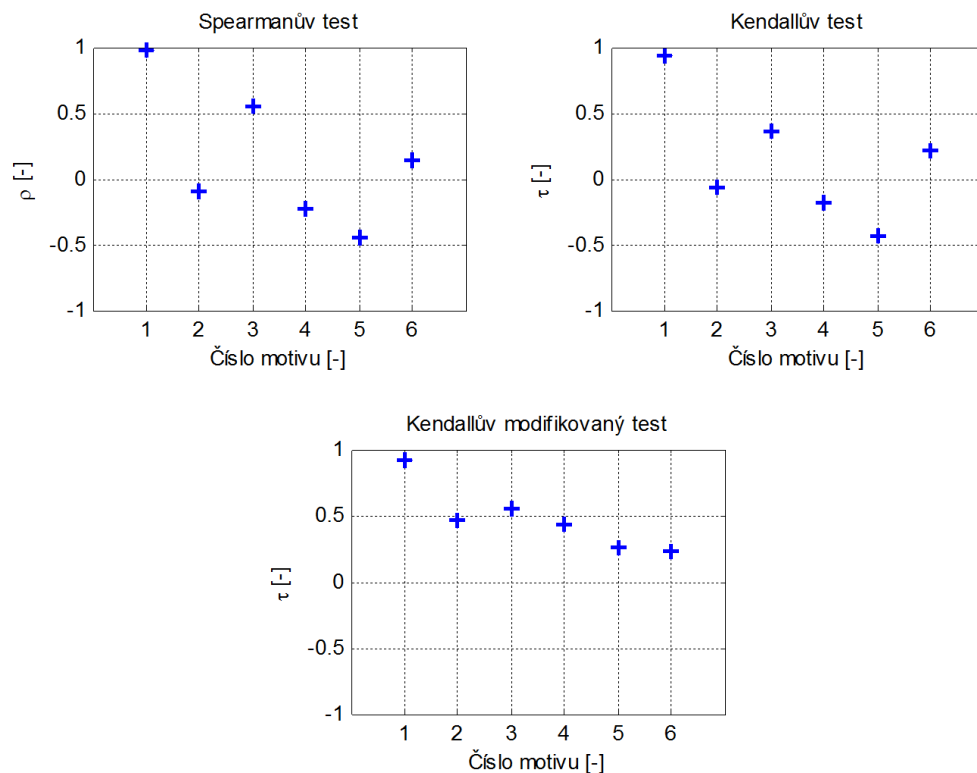
**Obr. 6.3.1** Ověření účinnosti TMQI



**Obr. 6.3.2** Ověření účinnosti NIQE



**Obr. 6.3.3** Ověření účinnosti BIQA



**Obr. 6.3.4** Ověření účinnosti CS

## 7 Závěr

V této diplomové práci byl podán přehled metod pro snímání a reprodukci HDR obrazu. HDR snímky zrealizované metodou vícenásobné expozice byly vytvořeny pomocí implementované funkce pro tvorbu HDR snímku v prostředí programu MATLAB [62]. Pro testovací účely byly použity tři takto vytvořené snímky; zbývající tři byly převzaty z volně dostupných knihoven.

Následně byly studovány metody pro mapování tónů, z nichž byly vybrány čtyři pokročilé operátory (Dragův operátor, operátor iCAM06, Reinhardův operátor a operátor Reinhard-Devlin), které byly součástí implementace Banterleho balíčku pro práci s HDR snímky [62]. Bylo zkoumáno chování parametrů vybraných operátorů, hledalo se jejich optimální nastavení a pro každý ze šesti motivů obrazu byly vytvořeny dvě varianty od každého operátoru.

V další kapitole byly představeny standardy ITU-R BT.500 a ITU-T P.910 pro subjektivní posouzení kvality mapovaných obrazů a byla vybrána metoda porovnávání snímků PC, jež byla nejvhodnější z hlediska předpokládané konzistence výsledků. Subjektivních testů se postupně zúčastnilo 28 pozorovatelů, kteří posuzovali kvalitu obrazů mapovaných čtyřmi operátory se šesti různými motivy obrazů. Výsledky byly vyhodnoceny na stupnici BT skóre. Nejvíce preferovaným operátorem byl iCAM06, jež patří mezi lokální operátory. Na zbylých místech se umístily globální operátory. Druhým nejpreferovanějším operátorem byl Reinhard patřící částečně i mezi lokální operátory a třetí byl Drago. Na posledním místě se umístil Reinhard-Devlin.

