

České vysoké učení technické v Praze
Fakulta elektrotechnická

Katedra Radioelektroniky
Obor: Audiovizuální technika a zpracování signálů



Identifikace kamery z parametrů snímku

Single Image Camera Identification from Image Parameters

DIPLOMOVÁ PRÁCE

Vypracoval: Bc. Radomír Švihel
Vedoucí práce: prof. Mgr. Petr Páta, Ph.D.
Rok: 2019

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Švihel** Jméno: **Radomír** Osobní číslo: **406069**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra radioelektroniky**
Studijní program: **Elektronika a komunikace**
Studijní obor: **Audiovizuální technika a zpracování signálů**

II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

Identifikace kamery z parametrů snímku

Název diplomové práce anglicky:

Single Image Camera Identification from Image Parameters

Pokyny pro vypracování:

Seznamte se s metodami identifikace kamery na základě vyhodnocení snímků pořízených tímto přístrojem. Zaměřte se především na přístupy využívající analýzu parametrů snímače kamery. Podejte přehled těchto metod. Vytvořte sadu testovacích snímků. Po dohodě s vedoucím práce vybrané metody realizujte a na vybrané sadě testovacích snímků proveďte jejich srovnání.

Seznam doporučené literatury:

- [1] Ambuj Mehrish, A. V. Subramanyam, Sabu Emmanuel, 'Sensor Pattern Noise Estimation Using Probabilistically Estimated RAW Values', Signal Processing Letters IEEE, vol. 23, pp. 693-697, 2016, ISSN 1070-9908.
- [2] Lukas J., Fridrich J., Goljan M., Digital Camera Identification from Sensor Noise, IEEE Transactions on Information Forensics and Security, vol. 1(2), 2006.
- [3] Arash Rashidi, Farbod Razzazi, 'Single image camera identification using l-vectors', Computer and Knowledge Engineering (ICCKE) 2017 7th International Conference on, pp. 406-410, 2017.

Jméno a pracoviště vedoucí(ho) diplomové práce:

prof. Mgr. Petr Páta, Ph.D., katedra radioelektroniky FEL

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) diplomové práce:

Datum zadání diplomové práce: **09.02.2018**

Termín odevzdání diplomové práce: **24.05.2019**

Platnost zadání diplomové práce: **30.09.2019**

prof. Mgr. Petr Páta, Ph.D.
podpis vedoucí(ho) práce

prof. Mgr. Petr Páta, Ph.D.
podpis vedoucí(ho) ústavu/katedry

prof. Ing. Pavel Ripka, CSc.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Diplomant bere na vědomí, že je povinen vypracovat diplomovou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v diplomové práci.

Datum převzetí zadání

Podpis studenta

Prohlášení

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

V Praze dne

.....
Bc. Radomír Švihel

Poděkování

Mé poděkování patří panu prof. Mgr. Petru Pátovi, Ph.D. za odborné vedení, ochotu a trpělivost, kterou mi v průběhu zpracování diplomové práce věnoval. Nemale poděkování patří také rodině, která neztrácela naději, že jednou sepišu tyto řádky. V neposlední řadě děkuji také Viole Vopalecké, Tereze Rybářové, Ireně Vanišové, Simoně Flossmannové, Romaně Černovské a Pavlu Štastnému za poskytnutí fotek a podporu.

Bc. Radomír Švihel

Název práce:

Identifikace kamery z parametrů snímku

Autor: Bc. Radomír Švihel

Studijní program: Elektronika a komunikace

Obor: Audiovizuální technika a zpracování signálů

Druh práce: Diplomová práce

Vedoucí práce: prof. Mgr. Petr Páta, Ph.D.

Katedra Radioelektroniky, Fakulta elektrotechnická, České vysoké učení technické v Praze

Konzultant: –

Abstrakt: Se stále větší popularitou digitálních fotoaparátů, snadným, dostupným a uživatelsky přívětivým užíváním programů a aplikací na úpravu snímku, roste také kvalita snímku a rychlost mezi jeho pořízením a publikováním ať už na sociální síti, v časopise, webových stránkách, jako osobní prezentace nebo také v komerční sféře. S tím může být spojeno i riziko neprávoplatného přivlastnění snímku. V takových případech mohou být výsledky z metod pro identifikaci kamery z parametrů snímku průkazným materiálem vlastnictví daného snímku. Práce se zaměřuje jednak na podání základního přehledu přístupů k identifikaci fotoaparátu a metod, které vznikly v posledních deseti letech. Dále se podrobněji zaměřuje na porovnání přesnosti vybraných metod a jejich testování na databázi pořízených fotek z fotoaparátů rozdílných značek a modelů.

Klíčová slova: Identifikace, kamera, šum, senzor, vzor

Title:

Single Image Camera Identification from Image Parameters

Author: Bc. Radomír Švihel

Abstract: As the popularity of the digital camera grows thanks to easy, affordable and user-friendly image editing programs and applications, image quality and speed between acquisition and publishing the image grow also. It doesn't matter whether is the image published on a social networking site, in a magazine, on a website, as a personal presentation, or in a commercial environment, everywhere is the possible risk of improper appropriation of the image. In such cases, the results from the camera identification methods according to the image parameters might be the evidence of ownership of the image. The thesis focuses on providing a basic overview of approaches to camera identification and methods that have emerged over the past decade. Furthermore, it focuses in more detail on the comparison of the accuracy of selected methods and their testing on a database of photos taken from cameras of different brands and models

Key words: Identification, camera, noise, sensor, pattern

Obsah

Úvod	11
1 Přehled metod	13
1.1 Metody pracující se vzorem sensorového šumu	13
1.1.1 Pairwise Magnitude Relations of Clustered Sensor Pattern Noise	13
1.1.2 Patch-Based Sensor Pattern Noise for Camera Source Identification	15
1.1.3 Source Camera Identification from Significant Noise Residual Region	16
1.2 Metody založené na neuronových sítích	18
1.2.1 Camera Model Identification With The Use of Deep Convolutional Neural Networks	18
1.3 Metody založené na Wavelet a Curvelet transformaci	20
1.3.1 Digital Camera Identification Based on Curvelet Transform . .	20
1.3.2 Source Camera Identification Forencics Based on Wavelet Features	21
1.4 Metody využívající automatického vyvažování bílé barvy	23
1.4.1 Source Camera Identification Usins Auto-White Balance Approximation	23
1.5 Metody založené na barevném filtru	25
1.5.1 An Improved Algorithm for Camera Model Identification Using Interchannel Demosaicking Traces	25
1.5.2 Using Improved Imaging Sensor Pattern Noise for Source Camera Identification	26
1.6 Ostatní metody	28
1.6.1 Camera Brand and Model Identification Using Moments of 1-D and 2-D Characteristic Functions	28
2 Vybrané metody	31
2.1 Databáze fotek	31
2.2 Získání zbytkového šumu	32
2.3 Metoda 1 - Patch-Based Sensor Pattern Noise for Camera Source Identification	33
2.3.1 Implementace metody v Matlabu	33
2.4 Metoda 2 - Pairwise Magnitude Relations of Clustered Sensor Pattern Noise	34
2.4.1 Implementace v Matlabu	35

2.5	Metoda 3 - Digital Camera Identification Based on Curvelet Transform	35
2.5.1	Implementace v Matlabu	36
2.6	Korelace a algoritmus pro vyhodnocení	36
3	Vyhodnocení	37
3.1	Algoritmy pro získání zbytkového šumu	37
3.2	Metoda 1	37
3.3	Metoda 2	39
	Závěr	41
	Literatura	42
	Přílohy	45
	A Algoritmy	45
	B Databáze fotek	47

Úvod

Při každém cvaknutí spouště fotoaparátu jsou v pořízené digitální fotografii také obsaženy jedinečné vlastnosti fotoaparátu, kterým je snímek pořizován. Na základě takovýchto vlastností, „vtisknutých“ do fotografie, lze z fotografie zpětně určit fotoaparát, kterým byla vyfocena.

Na základě vlastností, které jednotlivé metody používají k identifikaci fotoaparátu, lze podat jejich přehled. Nejvíce využívanou vlastností je vzor sensorového šumu, který je svým způsobem jedinečný pro každý čip, kterým jsou pořizovány snímky. Tento šum musí také bezpochyby vyprodukovat každý digitální fotoaparát od zrcadlovky po mobilní telefon (s foťákem). Jiné metody využívají například automatického vyvažování bílé v postprocesu zpracování snímku, algoritmy při interpolaci barev z Bayerovy masky nebo vlastnosti, které lze získat v doménách Wavelet nebo Curvelet transformace.

Metod k identifikaci digitálního fotoaparátu z parametrů snímku vzniklo za dobu existence digitální fotografie bezpočet. V následující kapitole uvádím výčet několika z nich, které jsou mladších deseti let, a které jsou co nejvíce různorodé v přístupu k jednotlivým vlastnostem.

Tři vybrané metody jsem se rozhodl reprodukovat a otestovat na vytvořené databázi fotografií.

