


**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**  
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH  
TECHNOLOGIÍ**

**ÚSTAV AUTOMATIZACE A MĚŘICÍ TECHNIKY**

**FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION  
DEPARTMENT OF CONTROL AND INSTRUMENTATION**

# **METODY DETEKCE A ROZPOZNÁNÍ OBLIČEJE V OBRAZE**

**FACE DETECTION AND RECOGNITION METHODS**

**DIPLOMOVÁ PRÁCE**  
MASTER'S THESIS


**AUTOR PRÁCE**  
AUTHOR

**Bc. Miroslav Zbranek**

**VEDOUČÍ PRÁCE**  
SUPERVISOR

**Ing. Peter Honec, PhD**

**BRNO 2012**



VYSOKÉ UČENÍ  
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky  
a komunikačních technologií

Ústav automatizace a měřicí techniky

# Diplomová práce

magisterský navazující studijní obor  
**Kybernetika, automatizace a měření**

**Student:** Bc. Miroslav Zbranek

**ID:** 106891

**Ročník:** 2

**Akademický rok:** 2011/2012

**NÁZEV TÉMATU:**

## Metody detekce a rozpoznání obličeje v obrazu

### POKYNY PRO VYPRACOVÁNÍ:

Cílem práce je navrhnout metodu pro detekci a rozpoznání obličeje v obrazu, optimalizovat funkci klasifikátoru vzhledem ke spolehlivosti rozpoznání, optimalizovat (předzpracovat) vstupní obraz. Veškeré práce provádějte s ohledem na plánovaný model využití - vstupní systém.

### DOPORUČENÁ LITERATURA:

Hlaváč, Šonka, Počítačové vidění.

Šonka, Hlávač, Boyle - IMAGE PROCESSING, ANALYSIS, AND MACHINE VISION,

**Termín zadání:** 6.2.2012

**Termín odevzdání:** 21.5.2012

**Vedoucí práce:** Ing. Peter Honec, Ph.D.

**Konzultanti diplomové práce:**

**doc. Ing. Václav Jirsík, CSc.**

*Předseda oborové rady*

### UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

## **Abstrakt**

Cílem této diplomové práce je prostudování metod pro detekci a rozpoznání obličeje v obrazu. Na základě prostudování odborné literatury bude zvolena metoda pro detekci obličeje a metoda pro rozpoznání obličeje. Obě metody budou implementovány za pomoci knihovny OpenCV a programovacího jazyku C/C++. Výsledkem práce je vytvoření grafického rozhraní, které využívá naprogramovaných funkcí pro detekci a rozpoznání obličeje jak z obrazu tak i kamery.

## **Klíčová slova**

Detekce, Rozpoznání, Obličej, Viola Jones, Local Binary Pattern, Světelná normalizace, OpenCV

## **Abstrakt**

The aim of this diploma thesis is to explore methods of face detection and recognition in the picture. The method for face detection and the method for face recognition will be chosen according to literature survey. Both methods will be implemented using the OpenCV library and a program language C/C++. The result of this project is creation of graphic interface which use programmed function for face detection and recognition from a picture and also a camcorder.

## **Keywords**

Detection, Recognition, Face, Viola Jones, Local Binary Pattern, Illumination normalization, OpenCV

### **Bibliografická citace:**

ZBRANEK, M. *Metody detekce a rozpoznání obličeje v obrazu*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2012. 66s. Vedoucí diplomové práce byl Ing. Peter Honec, Ph.D.

## **PROHLÁŠENÍ**

Prohlašuji, že svou diplomovou práci na téma **METODY DETEKCE A ROZPOZNÁNÍ OBLIČEJE V OBRAZU** jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne **21. května 2012**

.....

podpis

## **Poděkování**

Děkuji vedoucímu diplomové práce Ing. Peteru Honcovi, Ph.D. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne: **21. května 2012**

.....  
podpis autora

# OBSAH

1	Úvod .....	11
2	Základní pojmy .....	12
2.1	Obličej .....	13
2.2	Řetězec zpracování obrazu .....	14
2.2.1	Předzpracování obrazu .....	14
2.2.2	Segmentace obrazu .....	15
3	Metody Detekce obličeje .....	16
3.1	Rozdělení metod detekce obličeje .....	16
3.2	Detekce založená na barvě kůže .....	17
3.2.1	Model RGB .....	17
3.2.2	Model YCbCr .....	18
3.2.3	Model HSV .....	18
3.2.4	Active Shape Model .....	20
3.2.5	Viola-Jones detektor .....	21
3.3	Neuronové sítě .....	24
3.4	Sledování obličeje .....	26
3.5	Srovnání metod detekce obličeje .....	27
4	Rozpoznávání obličeje .....	28
4.1	Rozdělení metod rozpoznání obličeje .....	28
4.2	Principal Component Analysis .....	28
4.3	Elastic bunch graph matching .....	30
4.4	Local Binary Pattern .....	31
5	Realizace detekce obličeje .....	33
5.1	Knihovna OpenCV .....	33
5.2	Volba snímací roviny .....	33
5.3	Implementace Viola Jones detektoru .....	34
5.4	Trénování kaskády klasifikátorů .....	35
5.5	Předzpracování obrazu u detekce obličeje .....	36
5.6	Metoda pro detekci obličeje .....	37
5.6.1	Změna velikosti obličeje .....	37
6	Realizace rozpoznání obličeje .....	38
6.1	Předzpracování obrazu – světelná normalizace .....	38
6.1.1	Gama korekce .....	38
6.1.2	Rozdíl gaussovských rozostření .....	38
6.2	Metoda pro rozpoznání obličeje .....	40
6.2.1	Srovnávání histogramu .....	41
6.3	Databáze .....	42

7	Demonstrační aplikace .....	43
7.1	Popis aplikace.....	43
7.2	Struktura programu .....	47
7.3	Vývojový diagram aplikace .....	48
8	Interpretace výsledků.....	49
8.1	Pootočení obličeje .....	51
8.2	Závislost rozpoznání na typu masky .....	52
8.3	Závislost rozpoznání na pootočení .....	53
9	Závěr.....	54
10	Seznam použité literatury .....	56
	Seznam použitých zkratk a symbolů .....	60
	Seznam příloh.....	61



# SEZNAM OBRÁZKŮ

Obr. 1 Zjednodušený diagram detekce a rozpoznání obličeje .....	12
Obr. 2 Definice obličeje: a) dobře detekovatelný obličej, b) a c) nevhodné zachycení obličeje.....	13
Obr. 3 Příklady osově invariantnosti .....	13
Obr. 4 Řetězec zpracování obrazu [2] .....	14
Obr. 5 Reprezentace barevného modelu HSV a HSL [8] .....	19
Obr. 6 Rozložení bodů ASM[10].....	21
Obr. 7 Vstupní obraz (vlevo) a integrální obraz(vpravo) .....	22
Obr. 8 Využití integrálního obrazu .....	22
Obr. 9 Výpočet integrálního obrazu .....	22
Obr. 10 Příklady základních Haarových příznaků .....	23
Obr. 11 Kaskáda klasifikátorů .....	24
Obr. 12 Schéma neuronu .....	24
Obr. 13 Neuronová síť [12] .....	25
Obr. 14 Sledování obličeje v souřadnicích [13] .....	26
Obr. 15 Příklad ROC křivky[15] .....	27
Obr. 16 Příklad 25 snímků eigenfaces [18] .....	29
Obr. 17 Zobrazení kombinace projekční verze a vstupního obrazu při $\alpha = 0,25$ [19].	29
Obr. 18 a) Gaborovy filtry a příslušné jets, b) 2D mřížka obličeje [21].....	30
Obr. 19 LBP kružnicové uspořádání (8,1), (16,2) a (8,2) [24] .....	32
Obr. 20 Rozdělení obrazu do bloků a spojení jednotlivých histogramů po aplikaci LBP [23].....	32
Obr. 21 princip výpočtu potočené obdélníkové oblasti o $45^\circ$ [25].....	34
Obr. 22 Ekvalizace histogramu, vlevo vstupní obraz, vpravo obraz po ekvalizaci .....	36
Obr. 23 Světelná normalizace u dvou rozdílně nasvícených scén .....	39
Obr. 24 Výpočet LBP (vstupní obraz vlevo, vypočtený LBP vpravo).....	40
Obr. 25 Rozdělení obličeje do bloků a ukázka masky .....	40
Obr. 26 Vzhled GUI.....	43
Obr. 27 Ukázka online detekce a rozpoznání .....	45
Obr. 28 Zobrazení detekovaného obličeje a odpovídající obličej z databáze spolu se jménem a vzdáleností histogramů.....	47
Obr. 29 Struktura programu .....	47
Obr. 30 Vývojový diagram aplikace.....	48
Obr. 31 Příklad rozmanitosti BioID databáze.....	49
Obr. 32 Potočené obrazy z FEI databáze (horní řada $-40^\circ, -30^\circ, -20^\circ, -10^\circ$ , dolní řada $10^\circ, 20^\circ, 30^\circ, 40^\circ$ ).....	51
Obr. 33 Příklady testovaných masek .....	52

## SEZNAM TABULEK

Tab. 1 Převod z RGB do HSV .....	19
Tab. 2 Výkonnost klasifikátoru bez předzpracování .....	49
Tab. 3 Výkonnost klasifikátoru s předzpracováním .....	50
Tab. 4 Výkonnost klasifikátoru v závislosti na rotaci okolo osy Y FEI.....	51
Tab. 5 Výkonnost klasifikátoru v závislosti na rotaci okolo osy Y GTAV .....	51
Tab. 6 Závislost úspěšnosti rozpoznávání na volbě masky GTAV .....	52
Tab. 7 Závislost úspěšnosti rozpoznávání na volbě masky FEI .....	53
Tab. 8 Závislost úspěšnosti rozpoznávání při rotaci okolo osy Y .....	53

# 1 ÚVOD

Nasazování kamery jako snímacího prvku je v dnešní době využito v mnoha aplikacích. Pomocí kamery a následného zpracování obrazu dostáváme systém, který je schopen měřit, detekovat, rozpoznávat a provádět další operace za pomoci zpracování obrazu.

Tématem této diplomové práce je detekce a rozpoznání obličeje v obraze. Detekce obličeje není pro člověka složitým úkolem. Aby byla výpočetní jednotka schopna automatické detekce obličeje je nutno jej popsat vhodným způsobem pro následnou algoritmicizaci hledání. U detekce hledáme tedy prvek množiny (prvek reprezentuje obličej), která v rámci své množiny vykazuje velkou variabilitu. Rozpoznáním obličejů hledáme největší shodu nového prvku množiny se stávajícími.

Na začátku teoretické části je ujasnění základních pojmů nezbytných pro oblast počítačového vidění a detekce obličeje. V následujících kapitolách bude proveden literární průzkum metod pro detekci a rozpoznání. Vybrané metody dále budou detailněji představeny.

V praktické části budou zvoleny metody, které budou následně implementovány v knihovně počítačového vidění OpenCV s využitím programovacího jazyka C/C++. Vlastnosti implementovaných metod jsou závislé na podmínkách, v nichž je vstupní obraz pořízen. V praxi nelze pokaždé dodržet konstantní osvětlení spolu s homogenním pozadím. Důležitým faktorem pro každou metodu je volba vhodných technik předzpracování obrazu, které povedou k zvýšení jejich výkonnosti.

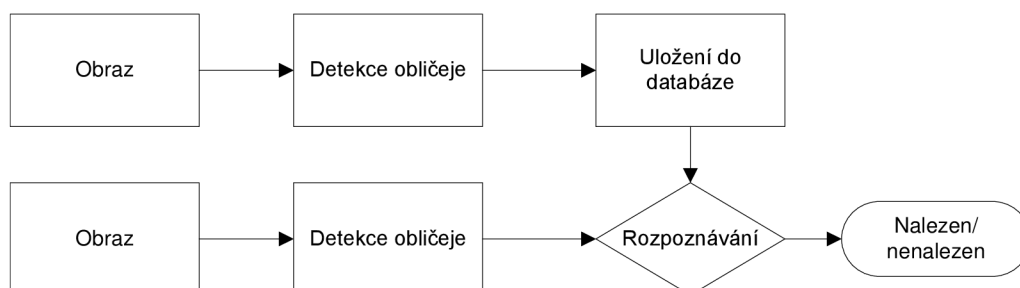
Závěrečným bodem praktické části, bude vytvoření grafického uživatelského rozhraní pro demonstraci implementovaných metod. V souvislosti se zjištěním výkonnosti jednotlivých metod, je potřeba zajistit obličejové galerie, na kterých je v závěru práce testována přesnost v závislosti na různých faktorech nastavení klasifikátoru anebo vlastnostech scény.

## 2 ZÁKLADNÍ POJMY

Detekce a rozpoznávání obličeje je vědní disciplínou počítačového vidění a zpracování obrazu. V současné době se jedná o velmi diskutované téma, na kterém se podílí mnoho vědeckých pracovníků v univerzitách po celém světě. Tato disciplína nachází uplatnění v široké škále aplikacích. Může se jednat o kriminalistiku, kde je používána pro identifikaci a verifikaci obličejů zájmových osob, bezpečnostní aplikace – přístup k aktivům na základě verifikace obličeje. Některé sociální sítě rovněž obsahují automatické rozpoznávání obličejů na fotografiích. Jednou z oblastí, kde se s detekcí obličeje lze setkat jsou multimédia: fotoaparáty, herní konzole, mobilní telefony a další.

Na první pohled se může pojem detekce a rozpoznání obličeje jevit jako tentýž. Detekce obličeje spadá v počítačovém vidění do skupiny detekcí objektů. Pod pojmem detekce obličeje rozumíme nalezení hranice obličeje popřípadě více obličejů na vstupním obrázku. Po správné detekci je možno uložit obličej do databáze.


Následným krokem je rozpoznání. Při rozpoznávání rovněž detekujeme obličej a následně ho porovnáváme s obličejovou databází a vyhodnocujeme procentuální shodu nově nalezeného obličeje s obličejovou databází. Výsledkem je zobrazení obličeje z databáze, u kterého byla naleznuta nejvyšší procentuální shoda s nově detekovaným.



Obr. 1 Zjednodušený diagram detekce a rozpoznání obličeje

## 2.1 Obličej

Prvním krokem než přistoupíme k samotné detekci obličeje, je potřeba definovat, co v realizaci našeho systému budeme považovat za obraz obličeje. Vzhledem k naší aplikaci není potřeba obličej zkoumat detailně z biologického hlediska. Obličej tedy budeme specifikovat jako obdélníkovou oblast, v němž za předpokladu zdravého jedince budou obsaženy obě oči, nos, ústa a rovněž výřez obličeje musí obsahovat co nejvíce relevantní informace, která je následně důležitá pro rozpoznávání obličeje. [1]



Obr. 2 Definice obličeje: a) dobře detekovatelný obličej, b) a c) nevhodné zachycení obličeje

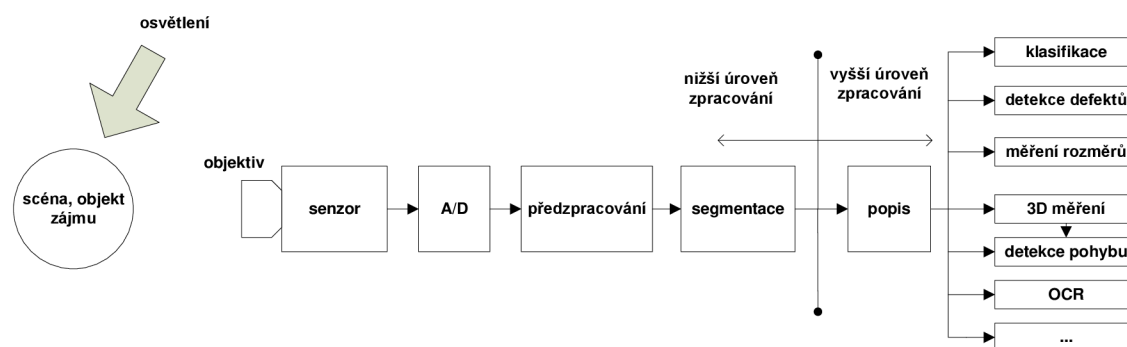
Detekce obličeje je možná i mimo čelní rovinu ( frontal face ). Čelní rovina je však nejlepší možností pro následné rozpoznávání. Se zvětšujícím se vzdálením od čelní roviny klesá i přesnost rozpoznávání.