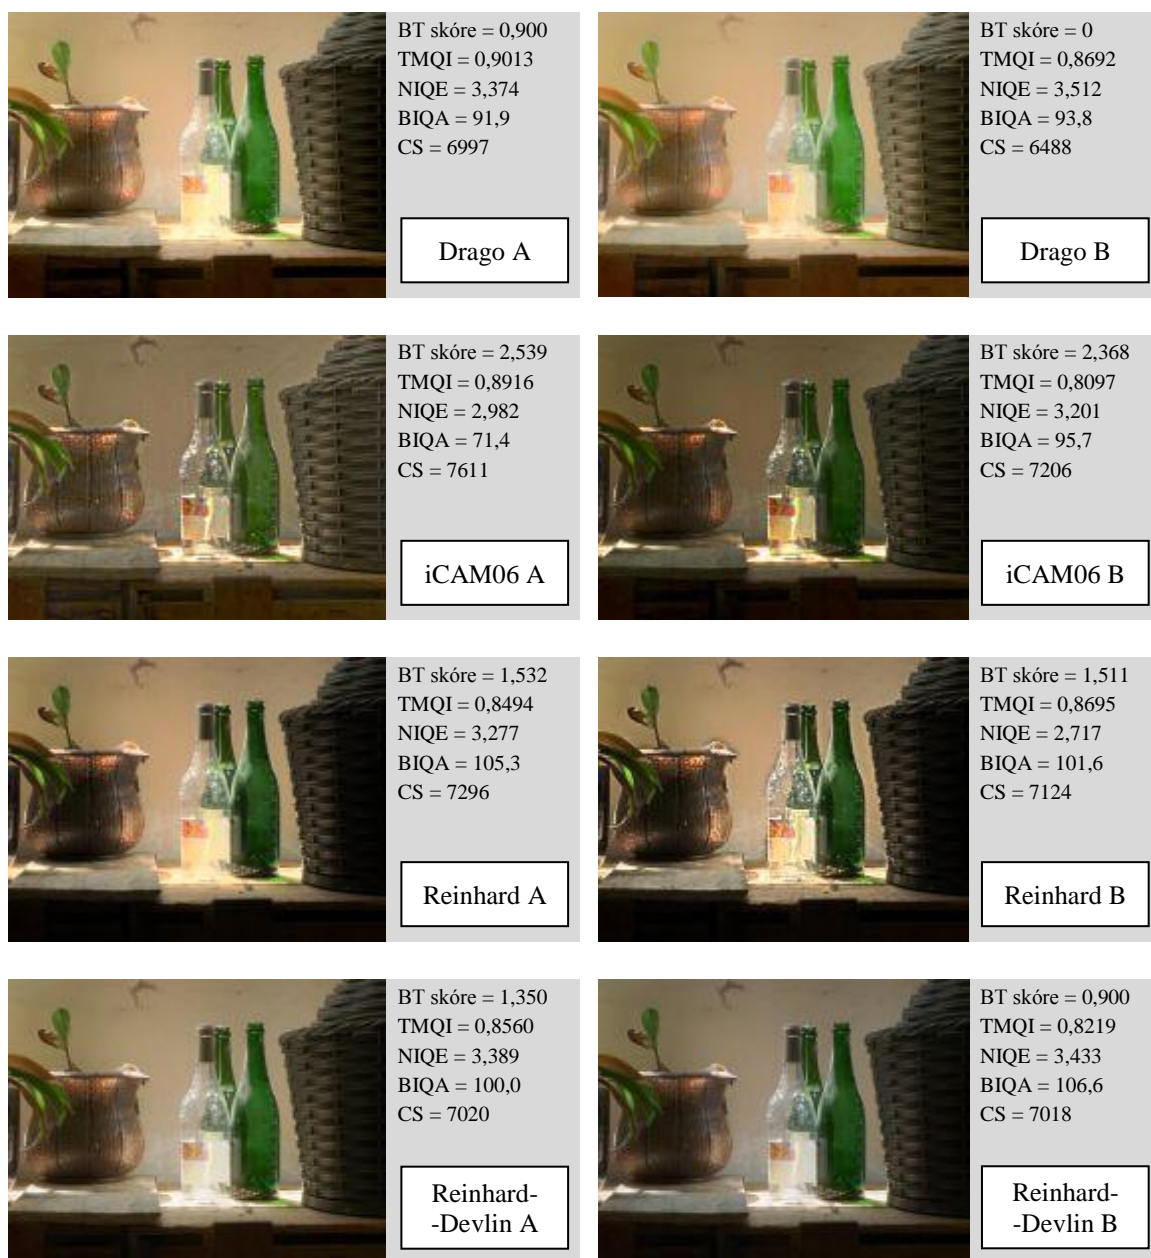
Po realizaci subjektivních testů byly prozkoumány vhodné metody objektivního hodnocení. V první řadě byly vyloučeny běžně používané plně referenční metriky.

Z existujících metod byly vybrány TMQI, NIQE, BIQA, CS a DRIM. Metoda DRIM je specifická tím, že neposkytuje jednu číselnou hodnotu, kterou by bylo možno porovnávat se subjektivními testy. Výsledkem metody DRIM byla mapa tří typů zkreslení, ze kterých lze vyčíst jistou podobnost výsledků se subjektivními testy.