Kapitola 1

Přehled metod

1.1 Metody pracující se vzorem sensorového šumu

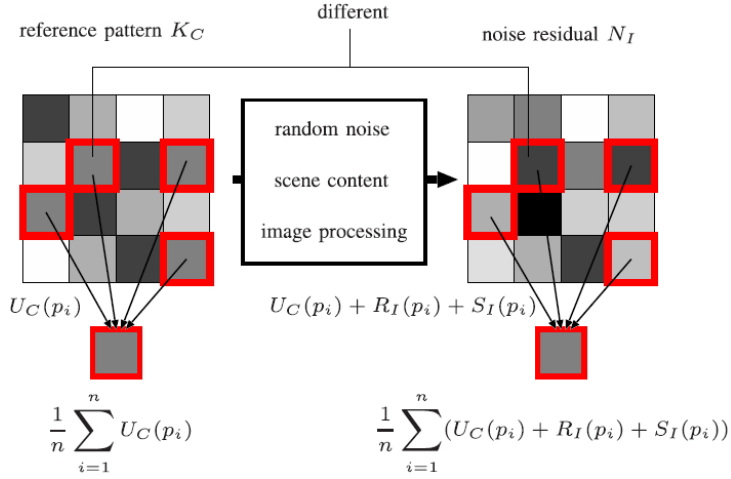
Každý snímek pořízený digitální kamerou obsahuje šum, který je generovaný jejím snímačem. Tento generovaný šum obsahuje za prvé složku šumu, který má náhodné rozložení na každém pořízeném snímku, a který nám k identifikaci kamery nikterak nepomůže. Za druhé, každý snímek obsahuje také šum, který nazýváme photo-response nonuniformity noise (PRNU). Tento šum je generovaný rozdílnou citlivostí jednotlivých pixelů snímače na světlo a má deterministické složky, které jsou vždy přibližně stejně rozložené v každém pořízeném snímku z jedné kamery. Zároveň je unikátní pro kamery odlišné i stejné značky a také pro rozdílné kamery stejné značky a modelu.

Právě tento PRNU šum se využívá v metodách identifikace kamery založených na vzoru sensorového šumu (sensor pattern noise). [13]

1.1.1 Pairwise Magnitude Relations of Clustered Sensor Pattern Noise

Metoda identifikace kamery založená na párové identifikaci pixelových klastrů slibuje velkou odolnost vůči kontaminaci snímku šumem. Pixely jsou klastrovány podle hodnoty PRNU testovací kamery. Vytváření párových klastrů spárováním klastru s negativní hodnotou PRNU šumu a klastru s pozitivní hodnotou PRNU šumu. Vzhledem k rozložení PRNU šumu snímače kamery se předpokládá, že pravděpodobnost výskytu stejného identického páru klastru je vyšší u stejného typu kamery než u různých typů.

Koncept klastrového PRNU šumu je zobrazen na obrázku 1.1. Referenční vzor K_C kamery C je generován průměrováním zbytkového šumu U_C získaného z několika flat-field snímků, ve kterých není zobrazená žádná scéna. Zbytkový šum N_I vstupního snímku I kamery C získáme použitím odšumovacího filtru F , proces můžeme zapsat



Obrázek 1.1: Koncept pixelových klustrů [13]

následovně $N_I = I - F(I)$.

Pokud c_k označíme jako klastř složený z pixelů p_1, p_2, \dots, p_n kamery C , které mají podobnou hodnotu PRNU, lze označit $\tilde{U}_c(c_k)$ jako průměrnou hodnotu PRNU šumu jednotlivých pixelů $U_c(p_i)$ v klastř c_k .

$$\tilde{U}_c(c_k) = \frac{1}{n} \sum_{k=1}^n U_c(p_i)$$

Naproti tomu, $\tilde{N}_I(c_k)$ lze označit jako průměrnou hodnotu zbytkového šumu N_I v klastř c_k . Zbytkový šum kromě PRNU šumu obsahuje ještě náhodný šum R_I obrázku I a kontaminaci šumem S_I , což je například vyfocená scéna, efekty nebo procesy při zpracování obrázku.

$$\tilde{N}_I(c_k) = \frac{1}{n} \sum_{k=1}^n U_c(p_i) + \frac{1}{n} \sum_{k=1}^n R_I(p_i) + \frac{1}{n} \sum_{k=1}^n S_I(p_i)$$

Zde se předpokládá nulové střední rozložení u zbytkového šumu $R_I(p_i)$. Tudíž s rostoucí velikostí klastř jde hodnota k nule a lze ji zanedbat. Třetí hodnota S_I je průměrná hodnota kontaminace šumem a měla by být malá. Ačkoliv $\tilde{N}_I(c_k)$ obsahuje malou chybu právě z hodnoty kontaminace šumem, téměř konverguje k hodnotě PRNU šumu $\tilde{U}_c(c_k) + \delta$, kde δ je chyba vzniklá právě z hodnoty kontaminace šumem S_I .

Hodnoty klastrového PRNU šumu $\tilde{U}_c(c_k)$ a klastrového zbytkového šumu $\tilde{N}_I(c_k)$ jsou vůči sobě porovnávány. V případě snímků pořízených z jednoho zařízení měly být stejné nebo velmi podobné. [13]

1.1.2 Patch-Based Sensor Pattern Noise for Camera Source Identification

Vzor sensorového šumu po extrakci ze snímku téměř vždy obsahuje zbytky z vyfocené scény, které mohou výrazně ovlivnit přesnost identifikace kamery. Řešení toho problému slibuje algoritmus metody Patch-Based Sensor Pattern Noise (PB-SPN). Metoda využívá rozdíl mezi sousedními pixely, které mohou přibližně reflektovat složitost textury na fotce. Pokud $\mathbf{I}_{i,j}$ je hodnotu pixelu (i,j) v obrázku I a $\mathbf{I}_{i,j+1}$ nebo $\mathbf{I}_{i+1,j}$ jsou hodnoty horizontálního nebo vertikálního sousedního pixelu od pixelu $\mathbf{I}_{i,j}$. Pak lze horizontální a vertikální rozdíly definovat jako

$$x = \mathbf{I}_n - \mathbf{I}_{n+1}$$

Tyto rozdíly v hodnotách sousedních pixelů mohou být modelovány obecnou Gaussovou distribucí danou

$$\mathbf{p}_{\alpha,\beta}(x) = \frac{\beta}{2\alpha\Gamma(1/\beta)} \exp\left(-\left(\frac{|x|}{\alpha}\right)^2\right),$$

$$\alpha = \sigma \sqrt{\frac{\Gamma(1/\beta)}{\Gamma(3/\beta)}}, \sigma > 0,$$

kde Γ je gama funkce, σ^2 odchylka, α zvětšení a β představuje změnu tvaru.

Parametr β můžeme definovat jako parametr složitosti a označit jej β_h a β_v jako složitost pro horizontální a vertikální posun. Dále pak β_{hv} jako jejich aritmetický průměr.

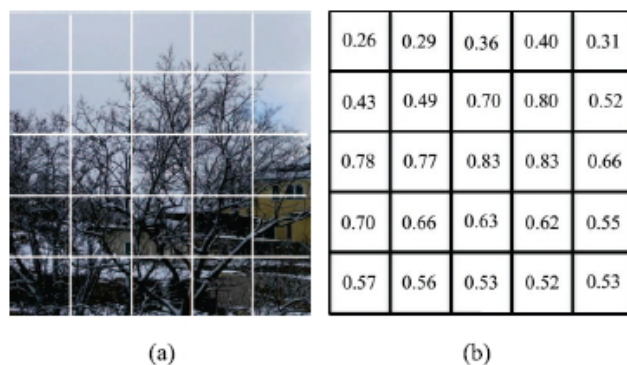
$$\beta_{hv} = \frac{\beta_h + \beta_v}{2}.$$

Parametr β_{hv} reflektuje hodnotu složitosti textury v každé části obrazu, jak je ukázáno na obrázku 1.2. Pokud je v některé části obrázku textura hladká, například modrá obloha, je hodnota parametru β menší a v částech se složitější texturou je β větší.

Za předpokladu, že máme n obrázků $\mathbf{I}_i (i = 1, 2, \dots, n)$ pořízených kamerou c , je nejprve každý obrázek rozdělen na několik částí velkých 128x128 pixelů a poté je pro každou část vypočítán parametr složitosti textury β . Dále jsou části se stejnou lokací na jednotlivých snímcích vzestupně seřazeny podle hodnoty β . Pro výpočet referenční hodnoty PB-SPN je použito 50% částí s minimální hodnotou β .

Referenční hodnoty SPN jsou počítány dvěma algoritmy. První z nich můžeme nazvat jako základní SPN, které je počítáno ze vztahu

$$K = \frac{\sum_{i=1}^N \mathbf{r}_i}{N},$$



Obrázek 1.2: a) Originální obrázek. b) Složitost textury v jednotlivých částech obrázku. [16]

kde N počet snímků použitých k získání SPN a \mathbf{r}_i je zbytkový šum získaný jako $\mathbf{r}_i = \mathbf{I}_i - F(\mathbf{I}_i)$, kde \mathbf{I}_i je originální obrázek a $F(\mathbf{I}_i)$ je obrázek získaný pomocí de-noising filtru založeného na vlnkové transformaci.

Druhý algoritmus pro získání referenční hodnoty SPN je založený na technice zvané Maximum Likelihood Estimator (MLE) a počítán ze vztahu

$$K = \frac{\sum_{i=1}^N \mathbf{r}_i \mathbf{I}_i}{\sum_{i=1}^N (\mathbf{I}_i)^2}.$$

Jednotlivé části lokálních SPN jsou pak kombinovány k získání celkového referenčního SPN, základního SPN a MLE SPN.