Obr. 3 Příklady osové invariančnosti

## 2.2 Řetězec zpracování obrazu

Řetězec zpracování obrazu je zobecněný postup pro získání potřebné informace z obrazu. Skládá se z několika po sobě jdoucích akcí. První akcí před samotnou činností detekce obličeje je pořízení vstupního obrazu. Pořízení obrazu je závislé na typu scény – pozadí, osvětlení a aparatuře, kterou ji zachycujeme. V ideálním případě by scéna měla mít dobré osvětlení a objekt zájmu (v našem případě obličej) by byl umístěn před homogenním pozadím.



Obr. 4 Řetězec zpracování obrazu [2]

Po digitalizaci A/D převodníkem získáváme digitální obraz zkoumané scény ovlivněný všemi fyzikálními aspekty snímání scény, jako je osvětlení objektu zájmu, optická soustava, senzor atd. S těmito daty je možné dále pracovat v oblasti zpracování obrazu.

### 2.2.1 Předzpracování obrazu

Předzpracování obrazu je technika úpravy pořizovaného obrazu. Důvod nutnosti předzpracování spočívá v nedokonalosti pořízení vstupního obrazu. Je téměř nemožné pořídít obraz bez šumu, rušení i při optimálních světelných podmínkách. Obecně lze říci, že předzpracování obrazu je tvořeno určitým postupem kroků sloužících pro zkvalitnění obrazu, aby mohlo dále dojít k vyhodnocení jeho informace.[4]

Nejčastější kroky předzpracování obrazu které mohou pomoci k potlačení některých negativních vlastností pořizovaného obrazu jsou:

- odstranění šumu,
  - lineární filtry,
  - nelineární filtry,
  - gaussův filtr,
  - průměrování,
- zaostření obrazu,
- rekonstrukce obrazu,
- odstranění zkreslení,
- jasová korekce,

- transformace jasové stupnice,
- vyhlazení obrazu,
- filtrace obrazu v kmitočtové oblasti,
- restaurace obrazu.

Zde je uveden výčet technik, které se dají zařadit do třídy předzpracování obrazu. Použití se odvíjí od typu dané aplikace, kterou se chystáme realizovat.

## 2.2.2 Segmentace obrazu

Segmentace obrazu je další skupinou metod, které se snaží oddělit objekty od pozadí a analyzovat obsah obrazu. Výsledkem segmentace je většinou soubor vzájemně se nepřekrývající oblasti. Z těchto údajů lze usoudit, že segmentace vychází ze znalosti obrazu – barvy, tvaru, polohy a dalších. Důležitým faktorem v této oblasti je složitost scény, překrývání objektů a nerovnoměrné osvětlení.

Přehled používaných metod[3]:

- segmentace prahováním,
  - prosté,
  - s více prahy,
  - adaptivní,
- hybridní metody,
  - neuronové sítě,
  - morfologické operace,
  - amplitudová projekce,
- znalostní metody – srovnávání se vzorem,
- metody orientované na regiony,
  - štěpení oblastí,
  - spojování oblastí,
  - shluková analýza,
- metody vycházející z detekce hran,
  - houghova transformace,
  - sledování hranice,
  - aktivní kontury.

Metody vyšší úrovně zpracování obrazu jsou závislé na konkrétní úloze a proto je nelze nějak obecněji popsat.

## 3 METODY DETEKCE OBLIČEJE

### 3.1 Rozdělení metod detekce obličeje

#### Znalostní metody

Využívají charakteristických pravidel pro lidský obličej. Při zkoumání obličeje můžeme určit fyzikálně - biologické vlastnosti mezi oblastmi obličeje. Jedná se například o relativní vzdálenost mezi očima, které jsou symetrické vzhledem k nosu a ústům. Metoda tedy zahrnuje detekci nejenom obličeje, ale i jeho částí a je vhodná pouze pro čelní snímání. Už při malém natočení obličeje může selhávat. Nevýhodou je velké množství falešných poplachů a nejednoznačné popsání obličeje. [5]

#### Invariantní rysy

Základním kamenem metod, založených na neměnných rysech je skutečnost, že člověk je schopen rychle rozpoznat lidskou tvář. V tomto případě musí lidský obličej obsahovat charakteristické rysy, které jsou stejné pro všechny ostatní obličeje. Obličejovými rysy jsou hrany, barva, intenzita, textura. Z výčtu uvedených rysů vyplývá, že metoda je velmi citlivá na osvětlení a šum v obraze. Náročná je také detekce rysů ve složitém pozadí. [5]

#### Srovnání se vzorem

Metoda porovnává kandidáty na obličeje s databází obličejových šablon nebo šablon části obličejů, která musí být předem vytvořena. Jedná se o metodu s jednoduchou implementací, avšak velmi časově náročnou při procházení celých databází.

Techniku lze rovněž použít i v obráceném pořadí a to pro rozpoznávání obličejů. U této metody se zavádí jistá míra odlišnosti od vstupního obrazu a od šablony, jelikož nikdy nemůže dojít k úplné shodě (pokud neporovnáváme dva totožné obrazy).

#### Metody založené na vzhledu

Do této skupiny patří všechny metody, u kterých je model obličeje vytvořen učením neboli trénováním algoritmu na trénovací množině. Tyto modely označujeme jako klasifikátory.

Výčet metod založených na vzhledu v originálním znění:

- neuronové sítě,
- principal component analysis, factor analysis,
- support vector machine,
- hidden markov model,
- sparse network of windows (SNoW),
- viola jones detector,



- distribution – based model,
- inductive learning C4.5,
- naive bayes classifier,
- kullback relative information.

V této kapitole bylo uvedeno rozdělení metod podle přístupu, s jakým řeší problém detekce obličeje. Obecně existuje velké množství metod a jejich modifikací. V následujících kapitolách budou popsány základní techniky detekce obličeje.

## 3.2 Detekce založená na barvě kůže

Často používaná metoda, zejména kvůli své jednoduchosti, která využívá specifické vlastnosti barvy lidské kůže. Za určitých světelných podmínek nemění barva kůže svoje vlastnosti. Pořízením obrazu obličeje u různých druhů snímacího zařízení vyvolávat různé výsledky, přestože původní scéna a její osvětlení zůstává neměnná. Tyto problémy nesmí být opomenuty, pokud chceme dosáhnout co největší robustnosti aplikace. Je proto nutné věnovat pozornost i samotnému pořízení obrazu, např. vyhnout se vinětami objektivu a snímacího prvku, „blikání“ obrazu způsobenému nestálostí osvětlení atd. Pro snazší zpracování je výhodné převedení obrazu (nejčastěji pořízeného v RGB) do jiného barevného modelu. Pro detekci kůže je potřeba odseparovat obličej od ostatních částí těla. K separaci je možné použít poměr výšky a šířky hlavy. Jedná se o invariální metodu. Dalšími rysy mohou být vzájemná poloha očí, úst, obočí.

### 3.2.1 Model RGB

Pravděpodobně nejrozšířenější barevný model obsahující tři složky (R - red (červená), G - green (zelená), B - blue (modrá)). Barvy lze vyjádřit barevným vektorem, jejíž složky vektoru nabývají hodnot z intervalu nebo  $\langle 0, 255 \rangle$  nebo dle barevné hloubky. V případě 24-bitové barevné hloubky lze tedy každý bod obrazu (pixel) vyjádřit za pomoci 3 bytů. Počet barevných odstínů je v této rozlišovací schopnosti roven:  $256^3 = 16\,777\,216$ .

Nevýhodou barevného prostoru RGB je fakt, že změna osvětlení se projeví ve všech složkách. V obrazu pořízeném za denního světla lze detekovat kůži pomocí následujících prahů.[6]

$$\begin{aligned}
 &R > 95, G > 40, B > 20 \\
 &\max\{R, G, B\} - \min\{R, G, B\} < 15 \\
 &|R - G| > 15, R > G, R > B
 \end{aligned}
 \tag{1}$$

U umělého osvětlení platí následující pravidla:

$$\begin{aligned} R > 220, G > 210, B > 170 \\ |R - G| \leq 15, R > B, G > B \end{aligned} \quad (2)$$

Pro některé výpočty se používá normalizovaný RGB model. Převod do normalizovaného RGB modelu je pomocí následujících vzorců [7]:

$$r = \frac{R}{R + G + B}, g = \frac{G}{R + G + B}, b = \frac{B}{R + G + B} \quad (3)$$

U normalizovaného modelu RGB je kůže definována v rozmezí:

$$\begin{aligned} \frac{r}{g} > 1.185, \quad \frac{r * b}{(r + g + b)^2} > 0.107 \\ \text{and } \frac{r * g}{(r + g + b)^2} > 0.112 \end{aligned} \quad (4)$$

### 3.2.2 Model YCbCr

Jedná se o model, který nevyjadřuje jednotlivé složky barev jako model RGB. Y zobrazuje světelnost, Cb představuje chrominanci signál modré barvy a Cr je chrominanci signál červené barvy. Pro převod z RGB do YCbCr modelu se užívají vztahy závislé na rozlišovací schopnosti původního obrazu. Podle standartu CCIR- 601 se užije následujících vztahů:

$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ -0.1687 & -0.3313 & 0.5 \\ 0.5 & -0.0418 & 0.0813 \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (5)$$

Detekce kůže v tomto modelu se provádí pouze v chromatických složkách, pro přepočít lze použít pouze těchto zjednodušených vztahů:

$$Cb = 0.5643(B - Y), Cr = 0.7133(R - Y) \quad (6)$$


Pro převod na rozmezí hodnot 0-255 je potřeba připočít konstanty.

Hodnota kůže by se v tomto modelu měla nacházet v rozmezí[6]:

$$\begin{aligned} 77 \leq Cb \leq 127 \\ 133 \leq Cr \leq 173 \end{aligned} \quad (7)$$

### 3.2.3 Model HSV

HSV barevný model se nejvíce podobá lidskému chápání barev. Opět se skládá ze tří složek. (Hue-odstín, Saturation-nasycení, Value-hodnota).[7] Grafické vyjádření je v podobě šestibokého jehlanu. Vrchol jehlanu představuje černou barvu a střed podstavy bílou. Nasycení odpovídá vzdálenosti od osy jehlanu. Dominantní barvy s nasycením rovno 1 leží na plášti jehlanu.



Obr. 5 Repräsentace barevného modelu HSV a HSL [8]

Převod z barevného prostoru RGB do HSV je definován následující tabulkou:

	Výsledná hodnota	podmínka
H	<i>Nedefinována, (0)</i>	$max=min$
	$60^\circ * (G-B) / (max-min)$	$max=R$ a $G \geq B$
	$60^\circ * (G-B) / (max-min) + 360^\circ$	$max=R$ a $G < B$
	$60^\circ * (G-B) / (max-min) + 120^\circ$	$max=G$
	$60^\circ * (G-B) / (max-min) + 240^\circ$	$max=B$
S	0	$max=0$
	$1-min/max$	$max \neq 0$
V	$max$	

Tab. 1 Převod z RGB do HSV

Převodní tabulky platí pro hodnoty  $r, g, b$  v intervalu  $\langle 0,1 \rangle$ . Veličina  $max$  je největší hodnota z  $r, g, b$ ,  $min$  naopak ta nejmenší.

V barevném prostředí HSV lze detekovat kůži dle následujících prahů:

$$\begin{aligned}
 &V \geq 40, \quad 0.2 < S < 0.6 \\
 &0^\circ < H < 25^\circ \text{ nebo } 335^\circ < H < 360^\circ
 \end{aligned} \tag{8}$$

Další možností je použití následujících pravidel:

$$\begin{aligned}
 &V \geq 40 \\
 &H \leq (-0.4V + 75) \\
 &10 \leq S \leq (-H - 0.1V + 110)
 \end{aligned} \tag{9}$$

$$\text{pokud } H \geq 0 \quad \text{pak } S \leq (0.08(100 - V)H + 0.5V)$$

$$\text{pokud } H < 0 \quad \text{pak } S \leq (0.5H + 35)$$

Všechny uvedené prahy a podmínky pro detekci kůže jsou přibližné a jsou heuristicky určeny. Problémem této metody je, že se jedná o obyčejné prahování, které při různých světelných podmínkách selhává. Další poznámkou je nutno dodat, že se detekuje pouze

kůže. Pro vybrání obličej je potřeba vybrat oblasti, které svým tvarem nebo např. poměrem šířka/výška mohou odpovídat velikosti obličej. [6]

### 3.2.3.1 Detekce očí

Detekce očí nemusí být nutně uplatňována jen při použití znalostní metody, ale může být nápomocná i při jiných metodách. K detekci očí můžeme využít hodnot maxim histogramu pro obě osy aplikovaného na gradient původního obrazu.

Další metodou může být použití mapy očí vztaženého k modelu YCbCr. Mapu očí popisují následující vzorce [9]:

$$EyeMapL = \frac{Y(x, y) \oplus g_{\sigma}(x, y)}{Y(x, y) \ominus g_{\sigma}(x, y) + 1} \text{ kde } g_{\sigma}(x, y) = \begin{cases} |\sigma| \cdot \left( \left| 1 - \left( \frac{R(x, y)}{\sigma} \right)^2 \right|^{1/2} - 1 \right) & R \leq |\sigma| \\ -\infty & R > |\sigma| \end{cases}$$

$$R(x, y) = \sqrt{x^2 + y^2}$$

$$EyeMapC = \frac{1}{3} \left\{ C_b^2 + \tilde{C}_r^2 + \frac{C_b}{C_r} \right\} \text{ kde } \tilde{C}_r : \text{ je negace } C_r \quad (10)$$

### 3.2.4 Active Shape Model

Jedná se v podstatě o metodu, která využívá srovnání se vzorem. V tomto případě je model reprezentován skupinou významných bodů (*landmarks*), které jsou ručně získávány z trénovacích dat. Umístění bodů je závislé na aplikaci. V případě detekce obličej jsou to body umístěny na obličej. *Landmarks* musí být významné body, tedy takové body, které nesou důležitou informaci. Takovými body jsou hrany nebo rohy.

Příklad rozložení bodů je na Obr. 6. Spojnice mezi body slouží pouze pro ilustraci.

Pokud vezmeme významné body jako vektor, přičemž body mezi sebou budou vztaženy invariantním způsobem, lze vyjádřit průměrný model tvaru z množiny trénovacích dat zarovnáním pomocí transformace podobnosti (*similarity transformation*).


Transformace určuje rotaci o úhel  $\theta$ , změnu měřítka  $s$  (*scale*) a translaci o  $(x_p, y_p)$ .

$$T \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} x_p \\ y_p \end{pmatrix} + \begin{pmatrix} s * \cos\theta & s * \sin\theta \\ -s * \sin\theta & s * \cos\theta \end{pmatrix} * \begin{pmatrix} x \\ y \end{pmatrix} \quad (11)$$

Pro uchování variace u všech modelů trénovacích vzorů, je statický model vyjádřen  $x'$  pomocí průměrného modelu  $\bar{x}$ , matice vlastních vektorů  $\Phi$ , a vektoru parametrů deformačního modelu  $b$ :

$$x' = \bar{x} + \Phi * b \quad (12)$$

Tímto vztahem lze určit libovolný model, z trénovacích dat za pomoci vektoru  $b$  a rotaci nebo posunutí pomocí výše uvedené rovnice.



Obr. 6 Rozložení bodů ASM[10]

Algoritmus ASM se skládá ze dvou iteračních kroků. V prvním se v okolí významných bodů určí jejich nejpravděpodobnější pozice a v druhém kroku se modifikují pozice bodů. Následující kroky se opakují, dokud nedojde k co nejmenší konvergenci. Z uvedeného vyplývá, že nedokonalostí tohoto algoritmu je nutnost dostatečně přesně umístit počáteční model. Rovněž velký počet významných bodů zvyšuje variabilitu všech možných tvarů a velký počet celkových iteračních kroků.

### 3.2.5 Viola-Jones detektor

Viola a Jones vymysleli techniku pro rychlou detekci v podstatě jakéhokoli objektu. Základním principem Viola Jones detektoru je pocházení obrazu pomocí malých podoken, které jsou schopny detekovat hledaný objekt, v našem případě obličej. Podokna, kterými je vstupní obraz procházen, mění svoji velikost, z čehož vyplývá, že výpočet pro různě velké podokna by byl různý. Aby došlo k rychlejší detekci a aby nebyla detekce ovlivněna velikostí podokna je každý obraz převeden na integrální obraz.[11]

- **Integrální obraz** – jedná se o sumu malých podobrazů. Detektor aplikuje výpočet integrálního obrazu aplikovaného na Haarových vlnkách pomocí následujícího vzorce:

$$ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y') \quad (13)$$

kde  $ii(x, y)$  je integrální obraz pro daný pixel


$i(x', y')$  je původní obraz

1	1	1
1	1	1
1	1	1

1	2	3
2	4	6
3	6	9

**Obr. 7 Vstupní obraz (vlevo) a integrální obraz(vpravo)**

Obr. 7 Vstupní obraz (vlevo) a integrální obraz(vpravo)Obr. 7 ukazuje, že výsledný pixel je suma pixelů, jejichž poloha je nalevo a nad vybraným pixelem. Využití integrálního obrazce k výpočtu sumy všech obdélníkových oblastí je nesmírně efektivní. Příklad je uveden na následujícím obrázku.