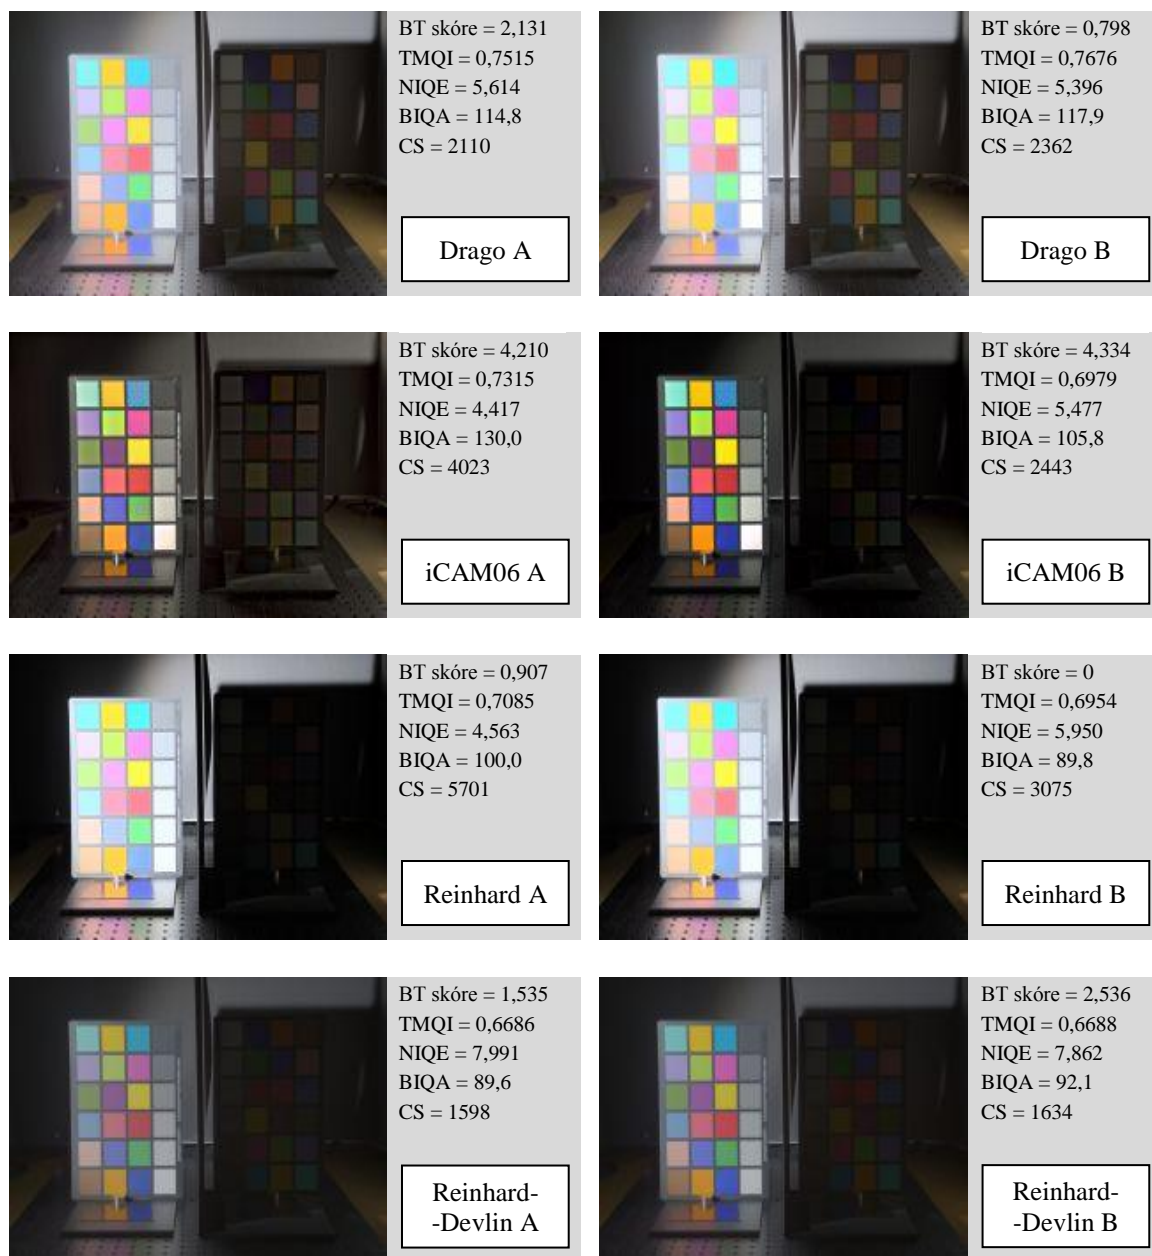
Na základě porovnání objektivních metod s metodou PC (Pair Comparison) lze konstatovat, že metody TMQI a NIQE neprojevíly s metodou PC výraznou závislost. Metoda BIQA vykazovala mírnou závislost. Jako nejspolehlivější se ukázala metoda CS, která u všech hodnocených motivů obrazů vykazovala kladnou korelaci. Přesto její průměrná korelace ukazuje, že je třeba hledat nová vhodnější kritéria pro objektivní porovnávání TMO.

## Apendix

Na následujících obrázcích jsou zobrazeny mapované obrazy pro subjektivní a objektivní testy. U každého obrazu se nachází tabulka s výsledky subjektivních testů (BT skóre) a objektivního hodnocení (TMQI, NIQE, BIQA, CS).