Testovací obrázek je nejprve rozdělen na jednotlivé části, pro které je opět jednotlivě vypočítaná hodnota složitosti textury β . Části s nejmenší hodnotou β jsou vybrány k získání zbytkového šumu. Na konci je porovnávána korelace mezi SPN z vybrané části testovacího obrázku a hodnotou referenční SPN odpovídajícího regionu. [16]

1.1.3 Source Camera Identification from Significant Noise Residual Region

Základní myšlenkou algoritmu je vzít z obrázku významné oblasti se zbytkovým šumem a použít je jako zdroj detekce. A zároveň vytřídit ty oblasti, které jsou výrazně kontaminovány nepotřebným šumem. Kvalita potřebného PRNU šumu k identifikaci kamery je ovlivněna scénou zachycenou na obrázku, jelikož ve velmi satureovaných oblastech může být signál PRNU slabý. K tomu se používá měření odstupů signál-šum (SNR).

Signál zbytkového šumu \mathbf{W} je rozdělen na M nepřekrývajících se a stejně velkých bloků. Pixely v rámci i -tého bloku mají předpoklad mít stejnou hodnotu tzv. shaping faktoru \mathbf{T}_i a také stejnou úroveň komplexního šumu Ξ_i , který je modelován jako střední hodnota Gussovského šumu s variací σ_i^2 . SNR i -tého bloku je

$$SNR_i = \frac{\|\mathbf{T}_i(\hat{\mathbf{I}\mathbf{K}})_i\|^2}{\|\Xi_i\|^2} = \frac{\|\mathbf{T}_i(\hat{\mathbf{I}\mathbf{K}})_i\|^2}{n\sigma_i^2},$$

kde $(\hat{\mathbf{I}\mathbf{K}})_i$ indikuje korespondující hodnoty i -tého bloku a n je počet pixelů v bloku.

K odhadnutí \mathbf{T}_i a σ_i^2 z pozorovaného signálu \mathbf{W} a $\hat{\mathbf{I}\mathbf{K}}$ je počítán koeficient korelace mezi \mathbf{W}_i a $(\hat{\mathbf{I}\mathbf{K}})_i$ následovně

$$\sigma_i = \frac{(\hat{\mathbf{I}\mathbf{K}})_i \odot \mathbf{W}_i}{\|(\hat{\mathbf{I}\mathbf{K}})_i\| \|\mathbf{W}_i\|},$$

kde \odot označuje elementární násobení.

Jelikož není praktické stanovit jednu absolutní prahovou hodnotu pro hodnoty SNR, využívá se alternativy, která třídí hodnoty SNR všech bloků a bere v úvahu určitou část těch největších hodnot. Pokud označíme S jakou soubor indexů získaných z významných regionů, může být stanoven následující detektor

$$\sigma = \frac{\sum_{i \in S} \mathbf{T}_i \left((\hat{\mathbf{I}\mathbf{K}})_i \odot \mathbf{W}_i \right) / \sigma_i^2}{\sqrt{\sum_{i \in S} \mathbf{T}_i^2 \|(\hat{\mathbf{I}\mathbf{K}})_i\|^2 / \sigma_i^2} \sqrt{\sum_{i \in S} \|\mathbf{W}_i\|^2 / \sigma_i^2}}.$$


Celkově pro daný obrázek \mathbf{I} pořízený kamerou C je nejprve odhadnutý faktor $\hat{\mathbf{K}}$ kamery. Poté vypočítaný zbytkový šum \mathbf{W} obrázku \mathbf{I} , následně vypočítaná hodnota SNR pro každý blok \mathbf{W} a jsou vybrány části bloků s největší hodnotou SNR. Dále je vypočítaný detektor σ . Pokud hodnota σ překročí určitou prahovou hodnotu, vede to k závěru, že kamera C je zařízen, ze kterého byl obrázek \mathbf{I} pořízen. [2]

1.2 Metody založené na neuronových sítích

Na rozdíl od klasických metod, metody založené na konvolučních neuronových sítích (CCNs) mohou automaticky získávat vlastnosti z obrázku a zároveň se učit klasifikovat během procesu učení. [1]

1.2.1 Camera Model Identification With The Use of Deep Convolutional Neural Networks

Obecná struktura konvolučních neuronových sítí (CNN) obsahuje vrstvu složenou z neuronů. Neuron vezme vstupní hodnotu, provede výpočet a výsledek předá další vrstvě. Struktura této metody je znázorněná na obrázku 1.3. Přičemž metoda zkoumá dva typy odšumovacích filtrů v předzpracování.



Obrázek 1.3: Architektura CNN pro identifikaci kamery. [11]

Jedním z nich je klasická cesta k získání zbytkového šumu pomocí odšumovacího filtru. Zbytkový šum je získávaný z obrázku I následovně

$$N = I - F(I),$$

kde $F(I)$ je obraz zbavený nadbytečného šumu a F je používaný odšumovací filtr. Filtr je používaný pro každý barevný kanál zvlášť.

Dalším typem odšumovacího filtru je horní propust použitá na vstupní obrázek I . Tento typ filtru může potlačit rušení způsobené hranami obrazu a textury k získání zbytkového šumu.

$$A = I * \frac{1}{12} \begin{pmatrix} -1 & 2 & -2 & 2 & -1 \\ 2 & -6 & 8 & -6 & 2 \\ -2 & 8 & -12 & 8 & -2 \\ 2 & -6 & 8 & -6 & 2 \\ -1 & 2 & -2 & 2 & -1 \end{pmatrix}$$

Výstupy z předzpracování obrazu jsou vstupem pro CNN.

První konvoluční vrstva (*Conv1*) aplikuje na vstupní hodnoty zbytkového šumu konvoluci s 64 kernelovými jádry o velikosti okna 3 x 3. Výstupem je mapa vlastností o velikosti 126 x 126. Tohle je vstupem pro druhou vrstvu (*Conv2*), která na vstup použije konvoluci s kernelovými jádry a velikosti okna 3 x 3. Zde je výstupem mapa vlastností o velikosti 64 x 64. Třetí konvoluční vrstva (*Conv3*) aplikuje konvoluci s 32 kernelovými jádry o velikosti 3 x 3. Na výstup každé konvoluční vrstvy je aplikovaná funkce Rectified Linear Unit (ReLU), která může pomoci k rychlejší konvergenci u velkých modelů trénovaných na velké databázi.

Výstup ze třetí konvoluční vrstvy následuje operace max-pooling s oknem 3 x 3. Max-pooling funguje na mapě vlastností na odpovídající konvoluční vrstvě a vede ke stejnému počtu prvků mapy vlastností s klesajícím prostorovým rozlišením. Výstup z max-pooling je přiveden na vstup fully-connected vrstev (*FC1*) a (*FC2*), které mají 256 a 4096 neuronů. Výstup ze třetí fully-connected vrstvy (*FC3*) je posílán na vstup softmax funkce. Během trénování jsou vrstvy (*FC1*) a (*FC2*) vynechány. [1], [11]

1.3 Metody založené na Wavelet a Curvelet transformaci

1.3.1 Digital Camera Identification Based on Curvelet Transform

Metoda využívá curvelet-based transformaci k identifikaci otisku snímku digitální kamery a slibuje překonání limitů Wavelet-based metod. K identifikaci kamery, ze které byl pořízen barevný snímek I je potřeba nejdříve určit vzor sensorového šumu R_C kamery C . Tento vzor R_C je získán aproximací PRNU šumu z průměru několika obrázků $I_s, s = 1, \dots, S$ a aplikací curvelet-based odšumovacího filtru F .

Curvelet-based odšumovací filtr F je složen kombinací curvelet transformace a cycle spinning. Nejprve je na barevný obrázek aplikuje operace cycle spinning s jedním posunem ve 2D směrech. Potom je použita curvelet transformace k získání koeficientů $c(j, l, k)$ ve všech směrech a velikostech. Zde je použito $j = \log_2(512) - 3$ a úhlový parametr $l = 16$. Potom následuje tvrdé prahování pro získání koeficientů $\hat{c}(j, l, k)$:

$$\hat{c}(j, l, k) = \begin{cases} c(j, l, k), & \text{pokud } c(j, l, k) \geq k \cdot \sigma_0 \cdot \tilde{\sigma} \\ 0, & \text{pokud } c(j, l, k) < k \cdot \sigma_0 \cdot \tilde{\sigma} \end{cases}$$

kde $k = 2, 5$ pro hodnoty s výjimkou nejmenších a $k = 2, 5$ pro nejmenší hodnotu. Následně je aplikovaná inverzní transformace k $\hat{c}(j, l, k)$ a je získán obraz zbavený šumu. Nakonec je použita inverzní operace cycle spinning, čímž je získán finální výsledek obrazu zbaveného šumu $F(I_s)$. Obraz zbytkového šumu je pak získán následovně $\mathbf{n}_s = I_s - F(I_s)$.

V procesu získání zbytkového šumu je vstupní obraz I_s rozdělen na 512 x 512 obrázkových bloků. Každý blok je v celém procesu zpracováván samostatně.

Metoda používá pro získání referenčního vzoru 20 náhodných obrázků z kamery C . Z nich je pomocí curvelet-based metody získáván obraz zbytkového šumu $\mathbf{n}_i (i \in R, G, B)$ pro jednotlivé barevné kanály a hodnoty jsou průměrovány ve 3 barevných kanálech. Tím je získán vzor sensorového šumu R_C kamery C , který obsahuje 3 referenční vzory R_{CR}, R_{CG}, R_{CB} ve 3 kanálech. Tyto tři reference jsou převedeny do 3 vektorů.