**Obr. 8 Využití integrálního obrazu**

Suma pixelů v původním obraze ohraničeného červenými body (D) se vypočítá:

$$D = (x_4, y_4) - (x_3, y_3) - (x_2, y_2) + (x_1, y_1) \quad (14)$$

V konkrétním případě vypadá výpočet následovně:

1	1	1
1	1	1
1	1	1


1	2	3
2	4	6
3	6	9

**Obr. 9 Výpočet integrálního obrazu**

$$D = (x_4, y_4) - (x_3, y_3) - (x_2, y_2) + (x_1, y_1) = 9 - 3 - 3 + 1 = 4$$

Při použití integrálního obrazu je vidět, že pro vypočítání sumy pixelů jakkoli velkého obrazce nám stačí pouze čtyři hodnoty.

VJ detektor trénuje vstupní obraz pomocí Haar funkcí.



Obr. 10 Příklady základních Haarových příznaků

Pro každé podokno se vypočte výsledná hodnota jako rozdíl sumy hodnot černých obdélníků mínus suma pixelů hodnot bílých obdélníků.

- **AdaBoost-** (Adaptive Boosting). Boosting je metoda k nalezení silného klasifikátoru za pomoci slabých klasifikátorů.

AdaBoost spojuje několik klasifikátorů s relativně špatnou úspěšností (slabých) klasifikátorů do jednoho silného klasifikátoru, který je úspěšnější než kterýkoli z oněch slabých klasifikátorů. U slabého klasifikátoru máme pouze jeden požadavek, aby byla chyba menší než 0,5.

Algoritmus AdaBoost:

Vstup  $(x_1, y_1) \dots (x_m, y_m)$

$x_i \in X, y_i \in \{-1, 1\}$

Inicializace vah  $D_1(i) = \frac{1}{m}$

For  $t = 1:T$

1) Find  $h_t = \operatorname{argmin} \varepsilon_j$

$$\text{kde } \varepsilon_j = \sum_{i=1}^m D_t(i) I[y_i \neq h_j(x_i)]$$

2) pokud  $\varepsilon_t \geq 0,5$  potom stop

3)  $\alpha_t = \frac{1}{2} \log\left(\frac{1 - \varepsilon_t}{\varepsilon_t}\right)$

4) Aktualizace vah

$$D_{t+1}(i) = \frac{D_t(i) \exp(-\alpha_t y_i h_t(x_i))}{Z_t}$$

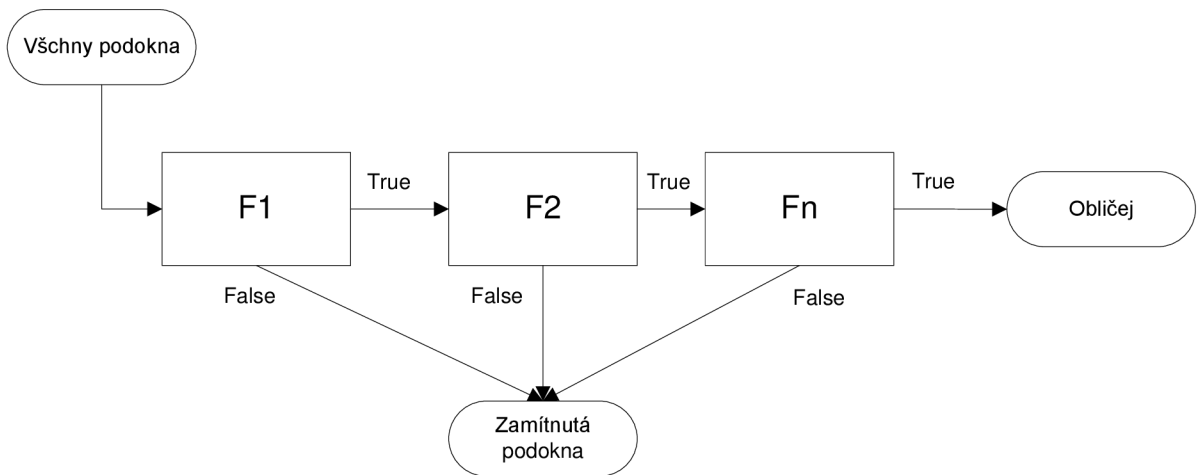
$$\text{kde } Z_t = \sum_{i=1}^m D_t(i) \exp(-\alpha_t y_i h_t(x_i))$$

Výsledný klasifikátor je:  $H(x) = \operatorname{sign}\left(\sum_{t=1}^T \alpha_t h_t(x)\right)$

V kroku 1 se vybere klasifikátor s nejmenší chybou, krok 2 definuje podmínku konvergence algoritmu. Krok 3 je krokem pro optimální predikci. Aktualizace vah,

zvýší váhu u špatně vybraných klasifikátorů a sníží váhu u dobrých. V dalším kroku se hledá klasifikátor, který bude klasifikovat lépe doposud špatné klasifikace měření.


- **Kaskáda klasifikátorů**—množina klasifikátorů, které vznikají při procházení celého obrazu. Jedná se modifikovaný rozhodovací strom, kde každá etapa klasifikátoru je naučena na detekci požadované oblasti zájmu (obličej). Jednotlivé stupně klasifikátoru tedy určují výřezy, které nejsou obličejem a pokračuje se na další stupeň.



Obr. 11 Kaskáda klasifikátorů

### 3.3 Neuronové síť

Neuronové síť jsou síť jednoduchých neuronových procesů uspořádaných do vrstev, které jsou propojeny. Jádrem neuronových sítí je výpočetní jednotka – *neuron*. Ten je inspirován biologickým neuronem nacházejícím se v mozku.




Obr. 12 Schéma neuronu

$$Y = f\left(\sum_{i=1}^N (w_i x_i) + \theta\right) \quad (15)$$



Kde:  $x_i$  – vstupy neuronu,  
 $w_i$  – synaptické váhy,  
 $\theta$  – práh neuronu,  
 $f(x)$  – přenosová funkce neuronu,  
 $Y$  – výstup neuronu.

Existuje mnoho typů přenosových funkcí, mezi základní patří funkce skoková, sigmoidální a hyperbolický tangens. Neurony jsou uspořádány do vrstev. Počet vrstev a počet neuronů v jednotlivých vrstvách se odvíjí od dané aplikace a neexistuje univerzální postup na určení topologie sítě. Bývá ovšem pravidlem, že počet neuronů ve vstupní vrstvě je roven počtu vstupů. V našem případě je to počet všech pixelů trénovacích vzorů (např.: pro trénovací vzory o velikosti 20 x 20 pixelů je počet vstupů roven 400). Na Obr. 13 je uveden příklad, jakou topologii by mohla obsahovat neuronová síť pro detekci obličejů.



Obr. 13 Neuronová síť [12]


Pokud by bylo použito uvedené neuronové sítě pro detekci obličejů, je potřeba projít v obraze všechny výřezy, které odpovídají velikosti trénovacích dat. To by u vstupního obrazu s velkým rozlišením, zapříčinilo velkou dobu prohledávání. Proto se Neuronové sítě kombinují s dalšími technikami, které sníží výpočetní náročnost.

### 3.4 Sledování obličeje

Sledování obličeje vychází z předpokladu již detekované tváře. Sledování umožňuje snížit výpočetní a časové nároky na systém – nemusí být tvář detekována v každém po sobě jdoucím okně. Stačí pouze analyzovat určitou oblast zájmu, které je odvozena z výřezu předchozí nalezené pozice se zvětšením např. 10% pro zachycení jiné polohy tváře.

Nejjednodušší technikou sledování pohybu objektů je porovnání se šablonou. Ve vstupním snímku se hledá nejvíce podobná textura textuře šablony. Úroveň korespondence vstupní oblasti a šablony, lze provádět v barevném obrazu nebo pouze ve vybrané složce. K tomuto účelu slouží vzorec normalizované křížové korelace.

Další technikou je Viola Jones detektor, který má rychlou odezvu ( doba zpracování snímku s rozlišením 640x480 se pohybuje okolo 300ms u P4 2,4GHz). Proto ke snížení časové náročnosti bývá aplikován pouze na menší oblast zájmu. Výše zmíněné dvě techniky detekce jsou vhodné pro translační pohyb obličeje v osách X,Y a Z.



Obr. 14 Sledování obličeje v souřadnicích [13]

Pro sledování obličeje i rotačních pohybů lze využít barvy kůže v barevném modelu HSV, konkrétně ve složce H a následně aplikovat algoritmus *CamShift* (Continuously Adaptive Mean Shift), který využívá histogramu v oblasti barvy kůže. Každý následující snímek jej zpětnou projekcí používá pro modelování pravděpodobnostního rozložení barvy kůže. Vyhodnocení pravděpodobností je založeno na Bayesově zákonu. Jádrem *CamShift* algoritmu je *Mean-shift*. Algoritmus *Mean-Shift* je iterativní a slouží k nalezení lokálního maxima.

Aby došlo k potlačení barvy pozadí podobné jako je lidská kůže, přidává se k metodě ještě adaptivní upravování barvy kůže v modelech *Cb* a *Cr*. Limitní hodnoty barvy kůže jsou uvedeny v kapitolách 3.2.3 a 3.2.2. [13] [14]

### 3.5 Srovnání metod detekce obličeje

Srovnání metod detekce obličeje se odvíjí od požadované aplikace. Nicméně častým ukazatelem je TPR (true positive rate), který určuje procentuální vyhodnocení počtu detekovaných obličejů (TP – true positive) vůči počtu všech obličejů, jenž měly být detekovány. Opačným pojmem k TP je TN( true negativ), tedy správné neoznačení tváře tam, kde není.[15]

Všechny metody detekce obličeje se dopouštějí dvou typů chyb:

- 1) FN (false negatives) – neoznačení tváře v obrazu.
- 2) FP (false positives) – označení oblasti, která není tvář


Vztah mezi TPR, FN a FP lze vyjádřit:

$$TPR = \frac{TP}{\text{celkový počet obličejů}} = \frac{TP}{(TP + FN)} \quad (16)$$

V souvislosti s TPR se uvádí i FPR (false positives rate) počet označených obličejů ke všem obrazům, kde obličej není.

$$FPR = \frac{FP}{\text{celkový počet neobličejů}} = \frac{FP}{(FP + TN)} \quad (17)$$

Závislost mezi TPR a FPR se v praxi vynáší do ROC (receiver operating characteristic ) křivky. Křivka slouží pro vybrání optimálního modelu. Všechny křivky by se měly nacházet od dělicí úhlopříčky vlevo, pak je přesnost klasifikátoru větší než náhodná (> 50%). [15]



Obr. 15 Příklad ROC křivky[15]

Jak bylo zmíněno na začátku kapitoly, porovnávání metod je závislé od aplikace.

Dalšími limitujícími faktory při porovnání může být:

- invariantnost obličeje vůči natočení,
- plocha obličeje,
- světelné podmínky,
- výpočetní a časová náročnost.

## 4 ROZPOZNÁVÁNÍ OBLIČEJE

### 4.1 Rozdělení metod rozpoznání obličeje

**Holistické metody** – metody identifikující a rozpoznávající obličej jako celek. Nevýhodou je špatná funkčnost v případě malého množství trénovacích dat.

Příklady metod: PCA, 2DPCA,  $(PC)^2A$

**Lokální metody** – lokální metody lze rozdělit ještě do dvou skupin:

Metody založené na příznacích - jádrem rozpoznávání u těchto metod je porovnávání grafů. Výhodou těchto metod je nepotřebnost více trénovacích dat jako u holistických metod. Metody:

- DCP – directional corners points
- EBGM – elastic bunch graph matching

Metody založené na vzhledu - tyto metody získávají informace z vymezených regionů. Příznaky jsou extrahovány metodami pro klasifikaci textur.[16] Metody :

- neural network,
- hidden markov model,
- local binary pattern,
- fractal features,
- local probabilistic subspace method.

**Hybridní metody** - tyto metody kombinují dva výše uvedené přístupy. Přínosem těchto metod, by měla být větší přesnost, jelikož poskytují komplexnější popis objektu

### 4.2 Principal Component Analysis

Analýza hlavních komponent (PCA) je holistická technika používaná k rozpoznávání obrazu nebo také ke kompresi. Cílem PCA je snížit dimenzi příznakového prostoru, avšak zachovat informaci. Příznakový subprostor je lineární kombinací původního příznakového prostoru.

Pro rozpoznání obličeje je potřeba obstarat ke každé osobě sadu tváří, které budou následně sloužit jako trénovací data. Všechny obličeje v trénovací množině se za pomoci PCA převedou do vektoru tváří zvaného *eigenfaces*, které reprezentují rozdíl mezi jednotlivými trénovacími vzory. [17]



Obr. 16 Příklad 25 snímků eigenfaces [18]

Pro rozpoznání nové osoby je aplikován rovněž PCA a následně se hledá nejmenší vzdálenost mezi nově vytvořeným vektorem eigenfaces a vektory eigenfaces z databáze. Nevýhodou této metody je nutnost obstarání sady tváří u každé osoby. Tuto nevýhodu odstraňuje rozšíření metody na 2DPCA nebo  $(PC)^2A$ .

Metoda  $(PC)^2A$  vychází z myšlenky předzpracování obrazu na základě intenzity obrazu. [19]. Mějme obraz  $I(x,y)$  o velikosti  $N_1 \times N_2$ , kde  $x \in [1, N_1], y \in [1, N_2]$  a  $I(x,y) \in [0,1]$

Horizontální a vertikální projekce se vypočte:

$$H_P(y) = \sum_{x=1}^{N_1} I(x,y), \quad V_P(x) = \sum_{y=1}^{N_2} I(x,y) \quad (18)$$


Nyní se stanoví projekční mapa:

$$M_P(x,y) = \frac{V_P(x)H_P(y)}{N_1 N_2 \bar{I}} \quad (19)$$

Kde  $\bar{I}$  je průměrná intenzita obrazu.

Posléze se stanoví kombinace projekční verze vstupního obrazu  $I(x,y)$ ,  $\alpha$  je kombinační parametr.

$$I_\alpha(x,y) = \frac{I(x,y) + \alpha M_P(x,y)}{1 + \alpha} \quad (20)$$



Obr. 17 Zobrazení kombinace projekční verze a vstupního obrazu při alfa =0,25 [19]

Z uvedených vzorců lze odvodit následující vlastnosti algoritmu  $(PC)^2A$ :

1. Průměrná intenzita obrazu  $I(x,y)$  je rovna průměrné intenzitě  $M_P(x,y)$ .
2. Pokud  $\alpha \neq -1$  potom je průměrná intenzita obrazu  $I(x,y)$  je rovna průměrné intenzitě  $I_\alpha(x,y)$ .
3. Pokud je  $\alpha = 0$ , pak  $I_\alpha(x,y) = I(x,y)$ .
4. Pokud  $\alpha \rightarrow \infty$ , pak se  $I_\alpha(x,y)$  se blíží  $M_P(x,y)$ .
5. Vnitřní dimenze  $M_P(x,y)$  je menší než  $(N_1 + N_2 - 1)$ .
6. Vnitřní dimenze  $M_P(x,y)$  je mnohokrát menší než  $I(x,y)$ .

Pokud není  $\alpha$  příliš velká, integrací  $M_P(x,y)$  do původního  $I(x,y)$  je vstupní obraz rozmazán, ale zároveň je zachována jeho hlavní informace. Takovéto rozmazání funguje lépe než standardní *eigenfaces*. [19]


### 4.3 Elastic bunch graph matching

Elastic bunch graph matching (EBGM) metoda byla vyvinuta na základě nedodržení invariantnosti vlastností obličeje, polohy obličeje a okolního prostředí.

Prvním krokem k vytvoření grafu je předzpracování obličeje za pomoci Gaborových filtrů. Denis Gabor navrhl sadu biologicky motivovaných filtrů, které při konvoluci zvýrazní obličejové rysy.