**Obr. 6.3.1** Subjektivní a objektivní hodnocení, motiv č. 1 [62]

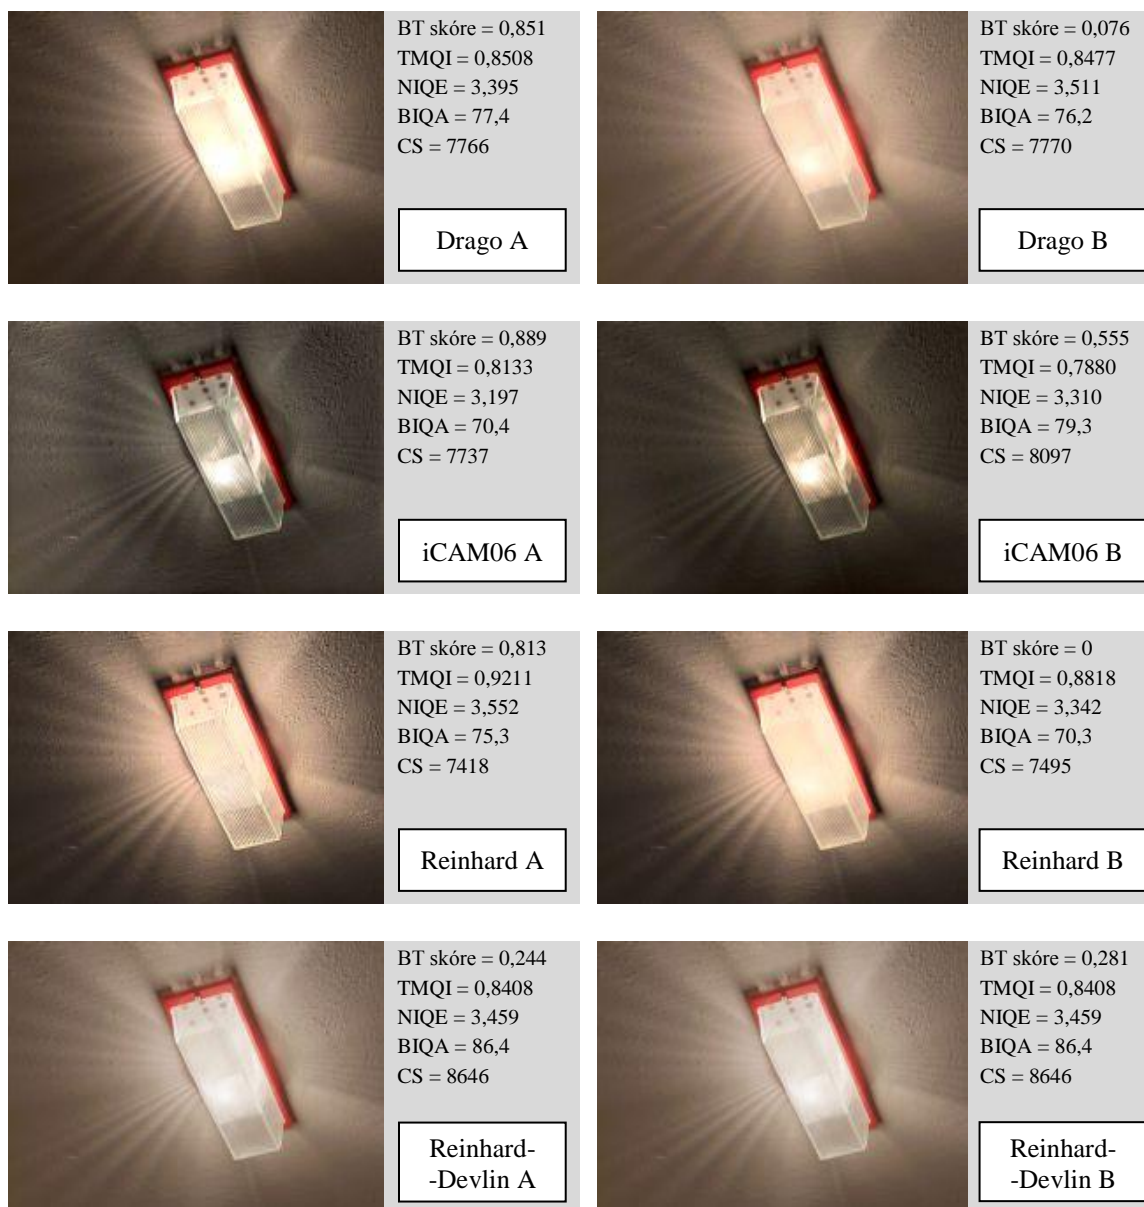


**Obr. 6.3.2** Subjektivní a objektivní hodnocení, motiv