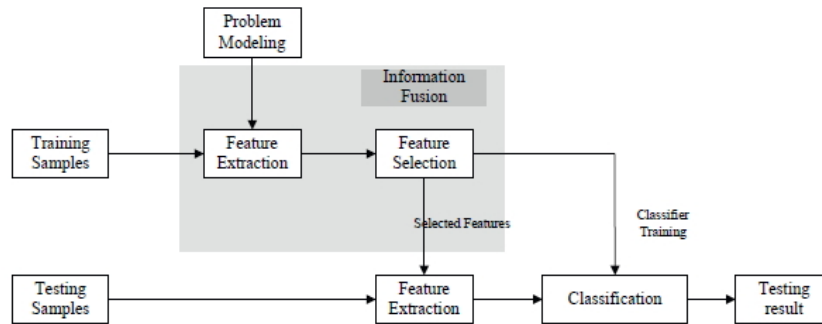
K určení kamery C , ze které byl pořízen barevný obrázek I , je z obrázku získán zbytkový šum v každém barevném kanálu R, G, B . Potom jsou počítány 3 korelace ρ_R, ρ_G, ρ_B mezi třemi referenčními vzory ze třech barevných kanálů vzoru sensorového šumu a mezi barevnými kanály z nového obrázku:

$$\rho_i(R_C, \mathbf{n}_i) = \frac{(\mathbf{n}_i - \bar{\mathbf{n}}_i) \cdot (\mathbf{R}_{Ci} - \bar{\mathbf{R}}_{Ci})}{\|\mathbf{n}_i - \bar{\mathbf{n}}_i\| \|\mathbf{R}_{Ci} - \bar{\mathbf{R}}_{Ci}\|},$$

kde $i \in R, G, B$. Následně je počítána korelace ρ_C mezi vzorem sensorového šumu a novým barevným obrázkem za použití $(\rho_R + \rho_G + \rho_B)/3$. Na závěr je určena prahová hodnota θ pro každou kameru principem minimalizace false acceptance rate. [7]

1.3.2 Source Camera Identification Forencics Based on Wavelet Features


Metoda extrahuje vlastnosti vybraného obrázku z koeficientů z jeho wavelet domény, čímž slibuje efektivnější přístup oproti získávání vlastností z prostorové domény obrázku. Využívá Sequential Forward Feature Selection (SFFS) ke snížení redundance a korelace vlastností a k výběru významnějších vlastností pro rychlejší výpočetní rychlost. Ke určení zdrojové kamery slouží metoda multi-class Support Vector Machine (multi-class SVM).



Obrázek 1.4: Blokový diagram metody. [3]

Na obrázku 1.4 je zobrazeno blokové schéma metody, které obsahuje čtyři hlavní procesy získání koeficientů z obrázku – analýza a selekce, trénink klasifikátoru, identifikace a ověření. Statistický model digitálního obrázku je získáván z koeficientů z wavelet domény obrázku, kde je extrahováno 216 vlnkových koeficientů vyššího řádu z dekompozice 4-tého řádu a také statistika výskytu 135 společných vlnkových koeficientů.

Koeficienty vyšších řádů jsou získávány z čtyřnásobné vlnkové dekompozice pomocí kvadratických zrcadlových filtrů (QMFs) pro oddělení frekvenčního prostoru na čtyři stupnice a orientace (vertikální, horizontální a diagonální sub-pásmo). Proces je zobrazen na obrázku 1.5.




Obrázek 1.5: Získávání koeficientů vyšších řádů. [3]

Pro barevný obrázek je dekompozice aplikována na každý barevný kanál. Z sub-pásmového histogramu koeficientů, lineární predikce v každé z orientací, měřítku a barvě jsou získávány čtyři vlastnosti (střední hodnota, rozptyl, šikmost a kurtóza).

Linie, hrany a rohy v obrázku způsobují korelaci mezi koeficienty odpovídající různě orientaci a měřítku. K získání těchto koeficientů je použita matice společných koeficientů. Tato matice reprezentuje texturu obrazu a aplikuje výpočet vzdáleností se

stejnou orientací koeficientů matice s různými měřítky. Potom jsou z těchto vzdáleností získány statistické vlastnosti. K extrakci se používá Db8 čtyř-stupňová vlnková dekompozice. Vzdálenosti jsou počítány z vertikálních, horizontálních a diagonálních sub-pásem matice pro každé měřítko a barevný kanál. Následně je ze vzdáleností získána energie, entropie, kontrast, homogenita a korelace vlastností. Celý proces je ukázán na obrázku 1.6.



Obrázek 1.6: Extrakce společných vlnkových vlastností. [3]

Sequential Forward Feature Selection (SFFS) algoritmus analyzuje všechny vlastnosti a vytváří sadu nejvýznamnějších vlastností jejich přidáním nebo odstraněním dokud je ještě co zlepšovat. Nejprve inicializuje aktuální vektor dvou vlastností poskytujících nejlepší výsledek klasifikace. Nejvýznamnější z nich přidá do aktuální sady vlastností. Následně odebere nejméně významnou vlastnost z aktuální sady a kontroluje zda odebrání vlastnosti zlepšilo nebo naopak zhoršilo výsledek klasifikace. Pokud se výsledek klasifikace zlepšil, odebere tuto vlastnost natrvalo a vrací se zpět k novému odebrání nejméně významné vlastnosti. Pokud se naopak výsledek klasifikace nezlepšil ponechává danou vlastnost v aktuálním sadě a přidává k ní další nejvýznamnější vlastnost. Na závěr je použitý Multi-Class Support Vector Machine pro klasifikaci a získání výsledku identifikace obrázku. [3]

1.4 Metody využívající automatického vyvažování bílé barvy

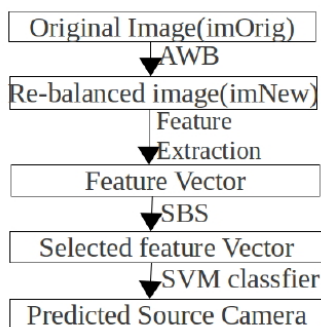
Vyvážení bílé barvy je aplikované ve všech digitálních fotoaparátech ke korekci barev obrázku v závislosti na zdroji světla. Každý digitální fotoaparát nějakým způsobem provádí vyvážení bílé barvy v procesu zpracování obrázku uvnitř fotoaparátu. I přesto, že uživatel vypne automatické vyvážení bílé barvy (AWB), foťák stále provádí fixní barevné korekce, které mohou být využity k identifikaci zařízení z porízeného snímku. [17]

1.4.1 Source Camera Identification Usins Auto-White Balance Aproximation

Tato metoda je založená na pozorování toho, že algoritmus pro vyvážení bílé barvy má na obraz malý nebo žádný efekt, pokud je na daný obraz aplikovaný podruhé.

$$WB(WB(im)) = WB(im)$$

Proces postupu metody je zobrazen na následujícím obrázku 1.7. Na originální obrázek *imOrig* se nejprve aplikuje vyvážení bílé k získání nového obrázku *imNew*. Poté jsou z *imNew* získány metriky kvality obrazu (IQM). Nežádoucí vlastnosti jsou eliminovány pomocí zpětného sekvenčního výběru (SBS). Nakonec pomocí SVM klasifikátoru je prováděná identifikace fotoaparátu, kterým byl daný snímek pořízen.



Obrázek 1.7: Jednotlivé kroky metody. [17]

Na každý obraz je aplikováno několik různých druhů AWB metod založených na rozdílných předpokladech.

- Gray-World s šesti barevnými adaptačními metodami
- White-Patch s procentním nastavením bílé 1/255, 0.01 a max-RGB s vyhlazením
- Shades-of-grey

- Gray-Edge s rozlišením 1 a 2

Poté jsou užity metriky k získání souboru vlastností k vyhodnocení kvality obrazu. Tyto vlastnosti jsou získávány z *imNew* po aplikování různých AWB metod na obraz *imOrig*. V tabulce 1.8 je přehled použitých metrik. Pokud je u dané metriky číslo 1, je získávána z barevného obrázku. V případě čísla 3 je metrika získávána z jednotlivých barevných kanálů separátně.

Name	Number
Mean Absolute Error (MAE)	3
Mean Square Error (MSE)	3
Normalized MSE	3
Peak-Signal-to-Noise Ratio	3
Maximum Difference	3
Czekznowski Correlation	1
Angle Mean	1
Structural Content	3
Correlation Quality	3
HVS real lab distance	1
HVS similarity weight	1
Block Weighted Spectral Distance (max,mean,median)	3*3

Obrázek 1.8: Přehled použitých metrik. [17]

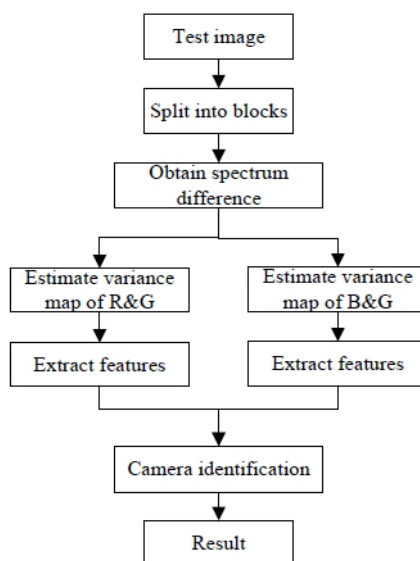
Pro redukci šumu a eliminaci nepotřebných hodnot je použit sekvenční zpětnovazební algoritmus (SBS). Tato metoda se pokouší optimalizovat kritéria odstraněním vlastností z počáteční sady kandidátů. SBS eliminuje čtyři vlastnosti z počáteční sady, nicméně ve všech experimentech je jich stále použito 404. Na závěr, k identifikaci foťáku, je použitý klasifikátor Support Vector Machine (SVM). [17]

1.5 Metody založené na barevném filtru

Metody založené na barevných filtrech využívají k identifikaci kamery interpolačních algoritmů, pomocí kterých jsou v přístroji dopočítávané chybějící barevné kanály pro jednotlivé pixely.