Tvář je následně popsána pomocí uzlových bodů označovaných v literatuře jako Jety (*Jets*). Vlastnosti Jetů závisí na počtu frekvencí a orientací. [20]

Příklad Jetů s 5 frekvencemi a 8 orientacemi je uveden na následujícím obrázku:




Obr. 18 a) Gaborovy filtry a příslušné jets, b) 2D mřížka obličeje [21]

Propojením jednotlivých jetů lze vytvořit graf o  $N$  uzlech a  $E$  úsečkách spojující uzly. Úsečky spojující uzly jsou dvourozměrné vektory a vytváří na obličejí 2D mřížku. Pro rozpoznávání obličejů je klíčová podobnost jednotlivých jetů na mřížce. [20]

## 4.4 Local Binary Pattern

Local Binary Pattern (LBP) je jednoduchá a velmi efektivní metoda k popsání vlastností textur. Princip metody spočívá v prahování okolních pixelů pomocí vlastního středového pixelu. Metoda je primárně určena pro šedo-tónové obrazy a díky své jednoduchosti je nasazována v mnoha aplikacích. Výhodou metody je robustnost vůči osvětlení a výpočetní jednoduchost- to umožňuje nasazení v real-time aplikacích. Metoda rovněž vychází z vlastností textur, ty lze popsat pomocí dvojrozměrného prostoru. [22]



Zde je uveden postup prahování, který využívá základní LBP u 8- bitového rozložení. Výsledek nového středového pixelu je určen rovnicí:

$$LBP(x_c, y_c) = \sum_{n=0}^7 s(I_n - I_c) 2^n \quad (21)$$

Kde  $I_c$  je šedo tónová hodnota středového pixelu,  $I_n$  jsou hodnoty okolních 8 pixelů jdoucích ve směru šipky. Funkce  $s$  je definována jako [23]:


$$s(k) = 1 \text{ pokud } k \geq 0$$

$$s(k) = 0 \text{ pokud } k < 0$$

Pokud právě počítaný pixel na okraji obrazu, je potřeba definovat jak bude výpočet probíhat, existují tři možnosti:

- část pixelů mimo obraz se nahradí nulami,
- ohnutí obrazu – pixely mimo obraz jsou nahrazeny pixely na protilehlém okraji,
- výpočet neprobíhá – pixely jsou následně oříznuty.

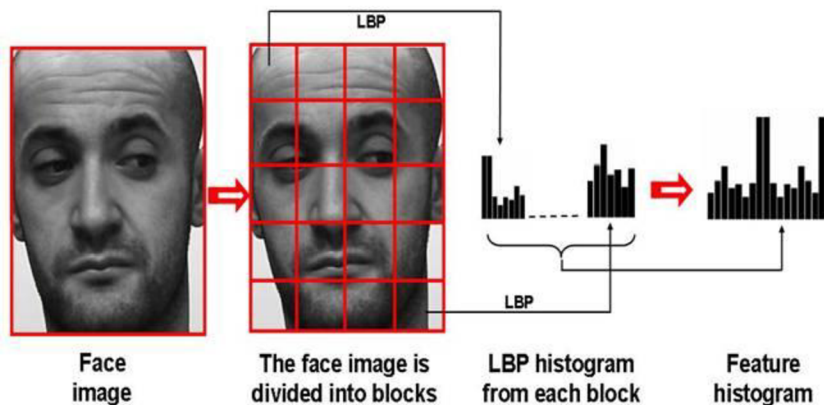
Základní LBP operátor je definován pro 8- okolí se vzdáleností od středu rovnou 1. Další verze LBP operátoru mohou být definována pro různá okolí a vzdálenosti od středového pixelu.



Obr. 19 LBP kružnicové uspořádání (8,1), (16,2) a (8,2) [24]

U ostatních uspořádání označuje LPB => (P,R). P- počet bodů a R- radius. Pokud body neleží ve středu pixelu, za pomoci bilineární interpolace se dopočítávají skutečné hodnoty jednotlivých bodů.

Aby mohlo dojít k využití LBP pro rozpoznávání obličejů, je obličej rozdělen na bloky, z nichž se po každý blok vypočítává histogram, který je následně připojen za ostatní histogramy z jednotlivých bloků. Počet bloků, do kterých se rozdělí obraz, závisí na aplikaci. Používá se dělení na 7x7, 5x5, 4x5 a 3x3 bloků. U bloků je pro zlepšení přesnosti rozpoznání použito ještě váhování.



Obr. 20 Rozdělení obrazu do bloků a spojení jednotlivých histogramů po aplikaci LBP [23]



## 5 REALIZACE DETEKCE OBLIČEJE

### 5.1 Knihovna OpenCV

Výstupem práce má být funkční aplikace, která bude tvořena ve vývojovém prostředí Microsoft Visual Studio 2010 s použitím knihovny OpenCV2.1. OpenCV (Open Source Computer Vision) je knihovna pro akademické a komerční použití. Původně je psána v jazyce C, nyní disponuje i rozhraním pro C++. Obsahuje více než 2000 funkcí, které jsou nápomocné v oblasti robotiky, počítačového vidění a mohou být používány i v reálném čase. Nutno podotknout, že OpenCV není součástí instalačního balíčku Visual Studia, takže je potřeba na ni v každém vytvořeném projektu odkazovat.

### 5.2 Volba snímací roviny

Před zvolením metody pro implementaci detekce obličeje je potřeba stanovit limitující podmínky snímání obrazu. Pokud bychom chtěli obličej pouze detekovat, je možno využít velké volnosti úhlu snímání. Požadavek na následné rozpoznání omezuje tuto volnost na pokud možno přímý čelní pohled.

Pokud budeme pro detekci uvažovat pouze čelní rovinu, obličej může vzniknout další variace polohy za pomoci rotace obličeje kolem osy Z, jak je zobrazeno na Obr. 14. Přírozenou a nejčastější pozicí obličeje je poloha, kdy jsou obě oči ve stejné vodorovné rovině. Detekce obličeje bude tedy splněna pouze v případě, bude-li obličej splňovat výše uvedené nároky na svoji polohu. Samozřejmě nelze vždy dodržet absolutní požadavky na dodržení roviny, proto musí být detektor schopen reagovat i na blízké odchylky od těchto rovin do úrovně  $\pm 10^\circ$ .

### 5.3 Implementace Viola Jones detektoru

Jak bylo zmíněno v teoretické části v kapitole 3.2.5 detektor Viola Jones je tvořen kaskádou klasifikátorů, které jsou trénovány na různých velikostech Haarových filtrů. Autoři zjistili, že samoučící klasifikátory dosahují lepší přesnosti než doposud lidsky vytvářené algoritmy. V roce 2001, kdy byl tento klasifikátor představen, umožňoval detekci obličejů v reálném čase. Od uvedení došlo k mnoha vylepšením a klasifikátor našel využití i v digitálních fotoaparátech.

Jednou z osob, která se na vylepšení původního klasifikátoru podílela, byl Rainer Lienhart. Lienhart představil výpočet pro sadu Haarových příznaků pootočených o 45°.

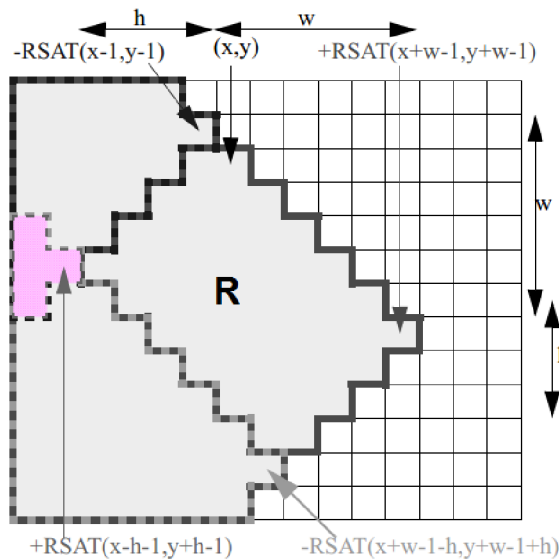
[25] Integrovaný obraz se tedy vypočítá pomocí vzorce:

$$ii(x, y) = \sum_{x' \leq x, x' \leq x - |y - y'|} i(x', y') \quad (22)$$

Suma pixelů tedy pro obdélníkovou oblast pootočenou o 45° je rovna:

$$RecSum(R) = RSAT(x + w, y + w) + RSAT(x - h, y + h) - RSAT(x, y) - RSAT(x + w - h, y + w + h)$$

Vysvětlení vzorce je pro ilustraci znázorněno na následujícím obrázku.



Obr. 21 princip výpočtu pootočené obdélníkové oblasti o 45° [25]

Zavedením pootočených Haarových filtrů se zkomplikoval proces učení, nicméně míra falešných detekcí byla snížena o 10%. Takto vylepšený natrénovaný klasifikátor obsahující 13 stupňů je součástí knihovny OpenCV.[25]

## 5.4 Trénování kaskády klasifikátorů

OpenCV 2.1 obsahuje utility, pomocí kterých je možnost natrénovat vlastní kaskádu klasifikátorů. První krokem je obstarání trénovací a testovací množiny.

Pomocí `opencv_createsamplesd.exe` vytvoříme vektor obsahující popis pozitivních obrazů, tedy obrazů s obličejí.

Volání v příkazovém řádku může vypadat následovně:

```
opencv_createsamplesd.exe
-info face.bat          - obsahuje informace o obrazech, jejich cestu, velikost a
kde se nachází obličej
-vec face.vec           - jméno výstupního souboru
-num 2429               - počet obrazů
-w 19                   - šířka obrazu
-h 19                   - výška obrazu
```

Pokud tedy máme vytvořen vektor, můžeme se pustit do samotného školení klasifikátoru `opencv_haartrainingd.exe`.

Volání příkazu a jeho nastavení mohou vypadat následovně:

```
opencv_haartrainingd.exe
-data classific_folder  - složka kde bude výsledný klasifikátor
-vec face.vec           - jméno souboru s pozitivními vzory
-nneg 4548              - počet negativních obrazů (pozadí)
-npos 2429              - počet pozitivních obrazů (obličejí)
-w 19                   - výška obrazu
-h 19                   - šířka obrazu
-bg non_face.bat        - soubor obsahující informace o cestě k negativním
vzorům
-nstages 20             - počet stupňů, jež má být natrénován
-nsplits 1              - určení použití slabého klasifikátoru nebo lepšího
-minhitrate 0.999       - minimální požadovaná úspěšnost klasifikátoru pro
jednotlivý stupeň
-maxfalsealarm 0.5      - maximální stupeň špatných detekcí pro jednotlivé
stupně klasifikátoru
-mode ALL                - počet Haarových příznaků, v tomto případě jsou
použity i pootočené příznaky o 45°
```

Zde byl uveden postup k natrénování Viola Jones detektoru za pomoci OpenCV. Jako databáze byla použita CBCL MIT databáze – více v kapitole 6.3. Přesnost a robustnost klasifikátoru závisí na trénovací množině, na které je trénován. V případě trénování Viola Jones detektoru se jedná o výpočetně a časově náročný proces (řádově až týdny

více na [26]). Dalším kritériem náročnosti trénování je nastavení jednotlivých parametrů, tak aby došlo k požadované přesnosti a nedošlo k přetrénování klasifikátoru.

## 5.5 Předzpracování obrazu u detekce obličeje

V kapitole 2.2.1 byl uveden přehled technik pro předzpracování obrazu. Použití jedné nebo kombinace více uvedených záleží na faktu v jakém „stavu“ se nachází vstupní obraz.

Implementace detekčního algoritmu předpokládá na vstupu barevný nebo šedo-tónový obraz. Nejvíce používanou technikou předzpracování obrazu v oblasti šedo-tónových obrazů je ekvalizace histogramu. Touto technikou dojde k zlepšení kvality kontrastu. V případě barevného obrazu na vstupu dojde k převedení do šedo-tónového dle vztahu:

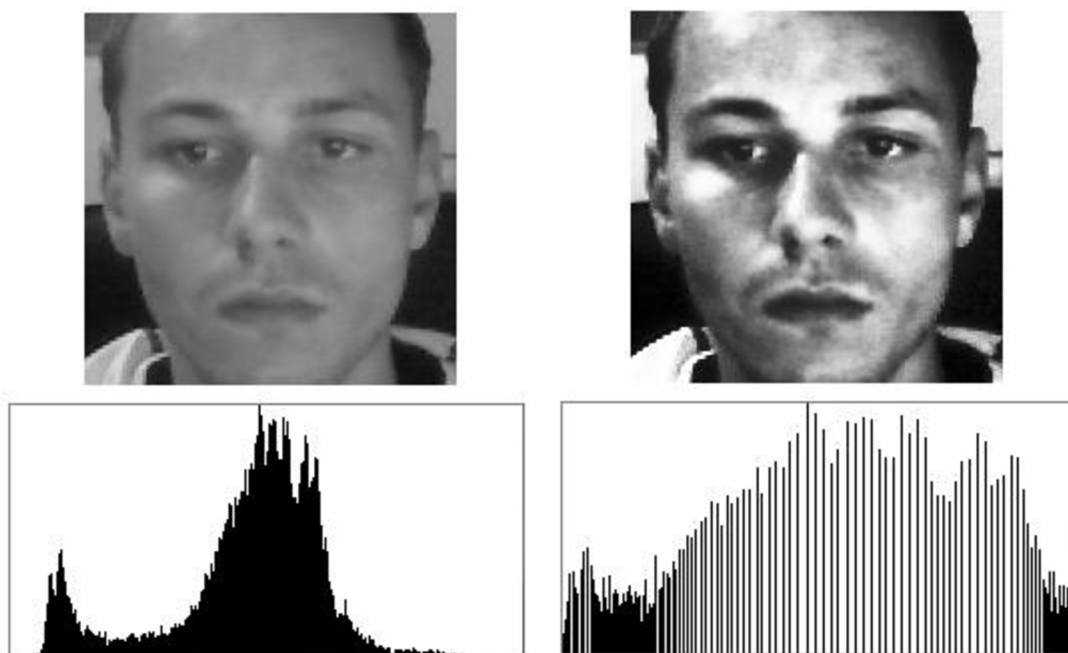
$$Y = 0,299R + 0,587G + 0,114B \quad (23)$$

Histogram kvantifikuje množství a frekvenci barev v obraze. Jinými slovy hodnota histogramu  $H$  pro index  $i$  říká, kolik pixelů v obraze má danou intenzitu  $i$ . [7]

Pro rozlišení obrazu  $m \times n$  platí:

$$\sum_{i=0}^{max} H(i) = m \times n \quad (24)$$

Pokud je šedo-tónový obraz technicky dobře proveden využívá celou škálu intenzit. Taková realizace se povede jen zřídka. Ke zlepšení parametrů obrazu se tedy použije ekvalizace histogramu, která převede stávající rozsah intenzit do maximálního rozmezí.



Obr. 22 Ekvalizace histogramu, vlevo vstupní obraz, vpravo obraz po ekvalizaci

## 5.6 Metoda pro detekci obličeje

V kapitole 5.1 byla představena knihovna OpenCV 2.1. Všechny realizované metody jsou psány v jazyku C/C++ a využívají funkcí knihovny OpenCV2.1.

Pro detekci obličeje byla vytvořena metoda:

```
IplImage *face_finding(IplImage* src)
```

U vstupního obrazu `src` dojde k jeho převedení na šedo-tónový s následnou ekvalizací histogramu. Úprava pomocí předzpracování zlepšuje výkonnost klasifikátoru. Po uvedených úpravách je detekován obličej pomocí Haarových příznaků. Při procházení obrazu se vybírají obdélníky o minimálních rozměrech 90 x 90 pixelů. V následujícím iteračním kroku je použito zvětšení procházených oblastí o 10%. Funkce zamítá oblasti, které obsahují mnoho, nebo naopak málo hran, zjištěných pomocí Cannyho hranového detektoru. Následně je výřez obličeje upraven na rozlišení 128 x 149. Volba zmíněného rozlišení souvisí s technikou rozpoznání obličeje uvedenou v kapitole 6.2. Rozlišení 128 x 149 je kompromisem mezi ztrátou podstatné informace a velkou délkou výsledného histogramu.[23] Každý kandidát na obličej je zařazen do seznamu, který je možno v grafickém rozhraní zobrazit (kapitola 7).

### 5.6.1 Změna velikosti obličeje

Minimem pro detekci obličeje je jeho rozlišení 90 x 90 a naopak maximální rozlišení není stanoveno. Zajištění detekce obličeje na rozlišení 128 x 149 není v praxi možné z důvodů předpokladu na realizaci systému. Každý detekovaný obličej je následně upraven na rozlišení 128 x 149.

Úpravu rozlišení je možno provést pomocí funkce `cvResize` a následujících interpolačních metod:

- `INTER_NEAREST` - interpolace nejbližším susedem,
- `INTER_LINEAR` - bilineární interpolace,
- `INTER_AREA` – převzorkování pomocí plochy,
- `INTER_CUBIC` – bikubická interpolace přes 4 – okolí,
- `INTER_LANCZOS4` – Lanczosova interpolace 8-okolím,

Pro změnu rozlišení obličeje je nastavena bilineární interpolace, která zamezuje aliasingu. Výsledný pixel je počítán jako průměrná hodnota svého 4 – okolí. Metoda úpravy rozlišení bilineární interpolací je použita i v ostatních částech práce.