č. 2 [63]

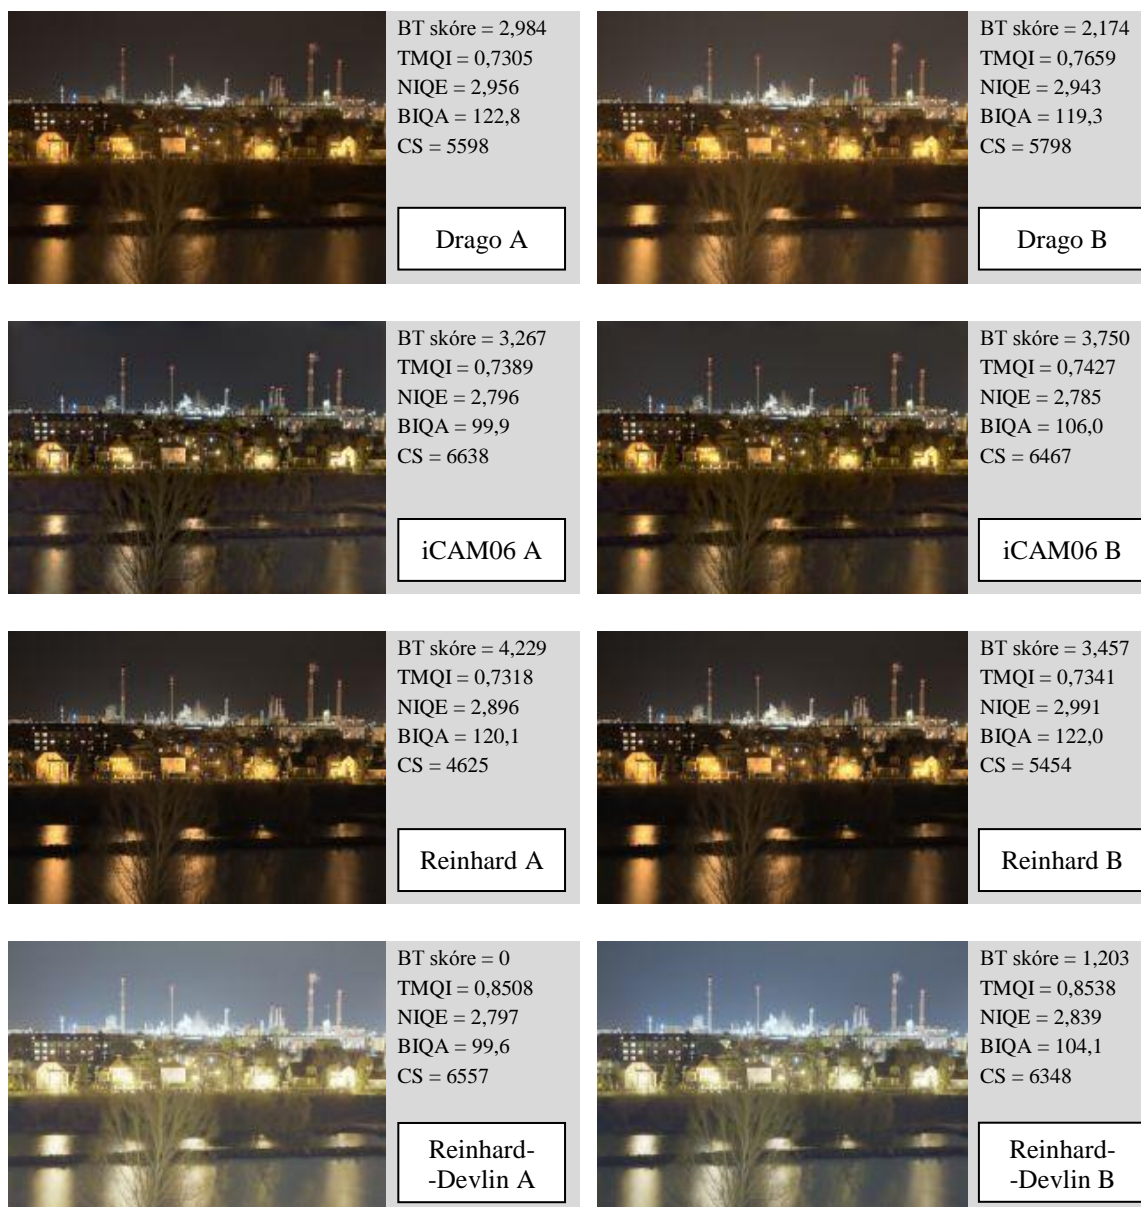




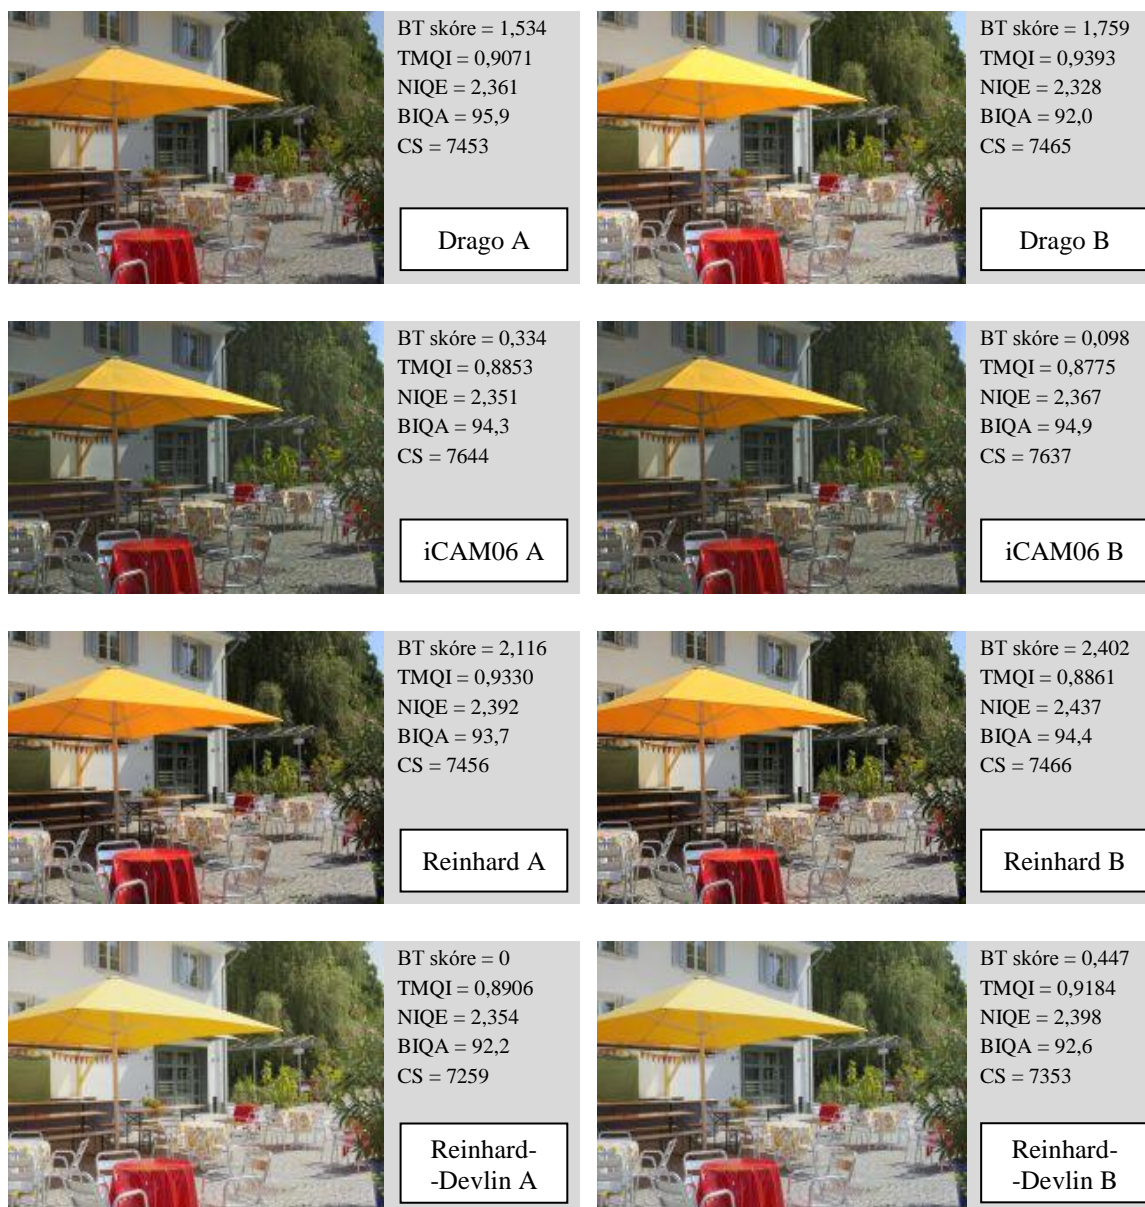
**Obr. 6.3.3** Subjektivní a objektivní hodnocení, motiv č. 3