1.5.1 An Improved Algorithm for Camera Model Identification Using Interchannel Demosaicking Traces

Lidské oko je nejvíce citlivé na zelenou složku viditelného světla, proto v mnoha barevných filtrech používaných ve fotoaparátech převládá počet vzorků zeleného kanálu nad vzorky modrého nebo červeného kanálu. V Bayerově masce je počet zelených vzorků dvojnásobný oproti červeným nebo modrým. Z tohoto důvodu se aliasing projevuje u zeleného kanálu méně než u ostatních a jeho vysokofrekvenční složky jsou lépe zachovány a také používány k nahrazení v kanálech modré a červené barvy. To vede k různým mezikanálovým odchylkám, které zanechávají ve snímku interpolační procesy. Metoda extrahuje spektra mezi zeleno-červenými a zeleno-modrými barevnými kanály a jejich rozdíl ve tvaru a textuře se využívá pro identifikaci kamery.



Obrázek 1.9: Blokové schéma algoritmu. [14]

Na obrázku [?] je blokové schéma algoritmu. Testovací obrázek je rozdělen do nepřekrývajících se bloků, k získání dostatečného počtu vzorků k odhadnutí odchylek. Poté je na každý barevný kanál jednotlivých bloků aplikována DFT k získání \tilde{R} , \tilde{G} a \tilde{B} a jsou vypočítány spektrální rozdíly $\tilde{G} - \tilde{R}$ a $\tilde{G} - \tilde{B}$. Dále se zavádí M jako počet vzorků v oblasti (u, v) pro každý blok jako $\Omega_i(u, v)$, $i = 1, 2, \dots, M$. Pak lze dostat mapy odchylek \sum_{RG} a \sum_{BG} korespondující s barevnými kanály, kde $\sum(u, v) = Var\{\Omega_i(u, v)\}$. Následně jsou za pomoci AdaBoost klasifikátoru získány vlastnosti k obrázku z jeho mapy odchylek.


Metoda využívá rozdílů ve tvaru a textuře map odchylek, jelikož tyto mapy jsou velmi podobné u stejného modelu kamery a lehce odlišné pro různé modely kamer. K tomu jsou vybrány 4-rozměrné tvarové funkce a 8-rozměrné texturové funkce pro každý barevný kanál. Vyrovnáním histogramu map odchylek se více vyznačí tvar a textura.

Dále je používána statistická distribuce, aby odrazila charakteristiky obrazové textury. Ke komplexnímu popisu texturové funkce jsou brány v úvahu čtyři směry, 0° , 45° , 90° a 135° . Texturová funkce je počítána ze čtyř skupin. První skupinou je texturová energie, která je měřena homogenitou obrazu. Druhou skupinou je texturový kontrast, což je měření kontrastu nebo také množství lokálních změn v obraze. Třetí skupinou je korelace textury měřená lineární závislostí šedých tónů v obraze. Poslední čtvrtou skupinou je entropie textury, což je množství informací, které obraze obsahuje.

Celkem se dostane 24 obrazových funkcí z map odchylek, tedy 12 funkcí pro každý barevný pár – $G - R$ a $G - B$. [14]

1.5.2 Using Improved Imaging Sensor Pattern Noise for Source Camera Identification

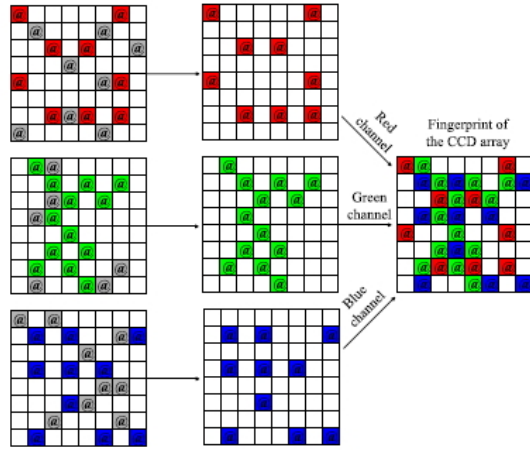
Světlo prostupující barevným filtrem ve foťáku vytvoří tři jedinečné obrazce pro každý barevný kanál, jak je ukázáno na obrázku 1.10. Z nich jsou následně dopočítávány barvy pro ostatní pixely v každém barevném kanálu. Této skutečnosti využívá metoda pro vytvoření jedinečného obrazové vzoru pro čip foťáku.



Obrázek 1.10: Získávání zbytkového šumu. Šedé bloky jsou interpolované hodnoty, černé představují nulovou hodnotu pro daný barevný kanál.

Označme r , g , b jako červenou, zelenou a modrou barvu. Z nich můžeme vybrat \tilde{W}_r , \tilde{W}_g , \tilde{W}_b jako význačné komponenty, ze kterých jsou tvořeny obrazové vzory pro každý barevný kanál. Z těchto komponent lze poskládat jedinečné obrazové vzory \tilde{W}'_r , \tilde{W}'_g , \tilde{W}'_b .

Na obrázku 1.11 je znázorněný postup získávání komponent \tilde{W}'_r , \tilde{W}'_g , \tilde{W}'_b , které jsou vybírány z \tilde{W}_r , \tilde{W}_g , \tilde{W}_b umístěných na pozicích, jejichž hodnota nebyla interpolována z okolních hodnot v příslušném barevném kanálu.



Obrázek 1.11: Schéma získání jedinečného vzoru kamery. [15]

Při konstrukci $\tilde{\mathbf{W}}'_g(i, j)$ se nebere v úvahu, jestli se hodnota $\tilde{\mathbf{W}}_g$ nachází na interpolované pozici či nikoliv. Místo toho se $\tilde{\mathbf{W}}_g$ porovnává s hodnotami v červeném a modrém kanále, umístěných na stejné pozici a výsledná hodnota se získá podle následujícího pravidla

$$\tilde{\mathbf{W}}'_g = \begin{cases} \tilde{\mathbf{W}}_g(i, j), & \text{pokud } g = \operatorname{argmax}_x \left| \tilde{\mathbf{W}}_x(i, j) \right|, \text{ kde } x \in \{r, g, b\} \\ 0, & \text{jinak} \end{cases}$$

Následnou kombinací $\tilde{\mathbf{W}}_r$, $\tilde{\mathbf{W}}_g$ a $\tilde{\mathbf{W}}_b$ získáme výsledný vzor sensorového šumu $\tilde{\mathbf{W}}_c$ pro daný foťák, který je následně pomocí korelačního detektoru porovnáván s ostatními vzory. [15]

1.6 Ostatní metody

1.6.1 Camera Brand and Model Identification Using Moments of 1-D and 2-D Characteristic Functions

Předpokladem v této metodě je, že jakékoliv odlišnosti v průběhu při snímání obrazu mohou vést ke statistickým rozdílům ve výsledném obraze. Momentové 1-D charakteristické funkce, jejich prediction-error 2-D, všechny koeficienty z vlnkové transformace do třetího stupně a momentové 2-D charakteristické funkce, získané pouze z JPEG 2-D, mohou odpovídajícím způsobem ovlivnit statistický model pro následnou klasifikaci.

Diskrétní Fourierovou Transformací (DFT) histogramu lze získat charakteristickou funkci pro daný obrázek definovanou jako

$$M_n = \frac{\sum_{i=1}^{N=2} x_i^n |H(x_i)|}{\sum_{i=1}^{N=2} |H(x_i)|},$$

kde $H(x_i)$ je charakteristická složka v DFT pro frekvenci x_i a N je počet rozdílných hodnot pixelů v obrázku.

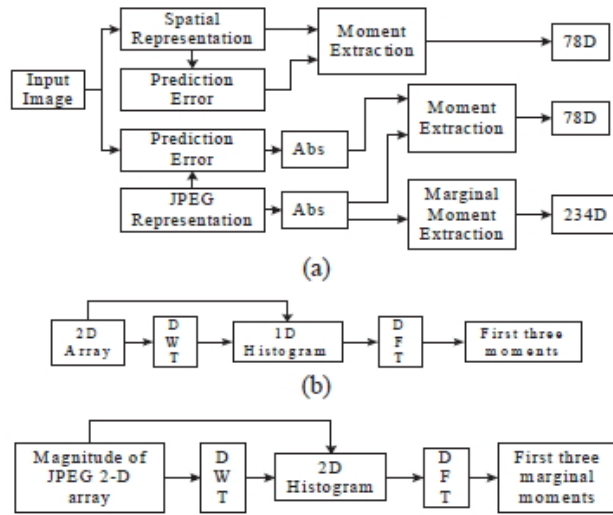
Statistické rozdíly mohou být zahrnuty v obsahu obrázku a šumu, proto metoda využívá prediction-error image, který obsahuje rozdílový snímek predikovaného obrazu z obrazu originálního. S ohledem na 2 x 2 bloky ve 2-D obrázku je predikce vyjádřena následovně

$$\hat{x} = \begin{cases} \max(a, b) & c \leq \min(a, b) \\ \min(a, b) & c \geq \max(a, b) \\ a + b - c & \text{otherwise,} \end{cases}$$

kde a, b jsou soudní pixely od pixelu x , c je diagonální pozice od x a \hat{x} je predikovaná hodnota x .