## 6 REALIZACE ROZPOZNÁNÍ OBLIČEJE

### 6.1 Předzpracování obrazu – světelná normalizace

Rozpoznávání obličeje je část, kdy porovnáváme dva obličeje a hledáme míru korespondence mezi těmito dvěma obrazy. Při rozpoznávání fotografií pořízených při neměnné scéně je jednodušší, nežli pokud porovnáváme obličeje, při jejichž pořízení byly měněny vlastnosti snímání scény (uvážujeme různé osvětlení). Pro zlepšení přesnosti se provede světelná normalizace podle následujících kroků.

#### 6.1.1 Gama korekce

Gama korekce sloužila původně u CRT vakuových obrazovek k vyrovnání nelineární jasové odezvy tak, aby se jeden obrázek zobrazil na různých zobrazovacích zařízeních stejně. Nesprávně nastavená gama může způsobit problémy s antialiasingem nebo rozostření obrazu. Pro odstranění nelinearity se použije gama korekce.[7]

Při použití v šedo-tónovém obraze představuje gama mocninu na jasovou úroveň:

$$I = I^\gamma \quad (25)$$

Kde parametr  $\gamma \in [0,1]$ . Volba parametru zvyšuje dynamický rozsah ve tmavých oblastech obrazu a zároveň ho snižuje ve světlých oblastech. Principem je, že intenzita světla je závislá na vlastnostech přichozího osvětlení na daný objekt. Tento problém tedy odstraníme gama korekcí. [27]

#### 6.1.2 Rozdíl gaussovských rozostření

Gama korekce neodstraňuje vliv celkové intenzity přechodů, jako jsou stíny. Stíny vyvolané povrchovou úpravou nesou užitečnou informaci, ale je těžké ji oddělit od stínů vyvolaných špatným osvětlením scény. Pro odstranění šumu z obrazu lze použít Gaussův filtr. Filtrace probíhá pomocí konvoluční masky elementem, který má normální (Gaussovo) rozložení.

$$G(x, y) = \frac{1}{2 * \pi * \sigma^2} * e^{-\frac{x^2+y^2}{2*\sigma^2}} \quad (26)$$

Výstupní obraz je tedy spočítán následovně:

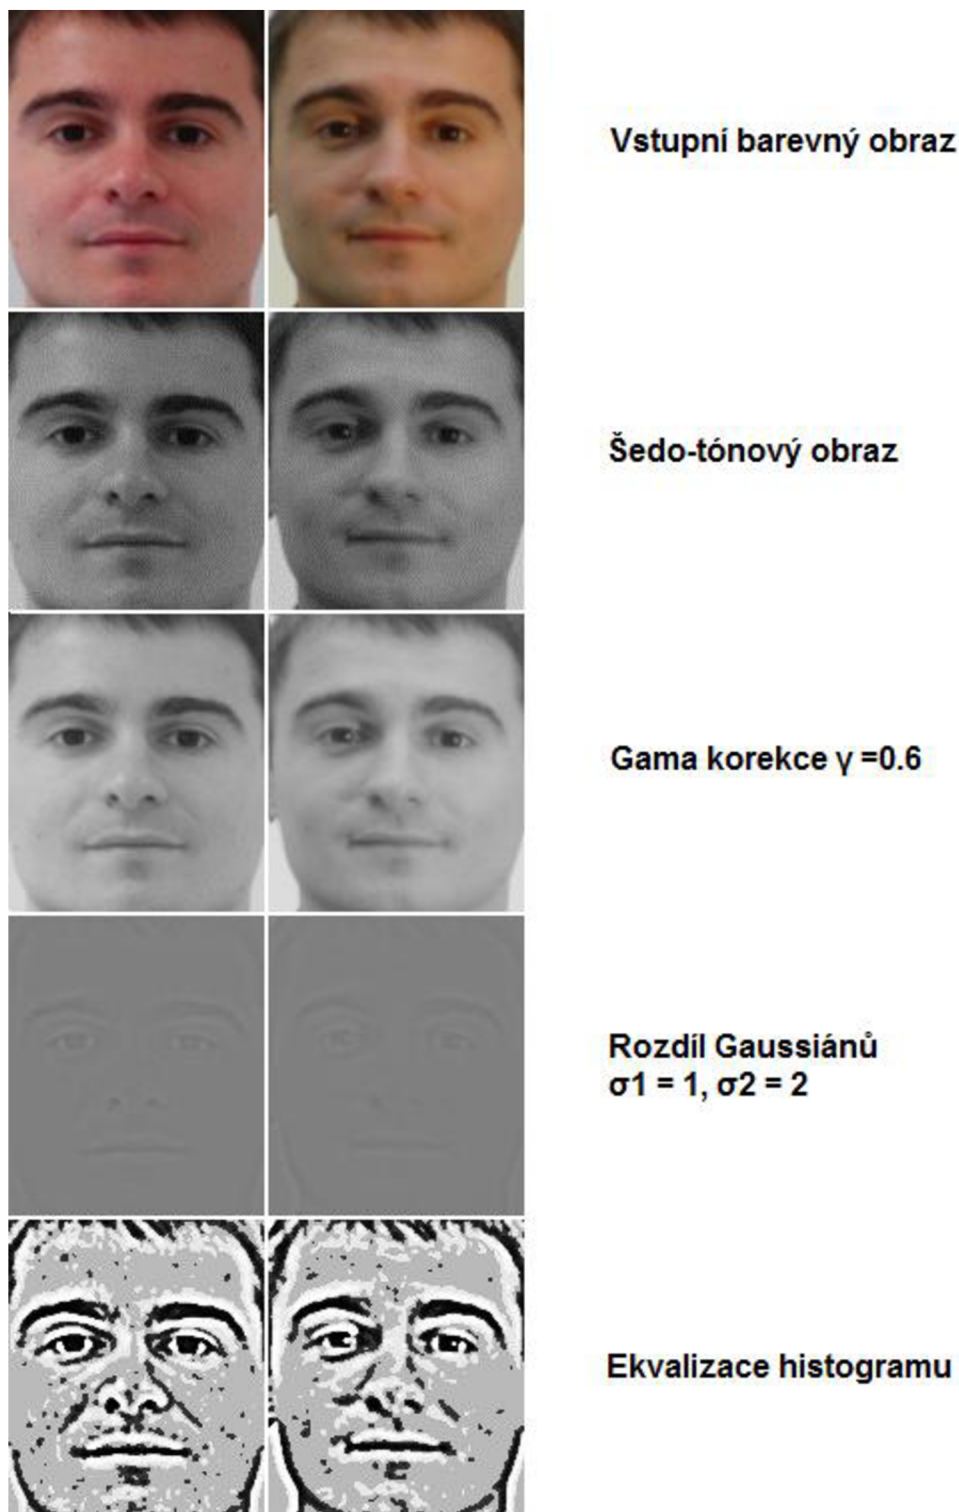
$$I_G(x, y) = G(x, y) * I(x, y) \quad (27)$$

Ze vzorce (26) je vidět, že jediným parametrem filtru je  $\sigma$ . Pro druhý obraz platí ty samé rovnice, pouze s odlišnou hodnotou  $\sigma$ . Rozdíl Gaussových filtrů se provede prostým odečtením dvou obrazů od sebe. Jelikož filtrace probíhá pomocí konvoluční masky, je potřeba zvolit její velikost ( $n \times n$ ). V případě OpenCV je velikost konvoluční odvozena od velikosti parametru  $\sigma$  (pokud není přímo zadána) dle vzorce:

$$n = 2 * \left( \frac{\sigma - 0.8}{0.3} + 1 \right) \quad (28)$$

Při použití rozdílu dvou obrazů vznikne vlastně pásmová propust, která odstraňuje vysokofrekvenční části jako šum a nízkofrekvenční části reprezentované homogenními oblastmi.

Posledním krokem světelné normalizace je zlepšení kontrastu pomocí ekvalizace histogramu, jak bylo vysvětleno v kapitole 5.5.



Obr. 23 Světelná normalizace u dvou rozdílně nasvícených scén


## 6.2 Metoda pro rozpoznání obličeje

Pro rozpoznání obličeje byla vybrána metoda local binary pattern (LBP). Zejména kvůli své výpočetní a časové nenáročnosti. Další výhodou metody je robustnost na změnu osvětlení. V kapitole 4.4 byly představeny různá okolí pro výpočet LBP. V implementaci je voleno 8-okolí s poloměrem 1, formální zápis je LBP(8,1). Výstupní obrázek z detekce obličeje má rozlišení 128 x 149. Výpočet probíhá u všech pixelů s výjimkou krajních, ty jsou následně ořezány a obraz dostane konečné rozlišení o hodnotě 126 x 147 pixelů.



Obr. 24 Výpočet LBP (vstupní obraz vlevo, vypočtený LBP vpravo)

Dalším krokem je rozdělení obrazu na 7 x 7 bloků, přičemž rozměr jednoho bloku je 18 x 21 pixelů. Pro zlepšení přesnosti rozpoznávání se doporučuje aplikovat na obraz rozdělený do bloků masku. Princip masky spočívá ve vlastnosti zvolení váhy danému regionu, jak je znázorněno níže.



Obr. 25 Rozdělení obličeje do bloků a ukázka masky

Pro každý ze 49 bloků je nyní vypočítán histogram, máme tedy 49 histogramů se zastoupením četnosti 0-255. Po spojení všech histogramů za sebe dostáváme pole o velikosti 49 x 255 hodnot. Vytvořením bloků se vrátíme k původní myšlence LBP, tedy k porovnávání textur. Zde porovnáváme lokální textury v obličeji.

Za pomoci OpenCV byla vytvořena metoda:

```
IplImage * compute_image_LBP(IplImage * img,  
CvHistogram *big_hist)
```

Vstupem do metody je obraz `img` a výstupem je histogram `big_hist`.



## 6.2.1 Srovnávání histogramu

Srovnávání histogramů je klíčový prvek v oblasti implementované metody pro rozpoznávání obličejů. Hledáme co největší podobnost mezi dvěma obličejí, tedy histogramy. V praxi se používají následující techniky pro srovnání histogramů:

- correlation,

$$d(H_1, H_2) = \frac{\sum_{i=0}^{N-1} (H'_1(i) * H'_2(i))}{\sqrt{\sum_{i=0}^{N-1} (H'_1(i))^2 * (H'_2(i))^2}} \quad (29)$$

$$kde \quad H'_k(i) = \frac{H_k(i) - 1}{\sum_{j=0}^{N-1} H_k(j)},$$

*N je počet prvků histogramu*

V případě shody je vzdálenost  $d = 1$ , úplná neshoda je rovna  $d = -1$

- chi-square,

$$d(H_1, H_2) = \sum_{i=0}^{N-1} \frac{(H_1(i) - H_2(i))^2}{(H_1(i) + H_2(i))} \quad (30)$$

Ze vzorce je na první pohled vidět, že absolutní shoda indikuje  $d = 0$ , zvětšení vzdálenosti indikuje větší rozdílnost mezi histogramy.

- intersection,

$$d(H_1, H_2) = \min(H_1(i), H_2(i)) \quad (31)$$

Velká vzdálenost označuje velkou podobnost, malá vzdálenost malou podobnost histogramů. Při normalizaci histogramu na hodnotu 1, vrací hodnotu  $d = 1$  při naprosté shodě a  $d = 0$  při neshodě.

- Bhattacharyya distance,

$$d(H_1, H_2) = \sqrt{1 - \sum_{i=0}^{N-1} \frac{\sqrt{(H_1(i) * H_2(i))}}{\sqrt{\sum_{i=0}^{N-1} H_1(i) * \sum_{i=0}^{N-1} H_2(i)}}} \quad (32)$$

Zde rovněž naprostá shoda vrací hodnotu 0, a s narůstající neshodou narůstá i vzdálenost.

Pro vyhodnocení přesnosti je zvolena metoda chi – square. Její výhodou je hledání minima mezi histogramy, což označuje největší míru pravděpodobnosti. [23]

## 6.3 Databáze

K ověření funkčnosti implementovaných algoritmů je zapotřebí galerie obrazů. Databázi si lze vlastnoručně vytvořit nebo získat z internetu, kde jsou databáze volně ke stažení nebo na vyžádání. Výhodou některých dostupných obličejových databází je skutečnost, že jsou tvořeny s ohledem na testování algoritmů detekce a rozpoznání obličeje. Obsahují tedy různé pozice obličeje a různé světelné podmínky.

### **GTAV face database**

Databáze vytvořená k otestování robustnosti algoritmů pro rozpoznávání obličejů vůči změně pozice a osvětlení. Obsahuje 44 osob, z nichž pro jednotlivou osobu je pořízeno 27 fotografií. Pozičně potočené obličeje o  $0^\circ$ ,  $\pm 30^\circ$ ,  $\pm 45^\circ$ ,  $\pm 60^\circ$  a  $90^\circ$  dále tři světelné podmínky: přírodní osvětlení, silný světelný zdroj z úhlu  $45^\circ$  a osvětlení v čelní rovině obličeje. Zbylý počet fotografií tvoří různé výrazy obličejů. Všechny fotografie jsou v rozlišení  $320 \times 240$  a formátu bmp. Databáze je přístupná pouze na vyžádání a je určena pouze vědeckým pracovníkům.[28]

### **FEI face database**

Databáze vytvořená na univerzitě FEI v Brazílii v období mezi červnem 2005 a dubnem 2006. Obsahuje 200 osob ve 14 různých zobrazeních. Obsahuje rozsah pootočení obličeje ve vertikální ose okolo  $180^\circ$ . Měřítko pootočení je okolo  $10^\circ$ . Dále obsahuje odlišný výraz v obličejí a dvě různé světelné podmínky. V databázi jsou zastoupeny muži a ženy rovným dílem ve věku 19 až 40 let s různými účesy a ozdobami ve tváři. Jedná se o studenty a zaměstnance univerzity. Všechny obrazy mají homogenní pozadí, rozlišení je  $640 \times 480$  pixelů ve formátu jpg. [29]

### **MIT CBCL**

Databáze Center for Biological and Computational Learning z univerzity MIT obsahující v tréninkovém setu 2429 obličejů a 4548 pozadí v šedo tónovém rozlišení  $19 \times 19$  ve formátu .pgm. Testující set obsahuje 472 obličejů a 23 573 (pozadí). Databáze je volně k dispozici.[30]

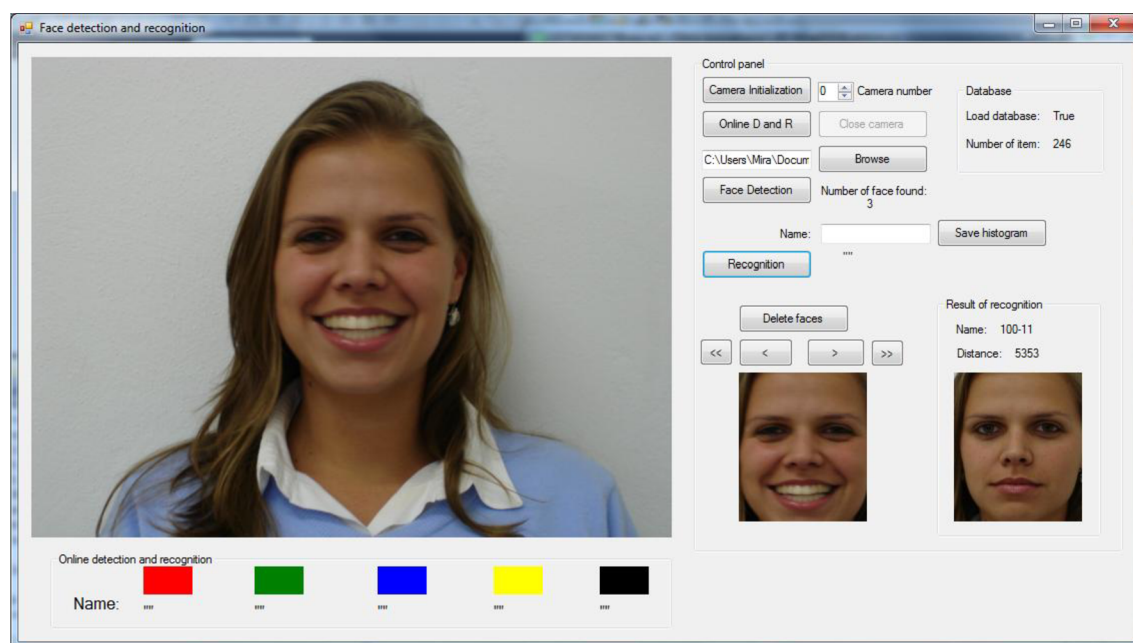
### **BioID**

Galerie obličejů sloužící k porovnávání algoritmů v oblasti detekce obličeje. Obsahuje 1521 šedotónových obrazů o rozlišení  $384 \times 286$  ve formátu pgm. Celkem je v databázi obsaženo 23 osob v různých světelných podmínkách a prostředí. Rovněž velikosti obličejů jsou různé.[31]

## 7 DEMONSTRAČNÍ APLIKACE

Jako výstup diplomové práce bylo naprogramováno grafické uživatelské rozhraní (GUI) za pomoci OpenCV2.1 a Microsoft Visual studia 2010. GUI je realizováno pomocí vývojového nástroje windows form application a využívá metody pro detekci a rozpoznání obličeje v obraze s názornou reprezentací jejich funkčnosti.