**Obr. 6.3.4** Subjektivní a objektivní hodnocení, motiv č. 4



**Obr. 6.3.5** Subjektivní a objektivní hodnocení, motiv č. 5



**Obr. 6.3.6** Subjektivní a objektivní hodnocení, motiv č. 6 [63]

## **Obsah přiloženého DVD**

### **Text práce**

Text práce ve formátu \*.pdf

Text práce ve formátu \*.docx

### **Použité a upravené programy**

Algoritmy pro TMO

Rozhraní pro testování snímků pomocí PC

Algoritmy pro objektivní metriky

### **Obrazy pro subjektivní a objektivní hodnocení**

#### **Výsledná data**

Subjektivní metody

Objektivní metody

Porovnání metod hodnocení

## Použitá literatura

- [1] F. DRAGO, K. MYSZKOWSKI, T. ANNEN, N. CHIBA. Adaptive Logarithmic Mapping For Displaying High Contrast Scenes. *Computer Graphics Forum*, Volume 22, Number 3, 2003.
- [2] J. KUANG, G. M. JOHNSON, M. D. FAIRCHILD, iCAM06. A refined Image appearance model for HDR image rendering. *Journal of Visual Communication and Image Representation*, Volume 18, Issue 5, 2007.
- [3] E. REINHARD, M. STARK, P. SHIRLEY, J. FERWERDA. Photographic Tone Reproduction for Digital Images. *ACM Transactions on Graphics*, 267-276, 2002.
- [4] E. REINHARD, K. DEVLIN. Dynamic Range Reduction inspired by Photoreceptor Physiology. *Visualization and Computer Graphics*. IEEE Transactions on 11, 13-24, 2005.
- [5] S. WINKLER. Digital Video Quality: Vision Models and Metrics. *John Wiley and Sons*, 2008.
- [6] H. YEGANEH, Z. WANG. Objective Quality Assessment of Tone-Mapped Images. *IEEE Transactions on Image Processing*, vol. 22, no. 2, 2013.
- [7] A. MITTAL, R. SOUNDARARAJAN, A. C. BOVIK. Making a Completely Blind Image Quality Analyzer. *IEEE Signal Processing Letters*, 2012.
- [8] W. XUE, X. MOU, L. ZHANG, A. C. BOVIK, X. FENG. Blind Image Quality Assessment Using Joint Statistics of Gradient Magnitude and Laplacian Features. *IEEE Transactions on Image Processing*, vol. 23, no. 11, 2014.
- [9] Q. SANG, X. WU, CH. LI, Y. LU. Universal blind image quality assessment using contourlet transform and singular-value decomposition. *Journal of Electronic Imaging*, 23, 061104, 2014.
- [10] T. O. AYDIN, R. MANTIUK, K. MYSZKOWSKI, H. P. SEIDEL. Dynamic Range Independent Image Quality Assessment. *ACM SIGGRAPH 2008*, papers. Article No. 69, 2008.
- [11] E. REINHARD. High Dynamic Range Imaging: Acquisition, Display, and Image-Based Lightning. *Morgan Kaufmann graphics*, 502 s. ISBN 0-12-585263-0, 2006.
- [12] DIGITAL PHOTOGRAPHY TIPS AND TECHNIQUES. Digital Photography Tips and Techniques. [online]. 2007 [cit. 2015-05-03]. Dostupné z: <http://dptnt.com/2007/10/high-dynamic-range-landscape-photography/>.
- [13] DIGITAL PHOTOGRAPHY REVIEW. Digital Photography Review: Fujifilm announce SuperCCD SR [online]. [cit. 2015-04-09]. Dostupné z: <http://www.dpreview.com/articles/6851251325/fujisuperccdsr>.

- [14] ISO 14524:2009. Photography - Electronic still-picture cameras - Methods for measuring opto-electronic conversion functions (OECFs). 2009
- [15] J. TUMBLIN and H.E. RUSHMEIER. Tone Reproduction for Realistic Images. *IEEE Computer Graphics and Applications*, 13(6):42–48, 1993.
- [16] K. PERLIN, E.M. HOFFERT. Hypertexture. *Computer Graphics (Proceedings of ACM SIGGRAPH 89)*, ACM, 23, 253–262, 1989.
- [17] M. D. FAIRCHILD, G. M. JOHNSON. iCAM framework for image appearance, differences, and quality. *Journal of Electronic Imaging* 13(1), 126–138, 2004.
- [18] F. DURAND, J. DORSEY. Fast bilateral filtering for the display of highdynamic-range image, *Proceedings of ACM SIGGRAPH 2002, Computer Graphics Proceedings, Annual Conference Proceedings*, pp. 257–266, 2002.
- [19] N. MORONEY, M. D. FAIRCHILD, R. W. G. HUNT, C.J. LI, M.R. LUO, T. NEWMAN. The CIECAM02 Color Appearance Model, *IS& T/SID 10th Color Imaging Conference*, Scottsdale 23–27, 2002.
- [20] F. EBNER, M. D. FAIRCHILD. Development and testing of a color space (IPT) with improved hue uniformity, *IS& T/SID 6th Color Imaging Conference, Scottsdale*, 9–13, 1998.
- [21] L. MICHAELIS, M. L. MENTEN. Die Kinetik der Invertinwirkung, *Bochemische Zeitschrift*, 49, 1913.
- [22] J. M. VALETON, D. van NORREN. Light adaptation of primate cones: an analysis based on extracellular data, *Vision, Res.* 23,1539–1547, 1983.
- [23] R. W. G. HUNT. The reproduction of colour, 5th ed., *Fountain Press Ltd.*, 1995.
- [24] J. C. STEVENS and S. S. STEVENS. Brightness Function: Effects of Adaptation, *Journal of the Optical Society of America*, 53(3), 1963.
- [25] R. W. G. HUNT. The Reproduction of Colour. *John Wiley and Sons*, 2004.
- [26] A. ADAMS. The camera. The Ansel Adams Photography series. *Little, Brown and Company*, 1980, 1981, 1983.
- [27] E. N. MITCHELL. Photographic Science. *John Wiley and Sons*, 1984
- [28] F. J. J. BLOMMAERT, J. B. MARTENS. An object-oriented model for brightness perception. *Spatial Vision* 5, 1, 15–41. 1990.  
K. I. NAKA, W. A. H. RUSHTON. S-potentials from luminosity units in the retina of fish (cyprinidae). *J Physiol*, vol. 185, pp. 587–599, 1966.
- [29] R. A. NORMANN, I. PERLMAN. The effects of background illumination on the photoresponses of red and green cones. *J Physiol*, vol. 286, pp. 491–507, 1979.
- [30] E. REINHARD. Parameter estimation for photographic tone reproduction. *Journal of Graphics Tools*, vol. 7, no. 1, pp. 45–51, 2003.
- [31] E. REINHARD, M. STARK, P. SHIRLEY, J. FERWERDA. Photographic Tone Reproduction for Digital Images. *ACM Transactions on Graphics*, vol. 21, no. 3, pp. 267–276, 2002.