Vlastnosti generované z různých subpásem stejného stupně u diskretní vlnkové transformace spolu nekorelují, čehož metoda také využívá při identifikaci kamery. Konkrétně používá tří stupňovou Haarovu vlnkovou transformaci k dekompozici do čtyř subpásem pro každý stupeň. To znamená s originálním obrazem 13 subpásem. Pro každé subpásma jsou získány první tři momenty charakteristické funkce. To samé je použito pro prediction-error obrazy. Tím je získáno celkem $39 + 39 = 78$ vlastností z originálního obrazu a jeho dekompozic. Struktura je zobrazena na následujícím blokovém diagramu 1.12.

Mnoho digitálních kamer používá v procesu zpracování obrazu pole barevných filtrů a barevnou interpolaci, která dopočítává jednotlivým pixelům jejich chybějící barevné složky R, G, B. Tento algoritmus může být rozdílný v pro každou kameru a specifické korelace existují mezi sousedními pixely. Uvnitř digitálního obrazového procesoru probíhají kromě barevné interpolace ještě další procesy, doostřování a redukce šumu, které mohou mít vliv na korelaci mezi hodnotami pixelů. Tyto procesy



Obrázek 1.12: a) Blokový diagram. b) sub-blokový diagram pro získání momentu. c) Sub-blokový diagram pro získání marginálního momentu. [6]

metoda uvádí ve 2-D histogramu jako korelační charakteristiky, kde se měří společný výskyt dvojice pixelů oddělených určitou vzdáleností a orientací. Během výpočtu 2-D histogramu je brána v úvahu horizontální, vertikální a diagonální orientace, jak je znázorněno na obrázku 1.13.



Obrázek 1.13: Horizontální, vertikální a diagonální orientace. [6]

Pro každou orientaci lze vypočítat dva marginální momenty 2-D charakteristické funkce podle vztahu

$$M_{u,n} = \frac{\sum_{j=1}^{N/2} \sum_{i=1}^{N/2} u_i^n |H(u_i, v_j)|}{\sum_{j=1}^{N/2} \sum_{i=1}^{N/2} |H(u_i, v_j)|},$$

kde $H(u_i, v_j)$ je 2-D složka charakteristické funkce na frekvenci (u_i, v_i) a N je počet absolutních hodnot v daném sub-pásmu. Celkem tedy metoda pracuje s 390-D vlastnostmi k danému obrázku. [6]

Kapitola 2

Vybrané metody

V praktické části diplomové práce jsem se rozhodl implementovat, vyzkoušet a porovnat následující tři metody, které odlišnými algoritmy využívají k identifikaci přístroje vzor sensorového šumu.

1. Metoda – Patch–Based Sensor Pattern Noise for Camera Source Identification
2. Metoda – Pairwise Magnitude Relations of Clustered Sensor Pattern Noise
3. Metoda – Digital Camera Identification Based on Curvelet Transform

Všechny vybrané metody jsem implementoval v programu Matlab R2015a a Matlab R2019a. Jejich funkčnost jsem testoval na vlastním vytvořené databázi fotek.

2.1 Databáze fotek

Pro testování jednotlivých algoritmů jsem chtěl vytvořit vlastní databázi zcela nahodilých fotek pořízených různými lidmi a nevyužívat veřejně dostupnou Dresden Image Database, ze které čerpala testovací fotky většina prezentovaných metod.

Podařilo se mi sesbírat dostatečné množství fotek z celkem třinácti různých digitálních fotoaparátů, různých značek, modelů, staří techniky a taky tříd od amatérských přístrojů po profesionální. Přehled fotoaparátů a počtu využívaných od jednotlivých přístrojů je uveden v následující tabulce 2.1.

Proměnná	Hodnota	Počet fotek
1.	Canon 7D mark I	180
2.	Canon 7D mark II	180
3.	Canon 5D mark III	180
4.	Canon 50D	180
5.	Canon 300D	180
6.	Canon G16	180
7.	Nikon D4s	180
8.	Nikon D5200	180
9.	Olympus E520	95
10.	Canon EOS M	180
11.	Canon PowerShot G9	180
12.	Fujifilm FinePix AX500	121
13.	Acer CR8530 180	180

Tabulka 2.1: Přehled použitých fotoaparátů a počet fotek.

2.2 Získání zbytkového šumu

Možností jak získat obraz zbytkového šumu ze snímku je také mnoho a z mnoha vybraných metod jej každý získává trochu jinak. Přičemž čímž lepší a kvalitnější obraz zbytkového šumu dokáže metoda extrahovat, tím se její úspěšnost zvyšuje.

První metoda k získání šumu využívá vlnkové transformace a Wienerovi filtrace, druhá používá Dark frames a třetí curvelet transformaci. Jelikož jsem Dark frames neměl k dispozici a pro některé fotoaparáty už je nemožné je získat, zbývalo mi u této metody nahradit extrakci šumu jinou metodou. Navíc pro objektivní porovnání úspěšnosti jednotlivých metod bylo potřeba zajistit každé z nich stejné vstupní podmínky.

Pro implementaci metody založené na vlnkové transformaci filtraci jsem využil podrobného návodu popsáném ve [9], kde jsem místo dynamického okna v průchodu Wienerovou filtrací použil statické okno 5×5 . V Matlabu je tato metoda implementována ve funkcích `BlockNOISEjustONE` a `BlockNOISEofONE`, podle použití pro filtraci černobílého nebo barevného obrazu.

Pro druhou metodu založenou na Curvelet transformaci jsem použil funkci volně dostupnou na <http://www.curvelet.org/download.html>. Použitá v algoritmu filtrace ve funkcích `BlockNOISE2` a `BlockNOISEjustONE2`, s drobnou úpravou výstupního parametru, místo obrazu zbaveného šumu vrací rovnou obraz zbytkového šumu.

Oba druhy získání šumu jsem porovnal na druhé metodě lastrových párů. Vzor sensorového šumu byl vytvořen pro první fotoaparát Canon 7D mark I, se kterým byly porovnávány ostatní fotoaparáty pro všechny velikosti klastrových párů. Z výsledků, podrobněji prezentovaných v části vyhodnocení šumu, lze z tabulky 3.1 vyznat, že lépe dopadla extrakce šumu založená na Curvelet transformaci, kterou jsem následně používal v algoritmech jednotlivých metod identifikace fotoaparátu.

2.3 Metoda 1 - Patch-Based Sensor Pattern Noise for Camera Source Identification

Pro vytvoření vzoru obrazu šumu je použito 50 snímků, které jsou na vstupu ořezány pomocí funkce `imageCROPP` na velikost 512×512 od středu obrázku, převedeny do černobílé a přetyčovány na datový typ *double*. Následně jsou obrázky rozděleny na bloky 128×128 a pro každý blok je odhadnutý parametr β , který reflektuje složitost textury. Pro hladké povrchy nabývá menších hodnot. Tento parametr získávám pomocí funkce `ggmle`, která je dostupná ke stažení na adrese <http://www.ifp.uiuc.edu/minhdo>.

Dále jsou vždy bloky na stejných pozicích od všech obrázků, seřazeny vzestupně podle parametru β . První polovina s nejmenší hodnotou β a tedy teoreticky s nejhladší strukturou následně používám k filtraci a získání obrazu šumu pro daný blok pomocí rovnice $r_i = I_i - F(I_i)$, kde r_i je zbytkový šum jednoho bloku jednoho snímku, I_i je odpovídající původní blok snímku a $F(I_i)$ je blok zbavený šumu filtrací.

Ze získaných sad obrazů šumů pro jednotlivé bloky jsou v dalším kroku použity dva přístupy k získání finálního vzoru sensorového šumu. První z nich značená jako *SPN* využívá klasického průměrování hodnot počtem celkových použitých snímků N , zapsáno rovnicí

$$K = \frac{\sum_{i=1}^N \mathbf{r}_i}{N}.$$

Druhý přístup je založený na technice *Maximum Likelihood Estimator (MLE)*, kterou lze matematicky vyjádřit následovně

$$K = \frac{\sum_{i=1}^N \mathbf{r}_i \mathbf{I}_i}{\sum_{i=1}^N (\mathbf{I}_i)^2}.$$

Vstupní testovací snímek je rovněž ořezán na stejnou velikost, rozdělen na bloky 128×128 a pro každý blok je odhadnutý parametr β . Blok s nejmenší hodnotou β je porovnáván s blokem ze vzoru šumu *SPN* a *MLE* na stejných pozicích. [16]

2.3.1 Implementace metody v Matlabu

Hlavním souborem a zároveň průvodcem je soubor `Patch_based_ALL.m`. Ten je rozdělen tři části, v první je specifikace parametrů, na jakou velikost bude ořezán vstupní snímek, jak velké bloky budou vytvářeny, kolik snímků bude použito na vytvoření vzoru sensorového šumu, kolik snímků bude následně testováno a v neposlední řadě určení z jakého fotoaparátu se budou snímky načítat, kde je také určena cesta k nim na disku.

Poté následují dvě sekce, jedna na vytvoření testovací sady snímků a druhá na vytváření vzoru sensorového šumu. V obou případech jsou data ukládány to struktury,

ze které si je vezme korelační algoritmus na porovnání podobnosti bloků. U testovací sady je vždy s blokem snímku ukládán také jeho index na polohu v původním obrazu. Vzor sensorového šumu je vytvářen zároveň pro *SPN* a *MLE*.

Vzory sensorového šumu lze uložit všechny pro jednotlivé fotoaparáty do jedné struktury, což je efektivnější na rychlost porovnávání. Větší testovací sady snímků je vzhledem k omezené paměti výpočetní techniky výhodnější načítat jednu po druhé a neuchovávat je v paměti všechny najednou.