### 7.1 Popis aplikace



Obr. 26 Vzhled GUI

Po spuštění aplikace je vytvořeno vlákno `backgroundWorkerDB`, které zajišťuje nahrání již předem vytvořené databáze histogramů do paměti programu. Vytvoření vlákna odstraňuje problém, pokud by byly použity obyčejné smyčky (`for`, `while`). Při použití standartních smyček by během jejich vykonání nebylo možno manipulovat s ostatními komponentami GUI (došlo by k „zamrznutí“). Proto jsou u načítání databáze a snímání scény z kamer použity vlákna. Databáze je nahrána ze složky „Databáze“ umístěné ve stejném adresáři jako program. Každá osoba v databázi má vlastní složku. Jméno složky je shodné se jménem, které bylo zadáno při ukládání a obsahuje histogram v xml souboru a příslušný obličej. Výhodou xml souborů je jednoduchá operace s nimi při nahrávání nebo ukládání do nich. V souvislosti s úspěšným nahráním databáze do paměti programu je zobrazen stav úspěšnosti načtení a celkový počet prvků.

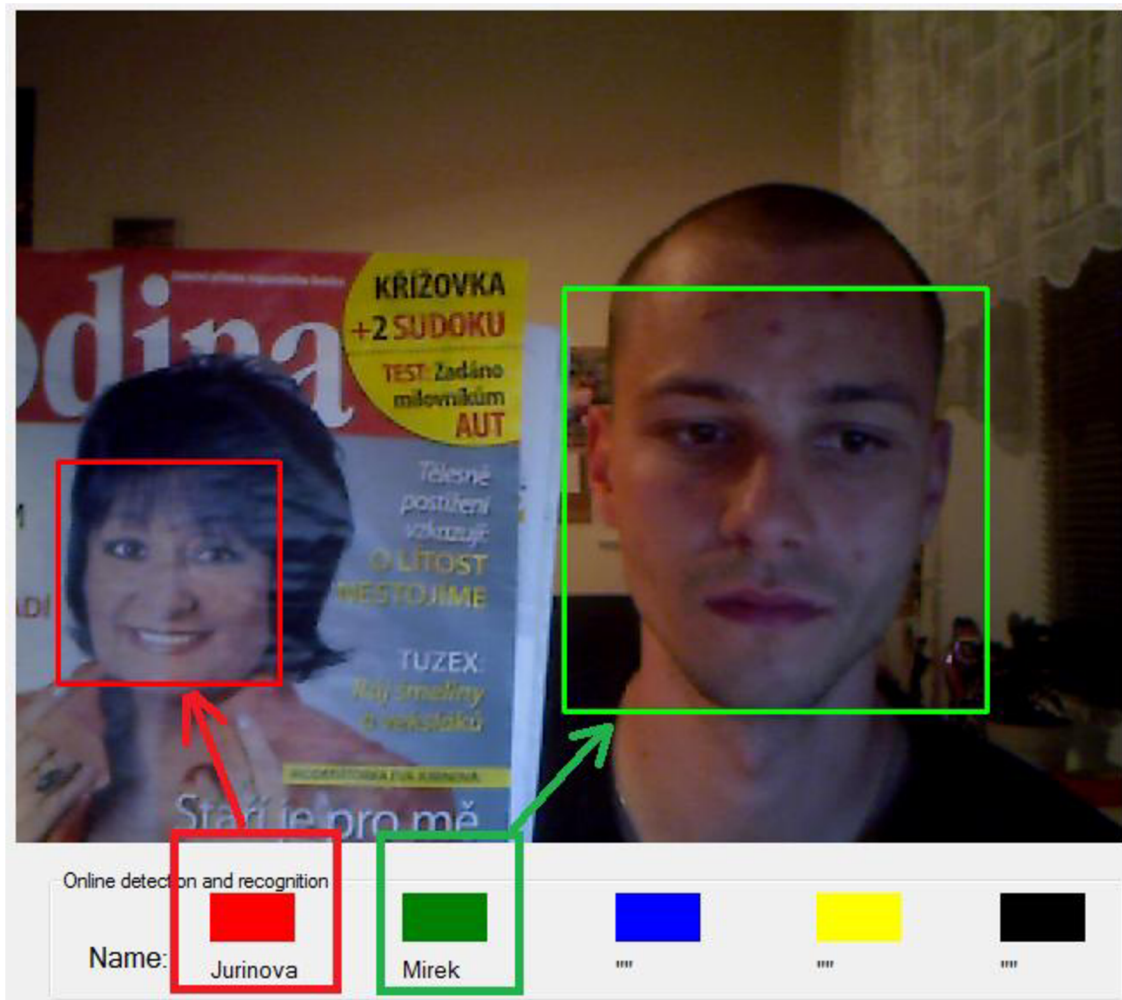
Jakmile se zobrazí úvodní obrazovka, lze se vydat různými směry. K těmto účelům slouží tlačítka v oblasti `Control panel`. Nyní bude vysvětleno, jaké funkce tlačítka obstarávají.

## Camera initialization

Zmáčknutím dojde k výběru kamery, pomocí komponenty `NumericUpDown` `Camera number` napravo od tlačítka. V případě připojení pouze jedné kamery k PC, je její hodnota pro výběr rovna 0. Stejná hodnota je i pro notebook včetně webové kamery. Pokud je v PC připojeno více kamer stačí hodnotu komponenty zvýšit. Následně je vytvořeno vlákno `backgroundWorkerCamera` sloužící k vykreslování videa z kamery rychlostí 25 fps (frames per second – obrazů za sekundu). Pro získání obrazu z kamery slouží funkce ze struktury `CvCapture`, další metody slouží k nastavení parametrů přijímaného videa – v případě aplikace se jedná o primární rozlišení, se kterým pracuje a to je 640 x 480. Následně je obraz převeden do bitmapové grafiky, aby mohl být zobrazen v grafickém objektu `camPictureBox` (hlavní zobrazovací okno).

## OnlineDaR

Pokud máme vytvořenou databázi, můžeme spustit online detekci a rozpoznání obličeje. Funkce je analogická jako **Camera Initialization**, dále je v ní implementována detekce obličeje. Obličeje jsou označeny barevnými rámečky, které jsou vykreslovány tak, aby bylo zachováno pořadí barev rámečků pod zobrazovacím oknem kamery - `camPictureBox`. Tedy pokud jsou detekovány dva obličeje, první rámeček zleva má barvu červenou a druhý zelenou viz Obr. 27 Ukázka online detekce a rozpoznání. Zmáčknutím tlačítka je rovněž spuštěn `Timer`. Časová konstanta časovače je nastavena na 2 sekundy a po uplynutí této doby je spuštěno vlákno `backgroundWorkerRecog` sloužící k rozpoznání detekovaných obličejů v databázi. Z důvodu přístupu metody pro online detekci a nově spuštěného vlákna ke stejné funkci `OpenCV`, je nutno zajistit bezkolizní průběh. Řešení tohoto problému je vypnutí detekce obličeje na interval, nežli je provedeno vlákno realizující rozpoznání obličejů.



Obr. 27 Ukázka online detekce a rozpoznání

### Close camera

Tlačítko sloužící k adekvátnímu ukončení vláken pokud běží online detekce a rozpoznání nebo jen samotné vykreslování z kamery (`backgroundWorkerCamera ->CancelAsync()`). V prvním zmíněném případě dojde i k vypnutí časovače. Funkce uvolňuje alokované prostředky používané v souvislosti s vykreslováním obrazu z kamery. Tlačítko se doporučuje stisknout i před samotným ukončením grafického rozhraní.

### Browse

Slouží po načtení libovolného obrazu z disku. K zobrazení cesty slouží systémový dialog `openFileDialog`. Jak bylo zmíněno, aplikace pracuje s primárním rozlišením 640 x 480. Je-li načítaný obrázek menší než toto rozlišení zobrazí se v původním rozlišení, jeli rozlišení vstupního obrazu větší nebo jeden z jeho rozměrů větší než primární defaultní rozlišení, pak je obraz zmenšen se zachováním poměru

stran a následně převeden do bitmapy. Opět je obraz vykreslen do `camPictureBox`. Obrázky menšího rozlišení než 640 x 480 se umisťují na střed `camPictureBoxu`.

### Face detection

Jak název vypovídá, stisknutím tlačítka dojde k detekci obličeje pomocí funkce `face_finding`. Detekce může probíhat na statické fotografii nebo při vykreslování videa z kamery. Nalezený obličej je zařazen do seznamu (`<list>`) `maybe_faces` a následně vykreslen do komponenty `facePictureBox` (viz. Obr. 28). Pokud je detekováno více obličejů lze mezi nimi přecházet pomocí tlačítek se symboly `<<`, `<`, `>`, `>>`. Počet obličejů v seznamu je zobrazen vedle tlačítka. Zobrazení obličeje do `facePictureBox` rovněž slouží k zachycení falešných detekcí obličeje.

### Delete faces

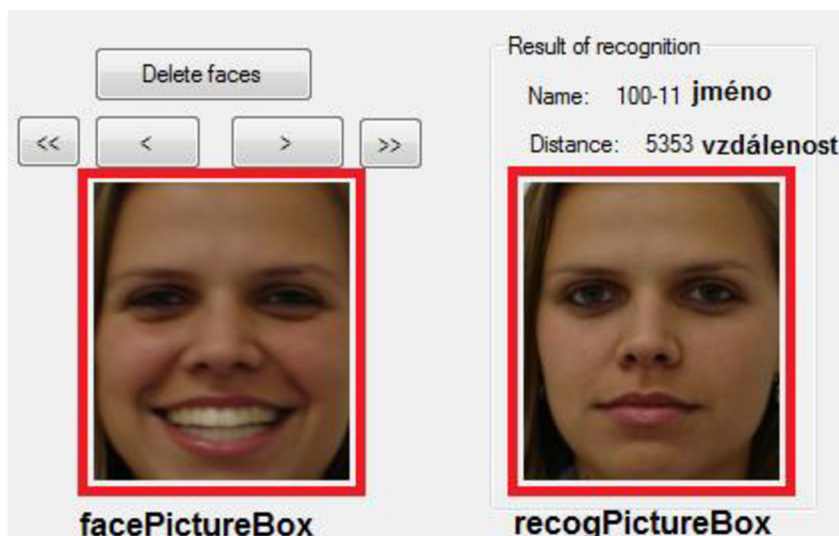
Tlačítko pro mazání všech obličejů ze seznamu `maybe_faces`.

### Save histogram

Funkce přebere právě zobrazený obličej z komponenty `facePictureBox` pro obličeje a zavolá metodu `compute_image_LBP`, která pro obličej vypočítá histogram. Histogram je poté uložen do souboru xml. Název xml souboru se odvíjí od zadání textu do `nameBox` nalevo od tlačítka. Pokud je jméno účastníka již v databázi obsaženo, pod tlačítkem je zobrazena informace o této skutečnosti v opačném případě je v databázi vytvořena složka a histogram je uložen. Do složky obsahující histogram je uložen také vybraný obličej ve formátu jpg.

### Recognition

Tlačítko pro zobrazený obličej komponentě `facePictureBox` provede výpočet histogramu pomocí metody `compute_image_LBP` a následně je porovnáván s každým histogramem z databáze pomocí Chi - Square metody. Hledáme nejmenší vzdálenost histogramů. Po jejím nalezení, je v komponentě `recogPictureBox` (Obr. 28) zobrazen vítězný kandidát spolu se jménem a vzdáleností histogramů.

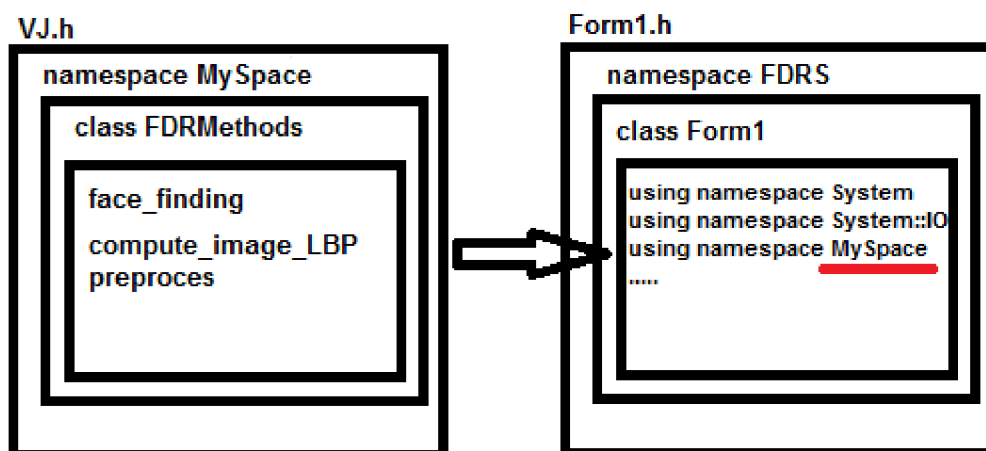


Obr. 28 Zobrazení detekovaného obličeje a odpovídající obličeje z databáze spolu se jménem a vzdáleností histogramů

Aplikace je naprogramována tak, aby nedošlo k žádné kolizi. Toho je dosaženo povolováním a zakazováním stisknutelnosti tlačítek (enable on/off).