- [32] Z. WANG, A. C. BOVIK, H. R. SHEIKH E. P. SIMONCELLI. Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600–612, 2004.
- [33] Z. WANG, and A. C. BOVIK. Reduced and no-reference image quality assessment. *IEEE Signal Processing Magazine*, vol. 28, no. 6, pp. 29–40, 2011.
- [34] W. J. CROZIER. On the Variability of Critical Illumination for Flicker Fusion and Intensity Discrimination. *J. Physiol.*, vol. 19, no. 3, pp. 503–522, 1935
- [35] P. G. J. BARTEN. Contrast Sensitivity of The Human Eye and Its Effects on Image Quality. DC: SPIE, 1999.
- [36] J. L. MANNOS, D. J. SAKRISON. The Effects of a Visual Fidelity Critereon on the Encoding of Images. *IEEE Transactions on Information Theory*, vol. 20, no. 4, pp. 525-536, 1974.
- [37] Z. WANG, E. P. SIMONCELLI, A. C. BOVIK. Multi-scale structural similarity for image quality assessment. *IEEE Asilomar Conference on Signals, Systems and Computers*, CA, pp. 1398–1402, 2003.
- [38] Z. WANG and Q. LI. Information Content Weighting for Perceptual Image Quality Assessment. *IEEE Transactions on Image Processing*, vol. 20, no. 5, pp. 1185–1198, 2011.
- [39] COMPUTER VISION TEST IMAGES. (2005) [Online]. Available: <http://www-2.cs.cmu.edu/afs/cs/project/cil/www/v-images.html>.
- [40] UCID - Uncompressed Colour Image Database. (2004) [Online]. Dostupné z: <http://www-staff.lboro.ac.uk/~cogs/datasets/UCID/ucid.html>.
- [41] A. MITTAL, A. K. MOORTHY, A. C. BOVIK. No-Reference Image Quality Assessment in the Spatial Domain. *IEEE Transactions on Image Processing*, vol. 21, no. 12, 4695-4707, 2012.
- [42] D. L. RUDERMAN. The Statistics of Natural Images. *Network Computation in Neural Systems*, 5(4):517 – 548, 1994.
- [43] T. GOODALL, A. C. BOVIK. No-Reference Task Performance Prediction on Distorted Images. *Image Analysis and Interpretation (SSIAI)*, 89-92, 2014.
- [44] N. E. LASMAR, Y. STITOU and Y. BERTHOUMIEU. Multiscale skewed heavy tailed model for texture analysis. *IEEE Transactions on Image Processing*, pp. 2281–2284, 2009.
- [45] K. SHARIFI, A. LEON-GARCIA. Estimation of Shape Parameter for Generalized Gaussian Distributions in Subband Decompositions of Video. *IEEE Transactions on Circuits and Systems for Video Technology*, 5(1):52-56, 1995.
- [46] N. E. LASMAR, Y. STITOU and Y. BERTHOUMIEU. Multiscale skewed heavy tailed model for texture analysis. *International Conference on Image Processing*, pp. 2281-2284, 2009.
- [47] M. SONKA, V. HLAVÁČ, R. BOYLE. Image Processing, Analysis, and Machine Vision. *Hardcover*. 1998.



- [48] H. R. SHEIKH, Z. WANG, L. CORMACK, A. C. BOVIK. Live Image Quality Assessment Database Release 2. [Online]. Dostupné z: <http://live.ece.utexas.edu/research/quality>.
- [49] E. C. LARSON, D. M. CHANDLER. Most apparent distortion: Full-reference image quality assessment and the role of strategy. *Journal of Electronic Imaging*, 19(1), 011006, 2010.
- [50] N. PONOMARENKO, V. LUKIN, A. ZELENSKY, K. EGIAZARIAN, J. ASTOLA, M. CARLI, F. BATTISTI. TID2008 – A Database for Evaluation of Full-Reference Visual Quality Assessment Metrics. *Advances of Modern Radio Electronics*, vol. 10, pp. 30-45, 2009.
- [51] A. SMOLA, B. SCHOLKOPF. A tutorial on support vector regression. *Statistics and Computing*, 14(3):199–222, 2004.
- [52] A. SHNAYDERMAN, A. GUSEV, A. ESKICIOGLU. SVD-based grayscale image quality measure for local and global assessment. *IEEE Transactions on Image Processing*, 15(2), 422–429, 2006.
- [53] A. SHNAYDERMAN, A. GUSEV, A. ESKICIOGLU. A multidimensional image quality measure using singular value decomposition, *Proc. SPIE 5294*, 82–92, 2003.
- [54] M. N. DO and M. VETTERLI. The contourlet transform: an efficient directional multiresolution image representation. *IEEE Transactions on Image Processing*, 14(12), 2091–2106, 2005.
- [55] P. J. BURT and E. H. ADELSON. The Laplacian pyramid as a Compaq image code. *IEEE Transactions on Communications*, 31(4), 532–540, 1983.
- [56] R. H. BAMBERGER and M. J. T. SMITH. A filter bank for the directional decomposition of images: theory and design. *IEEE Transactions on Signal Processing*, 40(4), 882–893, 1992.
- [57] R. MANTIUK, S. DALY, K. MYZKOWSKI, H. P. SEIDEL. Predicting Visible Differences in High Dynamic Range Images - Model and its Calibration. *Human Vision and Electronic Imaging X*, vol. 5666 of SPIE Proceedings Series, 204–214, 2005.
- [58] A. WATSON. The Cortex Transform: Rapid Computation of Simulated Neural Images. *Computer Vision Graphics and Image Processing*, 39, 311–327, 1987.
- [59] S. DALY. The Visible Differences Predictor: An Algorithm for the Assessment of Image Fidelity In Digital Images and Human Vision, *MIT Press, A. B. Watson*, Ed., 179–206, 1993.
- [60] S. ZDVIHAL. Diplomová práce – Metodika subjektivního hodnocení obrazu. 2014.
- [61] R. A. BRADLEY, M. TERRY. Rank analysis of incomplete block designs: The method of paired comparisons. *Biometrick*, 39(3/4):324 – 345, 1952.

- [62] F. BANTERLE, A. ARTUSI, K. DEBATTISTA, A. CHALMERS. Advanced High Dynamic Range Imaging: *Theory and Practice*, 2011.
- [63] K. SIMON, P. ZLLIKER, I. SPROW. EMPA Media Technology: HDR Database [online]. [cit. 2015-05-09]. Dostupné z: <http://empamedia.ethz.ch/hdrdatabase/index.php>.
- [64] L. KRASULA, K. FLIEGEL, P. Le CALLET AND M. KLÍMA. Using Full-Reference Image Quality Metrics for Automatic Image Sharpening. *In: Optics, Photonics, and Digital Technologies for Multimedia Applications III*, 913807 DOI: 10.1117/12.2052275. 2014.