Standardně je algoritmus nastaven, ať pracuje s černobílými snímky, jednoduše jej lze podle potřeby a návodu v kódu přenastavit ať pracuje se barevnými snímky a v každém barevném kanále provádí extrakci šumu zvlášť.

2.4 Metoda 2 - Pairwise Magnitude Relations of Clustered Sensor Pattern Noise

Částečně podobným způsobem jako v první metodě je získán vzor sensorového šumu i zde. Na vstupu je 50 snímků ořezaných na velikost 1024×1536 , převedeno na černobílou, přetypováno na datový typ *double* a rozděleno na bloky 512×512 . Každý blok je filtrován zvlášť k získání zbytkového šumu. Následně jsou bloky se šumem spojeny zpět do jedolitého obrazu a všech padesát snímků použitých pro vytvoření vzoru sensorového šumu je zprůměrováno obdobně jako u *SPN* vzoru.

Poté je matice vzoru sensorového šumu převedena na vektor, který je seřazený vzestupně podle hodnot šumu v jednotlivých pixelech. V seřazeném vektoru si každý pixel šumu drží u sebe i index jeho polohy v původní originální matici. Ze seřazeného vektory vytváří funkce `clusterCREATEtest` nebo `clusterCREATEpatt` klastry o počtu pixelů 1638, tak aby vzniklo celkem 960 klastrů. Jelikož jsou klastry vytvářeny ze seřazeného vektoru šumu postupně od pozice jedna, tvoří každý klastr vždy pixely šumu s podobnou hodnotou.

V následujícím kroku funkce `clusterPAIRcreatingTEST` nebo `clusterPAIRcreatingPATT` vytváří klastrové páry tak, aby každý klastr v páru obsahoval co nejvíce opačné hodnoty šumu. Tj, první pár tvoří klastry na pozici 1 a N , druhý pár klustry na pozici 2 a $N - 1$, třetí 3 a $N - 2$, atp., kde N je celkový počet klastrů. V mém případě 960, takže celkem mám 480 klastrových párů.

U testovacích snímků je postup identický. Na závěr je k porovnání podobnosti testovacího snímku se vzorem bráno postupně nejprve prvních 10% klastrových párů z celkového počtu 480, poté 20%, 30%, .. až 100% klastrových párů. Ještě před samotnou korelací podobnosti testovacího snímku se vzorem je každý pixel šumu na základně indexu polohy u něj uloženého vložen zpět na pozici, která mu odpovídal původně. Chybějící místa pixelů jsou doplněny nulami. [13]

2.4.1 Implementace v Matlabu

Zde je hlavním souborem a průvodcem soubor `Clustered_pairwise_ALL.m`. Opět s popisem a návodem přímo v kódu. Nejprve jsou v první části stanoveny specifikace velikosti vstupního snímku, velikosti bloků, velikost klastru, počtu snímků pro vytvoření vzoru sensorového šumu, počtu snímků testovacího datasetu a fotoaparát, pro který se budou načítat data. A podobně jako v předchozí metodě se volí, zda se bude načítat testovací snímky nebo vytvářet vzor šumu.

Zde je navíc ještě druhá část, kde se vybírá počet klastrových párů v procentech, fotoaparát pro který se budou vytvářet a zda se budou klastrové páry vytvářet pro testovací snímky nebo vzor šumu. U volby fotoaparátu se musí dát pozor, aby pro něj byly v předchozím kroku načtená data.

Stejně jako v předchozí metodě vzory sensorového šumu lze uložit všechny pro jednotlivé fotoaparáty do jedné struktury, testovací datasety je pak výhodnější držet načtený vždy jen jeden fotoaparát.

Algoritmus je také standardně nastaven, ať pracuje s černobílými snímky, jednoduše jej lze podle potřeby a návodu v kódu přenastavit ať pracuje se barevnými snímky a v každém barevném kanále provádí extrakci šumu zvlášť.

2.5 Metoda 3 - Digital Camera Identification Based on Curvelet Transform

Metoda v originále uvádí, že pro vytvoření vzoru sensorového šumu stačí pouze 20 snímků, nicméně pro zachování stejných podmínek jako v předchozích dvou metodách jich používám 50. Velmi podobně jako u předchozích metod jsou vstupní fotky ořezány na velikost 1024×1024 rozděleny do bloků o velikostech 512×512 . Tentokrát jsou snímky ponechány v barvě (tudíž metoda funguje jen pro barevné snímky) a každý blok je filtrován zvlášť ve všech třech barevných kanálech R, G, B . Tím jsou získány celkem tři vzory sensorového šumu, každý pro jeden barevný kanál.

Matice vzorů sensorového šumu pro jednotlivé kanály jsou převedeny na vektor. Podobně je tomu i u testovacího snímku. V dalším kroku jsou počítány tři korelace ρ_C mezi vektory sensorového šumu pro každý barevný kanál a vektory šumu u testovacího snímku podle následujícího vztahu

$$\rho_i(R_C, \mathbf{n}_i) = \frac{(\mathbf{n}_i - \bar{\mathbf{n}}_i) \cdot (\mathbf{R}_{Ci} - \bar{\mathbf{R}}_{Ci})}{\|\mathbf{n}_i - \bar{\mathbf{n}}_i\| \|\mathbf{R}_{Ci} - \bar{\mathbf{R}}_{Ci}\|},$$

kde $\bar{\mathbf{n}}_i$ a $\bar{\mathbf{R}}_{Ci}$ představují střední hodnoty a $i \in R, G, B$. [7]

2.5.1 Implementace v Matlabu

U této metody je hlavním souborem `Clustered_pairwise_ALL.m`. Základní přehled je stejný jako u předchozích dvou metod. Tahle metodabohužel není dotažené do konce. Respektive chybí u ní dokončit korelaci a porovnávání podobnosti jednotlivých vektorů.

2.6 Korelace a algoritmus pro vyhodnocení

Podobnosti vzorů seznorového šumu a testovacího obrázku jsem u prvních dvou metod prováděl pomocí matlabovské funkce `corr2`.

V souboru s názvem `CORRELACE` jsou nastaveny algoritmy korelace pro získání korelačních koeficientů pro první a druhou metodu. Následně jsou v souboru `Vyhodnocení` implementovány dva algoritmy pro vyhodnocování a usnadnění stanovení thresholdu pro minimální False Acceptance Rate (FAR), minimální False Rejection Rate (FRR). Funkce vyhodnocuje i další pomocné hodnoty jako TAR (True Acceptance Rate) a TRR (True Rejection Rate). U obou vyhodnocovacích algoritmů je potřeba zadat, jaký fotoaparát byl použitý jako vzor, vůči ke kterému se porovnával zbylý dataset.

Kapitola 3

Vyhodnocení

Výsledky korelací jednotlivých metod jsem vyhodnocoval pomocí souboru `Vyhodnoceni.m`, ve kterém jsou obsaženy tři části. Každá je nastavená pro vyhodnocení konkrétní metody. U každého vyhodnocování jsem stanovil pevný `threshold` a sledoval hodnoty False Acceptance Rate (FAR) a False rejection rate (FRR).

3.1 Algoritmy pro získání zbytkového šumu

Porovnání algoritmů pro extrakci zbytkového šumu jsem prováděl pomocí druhé metody pro identifikaci kamery u prvního fotoaparátu Canon 7D mark I pro všechny velikosti klastrových párů. Výsledky porovnání jsou uvedeny v tabulce 3.1. Hodnota `threshold` a hodnoty FRR jsou uváděny pro hodnotu, kdy metoda FAR = 1 fotka. V tabulce jsou hodnoty FRR uváděné v procentech. Velikost testovací sady fotek byla 100, u fotoaparátů 9 a 10 menší.

		Canon 7D mark I									
Metoda		CP10%	CP20%	CP30%	CP40%	CP50%	CP60%	CP70%	CP80%	CP90%	CP100%
Wavelet based transformace	Threshold	0,016	0,016	0,016	0,016	0,016	0,016	0,014	0,014	0,014	0,014
	FRR	17	12	12	11	11	11	11	11	11	11
Curvelet based transformace	Threshold	0,032	0,034	0,034	0,034	0,034	0,034	0,034	0,036	0,036	0,036
	FRR	3	1	0	0	0	0	0	0	0	0

Tabulka 3.1: FAR a FRR pro porovnání kvality extrakce zbytkového šumu metodou Wavelet absed a Curvelet Based.

Jak lze vidět z tabulky, Curvelet transformace má lepší výsledky nesprávně zamítnutých fotek při první nesprávně akceptované fotce. Z toho lze usoudit, že tento přístup k extrakci zbytkového šumu je lepší než pomocí Wavelet transformace.

3.2 Metoda 1

V první metodě jsem porovnával FRR a FAR pro dvě různé hodnoty `threshold`. Hodnota `threshold = 0,05` byla stanovena pro co nejmenší hodnoty FAR. Hodnotu

$thresholdu = 0,015$ jsem se snažil stanovit tak, aby byl co nejlepší poměr mezi hodnotami FRR a FAR, kde jsem se snažil mít co nejvíce správně rozpoznaných fotek k poměru co nejméně špatně rozpoznaných fotek. Výsledky pro oba $thresholdy$ jsou uvedeny v tabulkách 3.2 a 3.3. Hodnoty FAR a FRR jsou uváděné v procentech. Velikost testovací sady fotek byla 100, u fotoaparátů 9 a 10 menší.