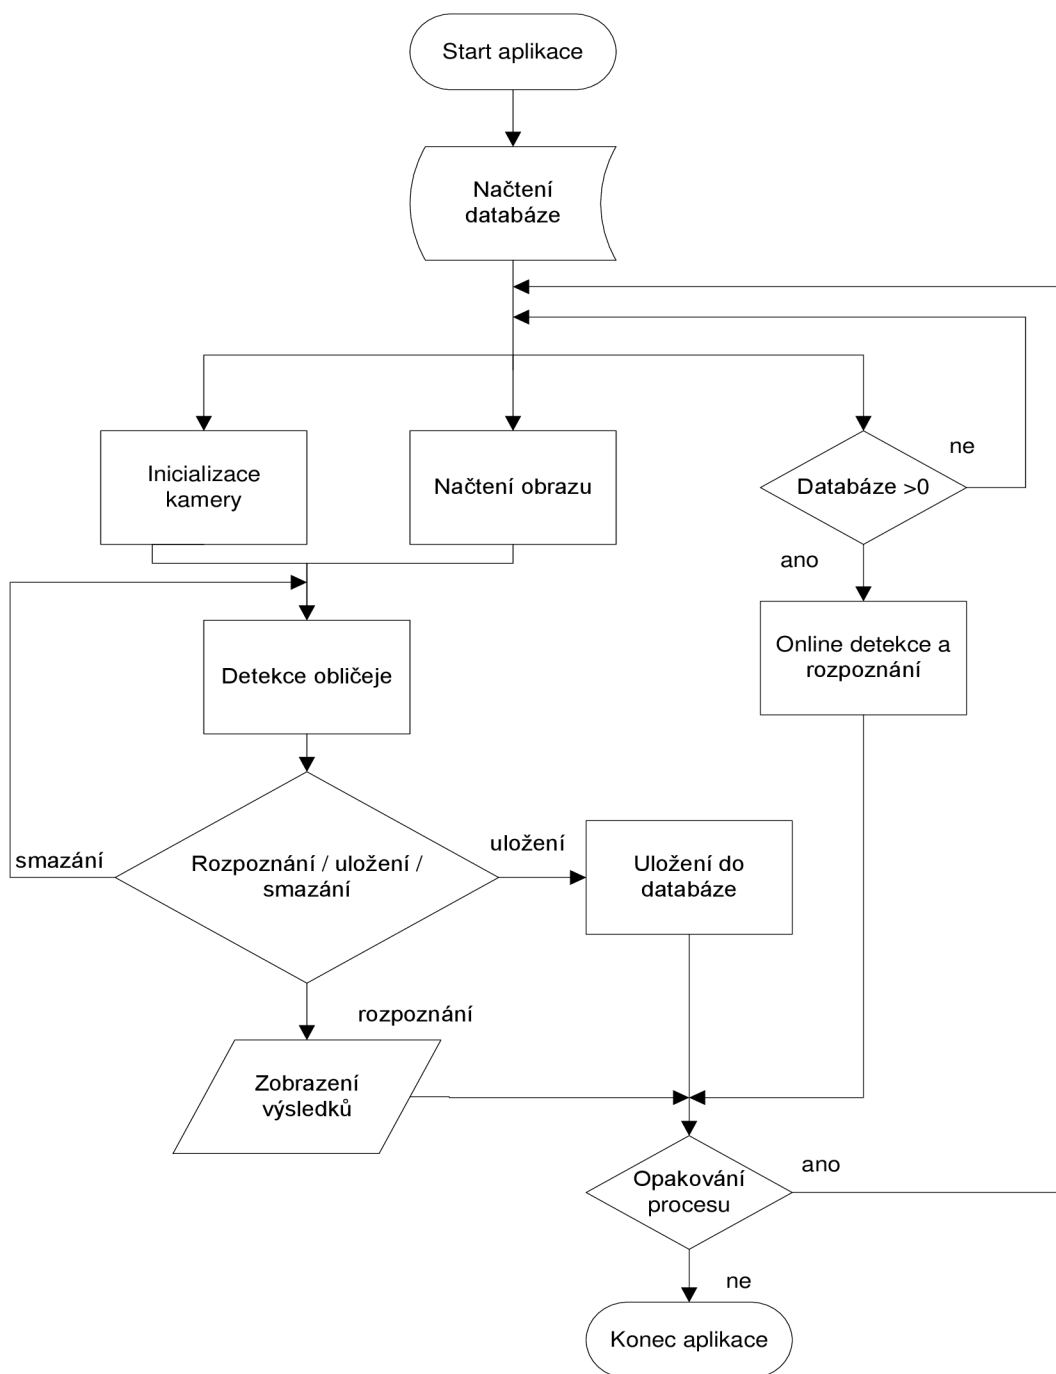
## 7.2 Struktura programu

Grafické rozhraní je realizováno typem projektu VS2010 windows form application. Struktura tohoto projektu je založena na .NET platformě. Celý projekt sdružuje namespace (jmenný prostor) FDRS, ve kterém jsou obstarávány všechny komponenty GUI. Pro větší přehled byl vytvořen hlavičkový soubor VJ.h v němž je implementován namespace MySpace obsahující třídu FDRMethods. Uvnitř třídy jsou naprogramovány metody pro detekci a rozpoznávání obličeje. Provázání mezi jednotlivými namespace se povede pomocí using namespace MySpace.



Obr. 29 Struktura programu

### 7.3 Vývojový diagram aplikace



Obr. 30 Vývojový diagram aplikace



## 8 INTERPRETACE VÝSLEDKŮ

V této kapitole představím funkčnost implementovaných metod a závislost jejich procentuálního vyhodnocení na vlastnostech nastavení a okolí. Pro vyhodnocení byly použity jako testovací množiny databáze: BioID, FEI, a GTAV představeny v kapitole 6.3.

Pro otestování nastavení parametrů klasifikátoru pro detekci obličeje bude použita databáze BioID, jelikož obsahuje čelní pozice obličejů na nehomogenním pozadí. Databáze je pořízena v místnostech s různými světelnými podmínkami, rovněž velikosti obličejů jsou různé. Počet prvků BioID databáze je 1521.



Obr. 31 Příklad rozmanitosti BioID databáze

Výkonnost klasifikátoru bude porovnávána v závislosti na velikosti detekčního okna, koeficientu pro zvětšování okna v následujícím iteračním kroku a předzpracování. Velikost detekčního okna bude měněna od základní velikosti, která je 19 x 19 po 90 x 90.

Pro tabulku bez předzpracování obrazu platí:

nastavení parametrů klasifikátoru (scale, window size)	TP	FN	TPR[%]	FP
1,1 19x19	1482	39	97,4	271
1,2 19x19	1451	70	95,4	80
1,1 45x45	1473	48	96,8	182
1,2 45x 45	1450	71	95,3	58
1,1 65x65	1472	49	96,8	96
1,2 65x65	1450	71	95,3	42
1,1 90x90	1462	49	96,8	50
1,2 90x 90	1448	73	95,2	6

Tab. 2 Výkonnost klasifikátoru bez předzpracování

Pro tabulku s předzpracováním obrazu platí:

nastavení parametrů klasifikátoru (scale, window size)	TP	FN	TPR[%]	FP
1,1 19x19	1482	39	97,4	291
1,2 19x19	1466	55	96,4	101
1,1 45x45	1478	43	97,2	198
1,2 45x 45	1463	58	96,2	79
1,1 65x65	1473	48	96,8	120
1,2 65x65	1462	59	96,1	50
1,1 90x90	1473	48	96,8	53
1,2 90x 90	1462	59	96,1	6

**Tab. 3 Výkonnost klasifikátoru s předzpracováním**

Z tabulek je zřejmé, že ekvalizace histogramu obrazu před samotnou detekcí obličeje zlepšuje jeho TPR (true positive rate viz. Kapitola 3.5). Zároveň ovšem vzrůstá i počet falešných detekcí, zejména při malých velikostech detekčního okna. V implementaci detektoru obličeje ( kapitola 5.6). jsem z důvodu kvality obličeje zvolili minimální velikost detekčního okna 90 x 90. Pokud použijeme zároveň změnu měřítka detekčního okna o 20% tak dostáváme zlepšení o 0,9%.

Pokud bychom chtěli výkonnost klasifikátoru hodnotit v ACCURACY(přesnost) je potřeba znát počet správně zamítnutých (TN) kandidátů v množině „neobličejů“-pozadí (N). V případě, že klasifikátor není testován na snímky obsahující pouze pozadí platí:

$$ACC = \frac{TN + TP}{P + N}, \text{pokud } N = 0 \text{ a } TN = 0 \quad (33)$$

*pak ACC = TPR*

Ukázky správných a chybných detekcí jsou umístěny v příloze A.

## 8.1 Pootočení obličeje

Databáze FEI a GTAV disponují obrazy s nejen čelní polohou obličeje ale i s různě pootočenými tvářemi. K otestování schopnosti klasifikátoru detekovat obličej v pootočení kolem osy Y (viz. Obr. 14) poslouží FEI databáze.



Obr. 32 Potočené obrazy z FEI databáze (horní řada -40°, -30°, -20°, -10°, dolní řada 10°, 20°, 30°, 40°)

FEI pootočení obličeje [°]	TP	FN	TPR [%]	FP
10	200	0	100,0	3
-10	200	0	100,0	0
20	199	1	99,5	3
-20	194	6	97,0	0
30	187	13	93,5	7
-30	186	14	93,0	5
40	139	61	69,5	11
-40	110	90	55,0	15

Tab. 4 Výkonnost klasifikátoru v závislosti na rotaci okolo osy Y FEI

Pro zhodnocení výkonnosti klasifikátoru v dané problematice u FEI databáze, dosahujeme relevantnějších výsledků, jelikož obsahuje větší počet vzorků po jemném odstupňování. Z tabulky lze vidět, že do vychýlení obličeje  $\pm 30^\circ$  má klasifikátor přijatelnou úroveň TPR 93 %. U větších odchylek dosahuje TPR horší přesnosti.

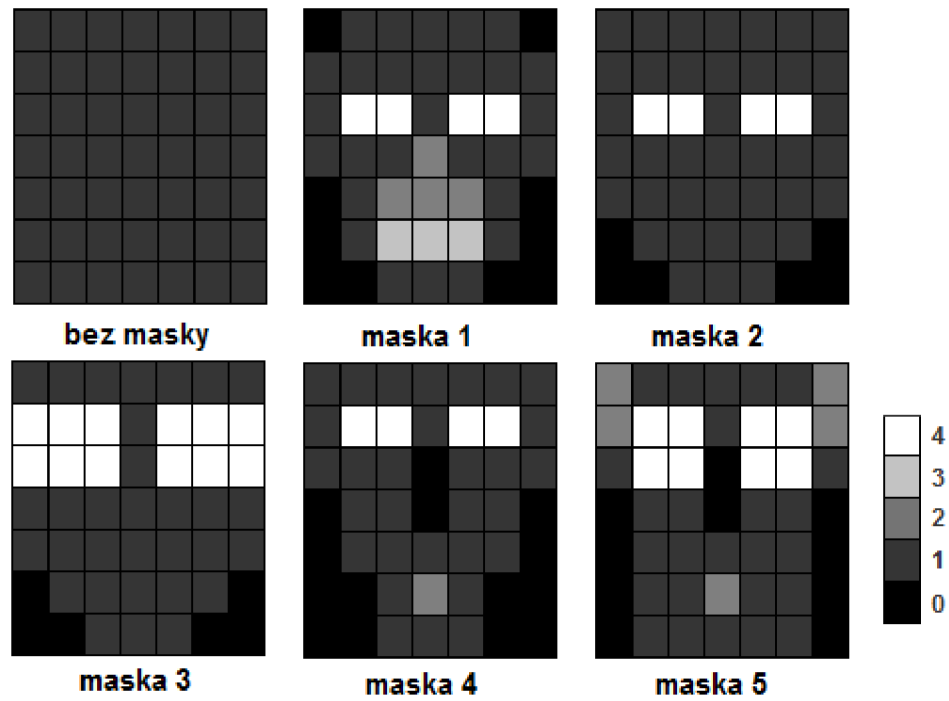
GTAV pootočení obličeje [°]	TP	FN	TPR [%]	FP
30	31	13	70,5	1
-30	27	17	61,4	7

Tab. 5 Výkonnost klasifikátoru v závislosti na rotaci okolo osy Y GTAV

U GTAV databáze bylo použito pouze pootočení o  $\pm 30^\circ$ . U tohoto testu je vidět špatný TPR a další test při  $\pm 45^\circ$  už by nebyl významný.

## 8.2 Závislost rozpoznání na typu masky

U rozpoznání obličeje hraje důležitou roli předzpracování obrazu zmíněné v kapitole 6.1. Dalším rozhodujícím faktorem je volba masky a přiřazení váhy k jednotlivým blokům v obličeji.



Obr. 33 Příklady testovaných masek

U testování přesnosti rozpoznávacího algoritmu, je potřeba vytvořit sadu trénovacích a testovacích dat. Trénovací data v našem případě jsou neutrální obličeje z databáze při čelním pohledu. Jako testovací data jsou obličeje s jinými světelnými podmínkami (GTAV\_ILL, FEI\_ILL) a různými výrazů v obličeji lišícími se od výrazů v trénovací sadě (GTAV\_EXP, FEI\_EXP).

	GTAV_EXP		GTAV_ILL	
	Detekce TPR [%]	Rozpoznání TPR [%]	Detekce TPR [%]	Rozpoznání TPR [%]
bez masky	97,7	86,0	93,2	84,0
maska 1	97,7	79,0	93,2	70,7
maska 2	97,7	88,4	93,2	82,9
maska 3	97,7	88,4	93,2	82,5
maska 4	97,7	83,7	93,2	78,0
maska 5	97,7	88,4	93,2	85,4

Tab. 6 Závislost úspěšnosti rozpoznávání na volbě masky GTAV

	FEI_EXP		FEI_ILL	
	detekce TPR [%]	rozpoznání TPR [%]	detekce TPR [%]	rozpoznání TPR [%]
bez masky	100	88,5	100	90,5
maska 1	100	84,5	100	88,0
maska 2	100	88,0	100	92,0
maska 3	100	88,5	100	90,5
maska 4	100	89,5	100	92,5
maska 5	100	91,5	100	94,5

**Tab. 7 Závislost úspěšnosti rozpoznávání na volbě masky FEI**

Porovnání úspěšnosti v závislosti na typu masky závisí na blocích, kterým přidělujeme větší váhu. Z tabulek lze vyčíst že váhování úst zhoršuje rozpoznávací schopnost, stejně jako přiřazení větší váhy v oblasti nosu (lze vidět zejména u masky 1). Volba vhodné masky rovněž nuluje hodnoty, které nejsou nápomocné při rozpoznání (dolní a krajní bloky obrazu).

Nejlepších výsledků dosáhla maska 5, u které je přiřazena hodnota 2 k bloku úst. Jako výhodou se projevilo anulovat hodnoty ležící na úrovni nosu. Rovněž výhodou je přiřazení největší váhy k oblasti obočí a očním víčkům. Maska 5 byla implementována v metodě `compute_image_LBP`. Příklady správného rozpoznání obličeje jsou umístěny v přílohách B a C. Chybné rozpoznání je znázorněno v příloze D.

### 8.3 Závislost rozpoznání na pootočení

Pro srovnání výsledků rozpoznání poslouží opět FEI databáze.

FEI	detekce TPR [%]	rozpoznání TPR [%]
-10°	100	89,0
10°	100	94,5
-20°	97	40,3
20°	99	64,8

**Tab. 8 Závislost úspěšnosti rozpoznávání při rotaci okolo osy Y**

Tabulka 8 potvrzuje teoretické předpoklady. Se zvyšujícím se úhlem pootočení klesá schopnost rozpoznání obličeje. Odchylka  $\pm 10^\circ$  není pro schopnost rozpoznávání ještě natolik citelná, jako  $\pm 20^\circ$ .

## 9 ZÁVĚR

Cílem diplomové práce bylo seznámit se s metodami pro detekci a rozpoznání obličejů v obraze. V teoretické části jsou uvedeny základní pojmy související s počítačovým viděním a detekcí obličejů. Následně je proveden přehled metod týkající se zmíněné problematiky a vybrané metody jsou popsány detailněji.

V praktické části jsem vybral pro detekci obličejů metodu Viola Jones zejména kvůli své výpočetní nenáročnosti a robustnosti. Klasifikátor je natrénován na sadu Haarových filtrů. Při procházení obrazu jsou vypočítávány odezvy detekčního okna na zmíněné filtry. Detekční okno mění svoji velikost podle nastavených parametrů. Velikost detekčního okna je uzpůsobeno v závislosti na dalším zpracování na minimální hodnotu 90 x 90 pixelů. Pro zlepšení přesnosti klasifikátoru je před detekcí provedena ekvalizace histogramu.

Pro rozpoznání obličejů byla vybrána metoda LBP(8,1). Detekovaný obličej je převeden na rozlišení 126 x 147 pixelů a rozdělen do 49 bloků, z nichž pro každý blok je vypočítán histogram. Všechny histogramy jsou připojovány do velkého pole (49 x 255 hodnot) a převedeno na histogram. Před výpočtem LBP je u detekovaného obličejů provedena světelná normalizace. Pro porovnávání dvou obličejů, které zastupují histogramy je vybrána statistická metoda Chi – Square, která vrací v případě absolutní shody hodnotu 0.

Obě vybrané metody byly implementovány pomocí knihovny OpenCV do grafického uživatelského rozhraní umožňujícího detekovat obličej ze statického obrazu i z kamery. Obličej je možno uložit do databáze, kde jsou přítomny obličejů z databází GTAV a FEI. Pro rozpoznání obličejů je hledána minimální vzdálenost histogramu zvoleného kandidáta s databází. Po nalezení minima je zobrazen obličej z databáze. Další funkcí uživatelského rozhraní je online detekce a rozpoznání. Při snímání obrazu z kamery jsou detekovány obličejů a je jim přiřazen barevný rámeček. Pod zobrazovaným oknem jsou každé 2s k barevným rámečkům doplněna výsledná jména z databáze. Vylepšení v této oblasti by přineslo trasování obličejů, které by snížilo výpočetní náročnost algoritmu, který nyní detekuje obličej na po sobě jdoucích snímcích.

Poslední částí v praktické realizaci je vyhodnocení procentuální úspěšnosti jednotlivých metod v závislosti na různých parametrech. Schopnost klasifikátoru detekce obličejů je testována na BioID databázi v závislosti na různé velikosti detekčního okna a parametru jeho zvětšení v následujícím iteračním kroku. Dalším testem byla schopnost detekce v závislosti na rotaci obličejů. Při nastavení parametru zvýšení detekčního okna o 20% a minimální velikosti 90 x 90 jsem dosáhl s předzpracováním obrazu přesnosti 96,1%. Zlepšení v porovnání bez předzpracování je o 0,9%.

Rozpoznávací přesnost byla testována na databázích FEI a GTAV v různých světelných podmínkách, obličejových výrazech a rotaci obličeje. Po aplikaci masky č.5 jsem v testu na obličejové výrazy dosáhl přesnosti 88,4% u GTAV databáze a 91,5% u FEI databáze. Rozpoznání v závislosti na jiných světelných podmínkách v porovnání s podmínkami při pořízení databáze dosáhlo přesnosti 85,4% u GTAV a 94,5% u FEI databáze.