## Seznam obrázků

Obr. 2.1.1 Scéna vyfotografovaná s přechodovým filtrem a bez něj [4] .....	2
Obr. 2.2.1 Super CCD [2].....	3
Obr. 2.4.1 Vícenásobná expozice jedné scény .....	3
Obr. 2.4.2 HDR snímek, příklad rozmazání kouře v oblasti komínu .....	4
Obr. 2.4.3 Sekvence snímků pro měření převodní charakteristiky .....	5
Obr. 2.4.4 Převodní charakteristika fotoaparátu Nikon D70 pro kanály R, G a B .....	5
Obr. 3.1.1 Vliv funkce $\log_2$ a $\log_{10}$ .....	7
Obr. 3.1.2 Vliv parametru $b$ : a) $b = 0,65$ , b) $b = 0,75$ , c) $b = 0,85$ .....	8
Obr. 3.1.3 Parametr $b$ nastavuje sklon funkce <i>bias</i> .....	8
Obr. 3.2.1 Model metody iCAM06 .....	10
Obr. 3.2.2 Mapovaný obraz metodou iCAM06 .....	15
Obr. 3.3.1 Zónový systém .....	16
Obr. 3.3.2 Vliv klíčové hodnoty pro různé tonality obrazu: a) tmavá, b) střední (šedá), c) světlá, d) světlejší .....	17
Obr. 3.3.3 Kontrola vysokých jasů. Na obrázku vpravo je lépe vidět struktura krytu .....	18
Obr. 3.3.4 Aplikace funkce zesvětlení a ztmavení .....	18
Obr. 3.3.5 Parametr $s$ ovlivňuje okolí s prudkými přechody. Efekt je patrný na levém obrázku kolem světla lampy .....	19
Obr. 3.4.1 Tvar převodní charakteristiky v závislosti na parametru $m$ .....	21
Obr. 3.4.2 Parametr $m$ ovlivňuje kontrast .....	21
Obr. 3.4.3 Parametr $f'$ ovlivňuje intenzitu .....	22
Obr. 3.4.4 Světelná adaptace, závislost na parametru $a$ .....	22
Obr. 4.1.1 Schéma metody DSCQS a stupnice hodnocení .....	24
Obr. 4.1.2 Schéma metody DSIS a hodnocení .....	25
Obr. 4.1.3 Schéma metody ACR .....	26
Obr. 5.1.1 Schéma přechodu na nižší měřítka .....	30
Obr. 5.1.2 Mapy jednotlivých stupňů strukturální similarity .....	31
Obr. 5.1.3 Histogramy – a) Gaussova křivka, b) Beta křivka .....	32
Obr. 5.2.1 a) MSCN koeficienty, b) párové koeficienty .....	33
Obr. 5.3.1 Marginální distribuce GM a LOG příznaků před a po normalizaci JAN .....	37
Obr. 5.3.2 Distribuční funkce nezávislosti mezi normalizovanými GM a LOG příznaky, a) světlo, b) lampička .....	39
Obr. 5.4.1 Schéma obrysové transformace .....	40
Obr. 5.4.2 Rozložení obrazu pomocí DFB .....	41
Obr. 5.4.3 SVD křivky obrazů s různým zkreslením .....	41
Obr. 5.5.1 Klasifikace zkreslení dle změny kontrastu mezi původním (modře) a mapovaným obrazem (fialově) .....	43
Obr. 5.5.2 Schéma metody DRIM .....	43
Obr. 5.5.3 Mapy tří kategorií zkreslení: zelená – ztracený kontrast, modrá – zesílený kontrast, červená – inverzní kontrast .....	45
Obr. 6.1.1 Testované motivy – a) láhve [64], b) tabulky [65], c) lampička, d) světlo .....	46
Obr. 6.1.2 Testované motivy – e) město, f) café [65] .....	47
Obr. 6.1.3 Statistické výsledky a statistická významnost .....	48
Obr. 6.1.4 Statistické výsledky a statistická významnost .....	49
Obr. 6.2.1 Výsledky hodnocení TMQI .....	51
Obr. 6.2.2 Výsledky hodnocení NIQE .....	52
Obr. 6.2.3 Výsledky hodnocení BIQA .....	53
Obr. 6.2.4 Výsledky hodnocení CS .....	54
Obr. 6.2.5 Hodnocení DRIM, motiv č. 1 .....	55
Obr. 6.2.6 Hodnocení DRIM, motiv č. 2 .....	55
Obr. 6.2.7 Hodnocení DRIM, motiv č. 3 .....	55
Obr. 6.2.8 Hodnocení DRIM, motiv č. 4 .....	56
Obr. 6.2.9 Hodnocení DRIM, motiv č. 5 .....	56

Obr. 6.2.10 Hodnocení DRIM, motiv č. 6 .....	56
Obr. 6.3.1 Ověření účinnosti TMQI .....	58
Obr. 6.3.2 Ověření účinnosti NIQE .....	58
Obr. 6.3.3 Ověření účinnosti BIQA .....	59
Obr. 6.3.4 Ověření účinnosti CS .....	59
Obr. 6.3.1 Subjektivní a objektivní hodnocení, motiv č. 1 [64] .....	61
Obr. 6.3.2 Subjektivní a objektivní hodnocení, motiv č. 2 [65] .....	62
Obr. 6.3.3 Subjektivní a objektivní hodnocení, motiv č. 3 .....	63
Obr. 6.3.4 Subjektivní a objektivní hodnocení, motiv č. 4 .....	64
Obr. 6.3.5 Subjektivní a objektivní hodnocení, motiv č. 5 .....	65
Obr. 6.3.6 Subjektivní a objektivní hodnocení, motiv č. 6 [65] .....	66

## Seznam tabulek

Tab. 4.1.1 Typy vyhodnocování metody SC .....	26
Tab. 5.2.1 Příznaky pro jeden stupeň .....	35
Tab. 6.1.1 Souhrn výsledků pozorování TMO .....	59