Threshold = 0,015				
Metoda	SPN		MLE	
Fotoaparát model	FRR	FAR	FRR	FAR
Canon 7D mark I	2	40	3	39
Canon 7D mark II	37	29	44	30
Canon 5D mark III	60	26	54	24
Canon 50D	63	35	61	35
Canon 300D	61	37	65	36
Canon G16	56	30	58	29
Nikon D4s	43	33	50	33
Nikon D5200	56	34	54	33
Olympus E520	40	18	42	18
Canon EOS M	59	35	57	33
Canon PowerShot G9	47	31	48	30
Fujifilm FinePix AX500	47	25	47	26
Acer CR8530	67	30	70	30

Tabulka 3.2: FAR a FRR pro první metodu, všechny fotoaparáty a metody průměrování šumů SPN a MLE, pro hodnotu $thresholdu = 0,015$.

Threshold = 0,05				
Metoda	SPN		MLE	
Fotoaparát model	FRR	FAR	FRR	FAR
Canon 7D mark I	5	16	10	16
Canon 7D mark II	85	8	88	8
Canon 5D mark III	94	6	93	4
Canon 50D	83	9	86	9
Canon 300D	90	11	91	11
Canon G16	87	8	88	7
Nikon D4s	80	7	78	7
Nikon D5200	76	10	81	11
Olympus E520	56	8	58	7
Canon EOS M	87	8	92	9
Canon PowerShot G9	92	6	92	6
Fujifilm FinePix AX500	82	7	81	7
Acer CR8530	93	6	93	6

Tabulka 3.3: FAR a FRR pro první metodu, všechny fotoaparáty a metody průměrování šumů SPN a MLE, pro hodnotu $thresholdu = 0,05$

Hodnoty FAR a FRR pro obě metody průměrování šumu (SPN i MLE) jsou si velmi podobné a to i pro obě hodnoty $thresholdu$. Dále lze na první pohled zjistit že výsledky pro první fotoaparát Canon 7D mark I jsou velmi uspokojivé o třídu lepší než u všech ostatních.

3.3 Metoda 2

Zde jsem nejprve zjišťoval hodnoty FRR a FAR pro všechny velikosti párových klastrů u jednoho fotoaparátu. Zde jsem volil fotoaparát Canon 7D mark I a výsledky pro něj jsou uvedeny v tabulce 3.1, ze které jsou vidět vyrovnané výsledky pro velikosti klastrových párů 30% až 100%. Hodnoty FAR a FRR jsou uváděné v procentech. Velikost testovací sady fotek byla 100, u fotoaparátů 9 a 10 menší.

Pro další měření jsem volil pevnou velikost klastru 80% a porovnával FRR a FAR u všech značek fotoaparátů. Zjištěné hodnoty jsou uvedeny v tabulce 3.4.

Thres hold = 0,001 (*Thres hold = 0,01)		
Metoda	CP 80%	
Fotoaparát model	FRR	FAR
Canon 7D mark I*	0	15
Canon 7D mark II	48	47
Canon 5D mark III	68	41
Canon 50D	8	67
Canon 300D	15	68
Canon G16	31	51
Nikon D4s	49	49
Nikon D5200	22	66
Olympus E520	58	27
Canon EOS M	14	64
Canon PowerShot G9	21	55
Fujifilm FinePix AX500	7	52
Acer CR8530	23	64

Tabulka 3.4: FAR a FRR pro druhou metodu, všechny fotoaparáty a velikost párového klastru 80%. Hodnota thresholdu = 0,001.

U všech fotoaparátů jsem volil pevnou hodnotu thresholdu 0,001, kromě prvního, u kterého lze pozorovat opět poznatelně lepší výsledky.

Závěr

Ve své práci jsem implementoval tři algoritmy pro tři metody identifikace kamery z parametrů snímku a vytvořil databázi různých fotoaparátů o celkovém počtu fotek 2196 fotek.

Dále jsem porovnal dva algoritmy, Wavelet based a Curvelet based, na odšumování fotek a tudíž získávání obrazu zbytkového šumu. Zde lze z naměřených hodnot v tabulce 3.1 s jistotou říci, že metoda Curvelet based je vhodnější a podává lepší výsledky, jak ostatně prezentováno v původní práci [7].

U první metody jsem porovnával také dva přístupy (SPN a MLE) k průměrování šumu pro získání vzoru sensorového šumu. Zde ze zjištěných hodnot v tabulce 3.2 a v tabulce 3.3 nelze jednoznačně říci, která z nich je lepší. Pro hodnotu thresholdu 0,015 vykazují obě téměř shodné výsledky FAR a FRR. Pro thresholdu 0,05 se zdá být metoda SPN a o něco lepší. Při stejné hodnotě FRR 16% má metoda SPN oproti MLE lepší FAR.

Při porovnání účinnosti metod jedna a dva nelze s určitostí říci, která z nich je lepší. Obě metody dosahovaly u fotoaparátu Canon 7D mark I výrazně lepší výsledků v porovnání s ostatními přístroji v databázi. U něj lze konstatovat na základě hodnot v tabulce 3.3 a tabulce 3.4, že o něco lepší účinnost má druhá metoda. Při téměř stejných hodnotách FAR dosahuje druhá metoda o něco lepších hodnot FRR.

Třetí metoda je implementována, nicméně pro ni nejsou vyhodnoceny výsledky.

Literatura

- [1] Amel Tuama, Frédéric Comby, Marc Chaumont. *Camera Model Identification With The Use of Deep Convolutional Neural Networks*. France. Montpellier University, Nîmes University. 2016.
- [2] Bei-Bei Liu, Yongjian Hu, Heung-Kyu Lee. *Camera Brand and Model Identification Using Moments of 1-D and 2-D Characteristic Functions*. Republic of Korea, China. Department of Electrical Engineering and Computer Science Korea Advanced Institute of Science and Technology, School of Electronic and Information Engineering South China University of Technology. 2009.
- [3] Bo Wang, Yiping Guo, Xiangwei Kong, Fanjie Meng. *Source Camera Identification Forencics Based on Wavelet Features*. China. School of Electronics and Information, Dalian University of Technology. 2009.
- [4] curvelet.org, 2019[online]. [Cit. 17.5.2019] Dostupné z: <http://www.curvelet.org/index.html>
- [5] Elena Anisimova, Jan Bednář, Petr Páta. *Zpracování obrazu pomocí vlnkové transformace*. Czech republic. ČVUT v Praze, Fakulta elektrotechnická, Katedra radioelektroniky. 2013.
- [6] Guanshuo Xu, Yun Qing Shi, Wei Su. *Camera Brand and Model Identification Using Moments of 1-D and 2-D Characteristic Functions*. USA. New Jersey Institute of Technology, Newark, US Army CERDEC, Fort Monmouth. 2009.
- [7] Chi Zhang, Hongbin Zhang. *Digital Camera Identification Based on Curvelet Transform*. China. Computer Institute, Beijing University of Technology. 2009.
- [8] IEEEExplore Digital Library, 2019[online]. [Cit. 1.5.2019] Dostupné z: <https://ieeexplore.ieee.org/Xplore/home.jsp>
- [9] Jan Lukáš, Jessica Fridrich, Miroslav Goljan. *Digital Camera Identification From Sensor Pattern Noise*. 2006.
- [10] Li Dan, Wang Yan, Fang Ting. *Wavelet Image Denoising Algorithm Based on Local Adaptive Wiener Filtering*. China. School of Electrical Engineering and Information, Anhui University of Technology. 2011.
- [11] Milan Herbig. *Diplomová práce - Rekonstrukce pózy lidské ruky z hloubkového obrazu*. Česká republika. Fakulta aplikovaných věd, Západočeská univerzita v Plzni. 2016.

- [12] Minh N. Do, 2019[online]. Department of Electrical and Computer Engineering University of Illinois at Urbana-Champaign. [Cit. 17.5.2019] Dostupné z: <http://minhdo.ece.illinois.edu>
- [13] Yoichi Tomioka, Yuya Ito, Hitoshi Kitazawa. *Pairwise Magnitude Relations of Clustered Sensor Pattern Noise*. 2013.
- [14] Yongjian Hu, Chang-Tsun Li, Xufeng Lin, Bei-bei Liu. *An Improved Algorithm for Camera Model Identification Using Interchannel Demosaicking Traces*. UK, China. Department of Computer Science, University of Warwick, School of Electronic and Information Engineering, South China University of Technology. 2012.
- [15] Yongjian Hu, Chao Jian, Chang-Tsun Li. *Using Improved Imaging Sensor Pattern Noise for Source Camera Identification*. China. School of Electronics and Information, Dalian University of Technology. 2009.
- [16] Yue Tan, Bo Wang, Meijuan Zhao, Xiangwei Kong, Ming Li. *Patch-Based Sensor Pattern Noise for Camera Source Identification*. Dalian, Liaoning. School of Information and Communication Engineering, Dalian University of Technology. 2015.
- [17] Zhonghai Deng, Arjan Gijsenij, Jingzuan Zhang. *Source Camera Identification Usins Auto-White Balance Aproximation*. Tuscaloosa USA, Netherlands. University of Alabama, University of Amsterdam. 2011.

Příloha A

Algoritmy

Jednotlivé implementované funkce a soubory pro Matlab jsou přiloženy na DVD1.

Příloha B

Databáze fotek

Vytvořená databáze fotek z různých fotoaparátů je přiložená celkem na čtyřech DVD - DVD1, DVD2, DVD3 a DVD4. Nebo je dostupná také z cloudového uložení na adrese <https://drive.google.com/drive/u/1/folders/1K0EtVMSzTxFLRkvUUqOFqHRsV0MP9fdz>.