V závěru bylo vytvořeno video názorně ukazující funkčnost aplikace. Video je na přiloženém CD.

## 10 SEZNAM POUŽITÉ LITERATURY

- [1]. MATAS, Jiří. *Detekce objektů pomocí scanning window* [online prezentace]. 2010 cit[2012-04-21]. Dostupné z: <http://cw.felk.cvut.cz/doku.php/courses/a4m33mpv/start>
- [2]. KALOVÁ, Ilona. *Předzpracování obrazu* [prezentace]
- [3]. KALOVÁ, Ilona. *Segmentace obrazu* [prezentace]
- [4]. HLAVÁČ, V., ŠONKA M. *Počítačové vidění*. Grada, Praha 1992
- [5]. XIONG, Ziyou. *An Introduction to Face Detection and Recognition* [online prezentace]. cit [2012-03-15]. Dostupné z: [http://web.cecs.pdx.edu/~mperkows/CLASS\\_479/Biometrics/FaceRecognition/](http://web.cecs.pdx.edu/~mperkows/CLASS_479/Biometrics/FaceRecognition/)
- [6]. GASPARINI, Francesca, SCHETTINI, Riamondo. *Skin segmentation using multiple tresholding*. [online]. [cit. 2012-05-08]. Dostupné z: <http://www.ivl.disco.unimib.it/papers2003/EI06-EI109%20Skin-paper.pdf>
- [7]. ŽÁRA, Jiří a Jiří ŽÁRA. *Moderní počítačová grafika*. Vyd 1. Brno: Computer Press, 2004, 609 s. ISBN 80-251-0454-0.
- [8]. GETREUER, Pascal. *Converting Color Representations* [online]. [cit. 2012-05-08]. Dostupné z: <http://www.getreuer.info/home/colorspace>
- [9]. KHANCHI, Sara. *Eye Detection in Color Images*. [online]. 2007 [cit. 2012-01-06]. Dostupné z: [profdoc.um.ac.ir/articles/a/359.pdf](http://profdoc.um.ac.ir/articles/a/359.pdf)
- [10]. TSALAKANIDOU, Filareti a Sotiris MALASSIOTIS. *Real-time 2D 3D facial action and expression recognition*. *Pattern Recognition* [online]. 2010, roč. 43, č. 5, s. 1763-1775 [cit. 2012-05-10]. ISSN 00313203. DOI: 10.1016/j.patcog.2009.12.009. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0031320309004786>
- [11]. VIOLA, Paul a Michael J. JONES, *Robust Real-Time Face Detection*, *International Journal of Computer Vision* 57(2), 2004.



- [12]. BRIMBECOMBE, Phil. *Face Detection using Neural Networks* [online]. [cit. 2012-03-10]. URN: 1046063. Dostupné z: [http://personal.ee.surrey.ac.uk/Personal/T.Windeatt/ug\\_projects/brimblecombe/](http://personal.ee.surrey.ac.uk/Personal/T.Windeatt/ug_projects/brimblecombe/).
- [13]. PŘINOSIL, Jiří. *PŘESNÉ SLEDOVÁNÍ POHYBU TVÁŘÍ V REÁLNÉM ČASE*. [online]. roč. 2009, č. 56 [cit. 2012-04-12]. ISSN 1213-1539. Dostupné z: <http://www.elektrorevue.cz/cz/clanky/zpracovani-signalu/20/presne-sledovani-pohybu-tvari-v-realnem-case/>
- [14]. SEE, Alex, Kok BIN a Liaw Yee KANG. Face detection and tracking utilizing enhanced CAMSHIFT model. *International journal of innovative computing, information: IJICIC* [online]. 2007, s. 597-608 [cit. 2012-04-22]. ISSN 1349-4198. Dostupné z: [citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.132.6939&rep=rep1&type=pdf](http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.132.6939&rep=rep1&type=pdf)
- [15]. Receiver operating characteristic. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001- [cit. 2012-03-17]. Dostupné z: [http://en.wikipedia.org/wiki/Receiver\\_operating\\_characteristic](http://en.wikipedia.org/wiki/Receiver_operating_characteristic)
- [16]. ORAVEC, Miloš et al. (2011). Efficiency of Recognition Methods for Single Sample per Person Based Face Recognition, Reviews, Refinements and New Ideas in Face Recognition, Dr. Peter Corcoran (Ed.), ISBN: 978-953-307-368-2, InTech, [cit. 2012-03-17]. Dostupné z: <http://www.intechopen.com/books/reviews-refinements-and-new-ideas-in-face-recognition/efficiency-of-recognition-methods-for-single-sample-per-person-based-face-recognition>
- [17]. ENAMI, Shervin. *Introduction to Face Detection and Face Recognition*. Shervin Enami [online]. [cit. 2012-02-10]. Dostupné z: <http://www.shervinemami.info/faceRecognition.html>
- [18]. *Face Recognition using Eigenfaces*. [online]. [cit. 2012-03-7]. Dostupné z: <http://www.cs.princeton.edu/~cdeco/eigenfaces/>

- [19]. WU, Jianxin a Zhi-Hua ZHOU. Face Recognition with One Training Image per Person. [online]. 2002, roč. 23, č. 14, s. 1711-1719 [cit. 2012-05-11]. Dostupné z:  
<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.92.1053&rep=rep1&type=pdf>
- [20]. JAIN, C. *Intelligent biometric techniques* [online]. Vyd. 1. New York: CRC Press, 1999, s. 355-396 [cit. 2012-04-17]. ISBN 0-8493-2055-0.
- [21]. European Journal of Human Genetics. In: LOOS, Hartmut S et al. *European journal of human genetics: EJHG* [online]. [cit. 2012-03-28]. ISSN 1018-4813. DOI: 10.1038/sj.ejhg.5200997. Dostupné z:  
<http://www.nature.com/ejhg/journal/v11/n8/full/5200997a.html>
- [22]. PIETIKÄINEN, Matti. Local Binary Patterns. *Scholarpedia* [online]. 2010, roč. 5, č. 3, s. 9775- [cit. 2012-05-13]. ISSN 1941-6016. DOI: 10.4249/scholarpedia.9775. Dostupné z:  
[http://www.scholarpedia.org/article/Local\\_Binary\\_Patterns](http://www.scholarpedia.org/article/Local_Binary_Patterns)
- [23]. AHONEN, Timo, Abdenour HADID a Matti PIETIKÄINEN. Face Description with Local Binary Patterns: Application to Face Recognition. [online]. [cit. 2012-05-13]. Dostupné z:  
[http://www.csee.wvu.edu/~ross/courses/sp12/biom693/reading/AhonenLBPFace\\_PAMI2006.pdf](http://www.csee.wvu.edu/~ross/courses/sp12/biom693/reading/AhonenLBPFace_PAMI2006.pdf)
- [24]. PIETIKÄINEN, Matti. *Computer vision using local binary patterns* [online]. London [etc.]: Springer, 2011 [cit. 2012-05-13]. ISBN 978-085-7297-488. Dostupné z:  
<https://springerlink3.metapress.com/content/k217613216142w5w/resource-secured/?target=fulltext.pdf&MUD=MP&sid=eb1z1mli3rkwjatw11ybe2pn&sh=www.springerlink.com>
- [25]. LIENHART, Rainer a Jochen MAYDT. *An Extended Set of Haar-like Features for Rapid Object Detection*. IEEE ICIP 2002, Vol. 1, pp. 900-903, Sep. 2002 [online]. [cit. 2012-05-13]. Dostupné z: <http://mmc36.informatik.uni-augsburg.de/mediawiki/images/c/c3/>
- [26]. SEO, Naotoshi. Tutorial :OpenCV haartraining. [online]. [cit. 2012-02-11]. Dostupné z: <http://note.sonots.com/SciSoftware/haartraining.html>

- [27]. ZHOU, S. *Analysis and modeling of faces and gestures: third international workshop*, AMFG 2007 Rio de Janeiro, Brazil, October 20, 2007 : proceedings [online]. New York: Springer, c2007, s. 168-182 [cit. 2012-04-03]. ISBN 978-3-540-75689-7. Dostupné z : <http://lear.inrialpes.fr/pubs/2007/TT07/>
- [28]. GTAV Face Database. [online]. [cit. 2012-04-28]. Dostupné z: <http://gps-tsc.upc.es/GTAV/ResearchAreas/UPCFaceDatabase/GTAVFaceDatabase.htm>
- [29]. FEI Face Database. [online]. [cit. 2012-04-28]. Dostupné z: <http://fei.edu.br/~cet/facedatabase.html>
- [30]. Face Data. [online]. [cit. 2012-04-28]. Dostupné z: <http://cbcl.mit.edu/software-datasets/FaceData2.html>
- [31]. BioID face database. BIOD. [online]. [cit. 2012-04-28]. Dostupné z: <https://www.bioid.com/downloads/software/bioid-face-database.html>

# SEZNAM POUŽITÝCH ZKRATEK A SYMBOLŮ

RGB – Red,Green,Blue

HSV – Hue,Saturation, Value

ASM – Active shape model

TPR – True positive rate

TP – True positive

TN- True negative

FN – False negative

FP – False positive

ROC – receiver operating characteristic

PCA – Principal component analysis

EBGM – Elastic Bunch Graph Matching

LBP – Local binary pattern

JPG – Joint Photographix Expert Group (JPEG)

BMP- BitMaP

XML – eXtensible Markup Language

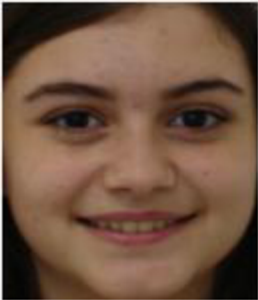


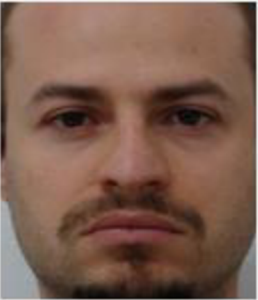


# SEZNAM PŘÍLOH

A Příklady správné a špatné detekce na BioID databázi.....	62
B Správné rozpoznání FEI databáze.....	63
C Správné rozpoznání GTAV databáze- různé světelné podmínky.....	64
D Chybné rozpoznání.....	65
E Správné rozpoznání v závislosti na rotaci obličeje.....	66
F Chybné rozpoznání v závislosti na rotaci obličeje.....	66
G Obsah CD.....	66

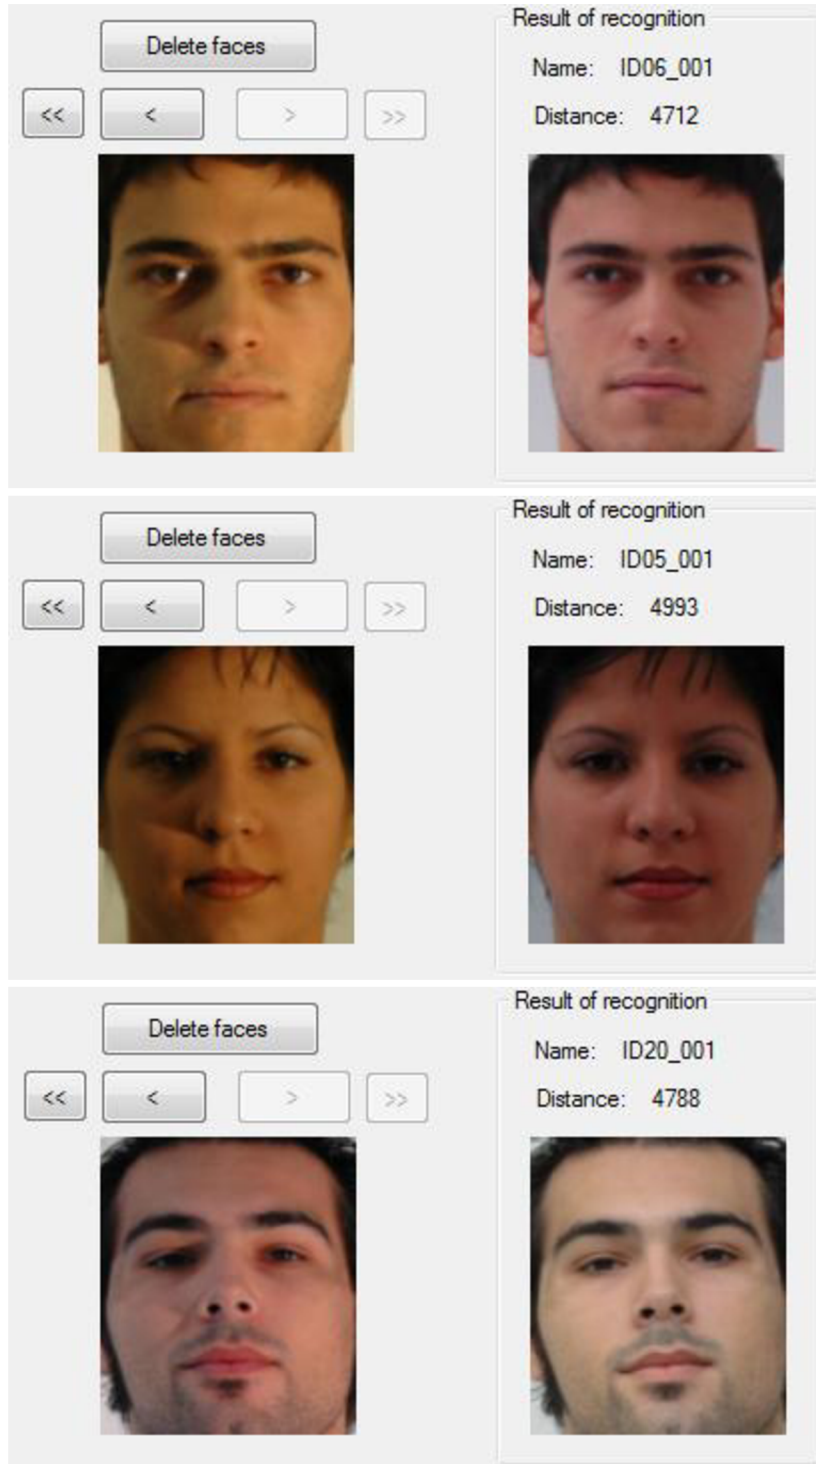
**A** Příklady správné a špatné detekce na BioID databázi



## B Správné rozpoznání FEI databáze

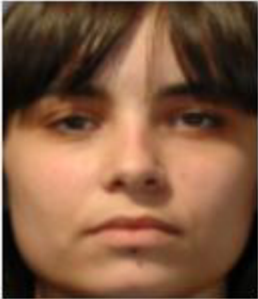
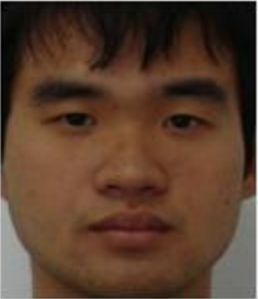




<p>Delete faces</p> <p>&lt;&lt; &lt; &gt; &gt;&gt;</p> 	<p>Result of recognition</p> <p>Name: 11-11</p> <p>Distance: 4118</p> 
<p>Delete faces</p> <p>&lt;&lt; &lt; &gt; &gt;&gt;</p> 	<p>Result of recognition</p> <p>Name: 6-11</p> <p>Distance: 6899</p> 
<p>Delete faces</p> <p>&lt;&lt; &lt; &gt; &gt;&gt;</p> 	<p>Result of recognition</p> <p>Name: 16-11</p> <p>Distance: 4239</p> 

### C Správné rozpoznání GTAV databáze- různé světelné podmínky






## D Chybné rozpoznání

<p>Delete faces</p> <p>&lt;&lt; &lt; &gt; &gt;&gt;</p> 	<p>Result of recognition</p> <p>Name: 10-11</p> <p>Distance: 8519</p> 
<p>Delete faces</p> <p>&lt;&lt; &lt; &gt; &gt;&gt;</p> 	<p>Result of recognition</p> <p>Name: 136-11</p> <p>Distance: 5514</p> 
<p>Delete faces</p> <p>&lt;&lt; &lt; &gt; &gt;&gt;</p> 	<p>Result of recognition</p> <p>Name: ID06_001</p> <p>Distance: 5754</p> 

### E Správné rozpoznání v závislosti na rotaci obličeje



### F Chybné rozpoznání v závislosti na rotaci obličeje



### G Obsah CD

*Adresář*

/text

/projekt

/video

*Obsah*

obsahuje elektronickou podobu diplomové práce

zdrojové soubory demonstrační aplikace

videokázka funkčnosti aplikace