

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky a
komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2021

Bc. Michal Koupil



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

BIOMETRIE POMOCÍ ROZPOZNÁVÁNÍ TVÁŘE

BIOMETRICS USING FACE RECOGNITION

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Michal Koupil

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jan Odstrčilík, Ph.D.

BRNO 2021



Diplomová práce

magisterský navazující studijní program **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

Student: Bc. Michal Koupil

ID: 194697

Ročník: 2

Akademický rok: 2021/22

NÁZEV TÉMATU:

Biometrie pomocí rozpoznávání tváře

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou biometrie a zaměřte se konkrétně na metody využívající k identifikaci osob rozpoznávání tváře. 2) Proveďte literární rešerši biometrických metod využívajících rozpoznávání tváře. 3) V rámci rešerše se zabývejte dostupností veřejných biometrických databází a vhodné databáze pro biometrii pomocí rozpoznávání tváře blíže popište. 4) Navrhněte a implementujte vybranou metodu pro rozpoznávání tváře s využitím nalezených volně dostupných databází. 5) Rozšiřte navrženou metodu pro účely biometrické identifikace osob a vhodně otestujte její úspěšnost. 6) Proveďte diskusi dosažených výsledků a zhodnoťte účinnost a využitelnost aplikovaného řešení.

DOPORUČENÁ LITERATURA:

[1] KORTLI, Y.; JRIDI, M.; AL FALOU, A. et al. Face Recognition Systems: A Survey. *Sensors*, 2020, roč. 20, č. 2.

[2] DARGAN, S.; KUMAR, M. A comprehensive survey on the biometric recognition systems based on physiological and behavioral modalities. *Expert Systems with Applications*, 2020, roč. 143, č. 4.

Termín zadání: 7.2.2022

Termín odevzdání: 20.5.2022

Vedoucí práce: Ing. Jan Odstrčilík, Ph.D.

prof. Ing. Ivo Provazník, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor semestrální práce nesmí při vytváření semestrální 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

Tato práce je zaměřena na detekci obličejů ve snímku a jejich následné rozpoznání v rámci dané databáze. Detekce obličeje ve snímku byla v praktické části realizována pomocí Viola-Jones algoritmu, k rozpoznání obličejů bylo použito metod PCA (*Principal Component Analysis*) a LBPH (*Local Binary Pattern Histograms*). Implementovaný algoritmus byl testován na volně dostupných obrazových databázích. Celková úspěšnost detekce obličeje byla 93,4 %. Celková úspěšnost rozpoznání obličeje byla metodou PCA 88,1 % a metodou LBPH 93,1 %. Metoda LBPH je schopna lépe než metoda PCA rozpoznávat u obrazových sad, kde lidé nejsou ideálně nasnímáni. Při testování na kvalitních datech pro biometrii fungují obě metody spolehlivě, PCA za kratší časový úsek.

Klíčová slova

Biometrie, lokalizace obličeje, Viola-Jones algoritmus, rozpoznání obličeje, PCA, LBPH

Abstract

This work is focused on a face detection in a picture and subsequent recognition of the face in its respective database. Face detection had been implemented using Viola-Jones algorithm. To recognize the face afterwards, PCA (*Principal Component Analysis*) a LBPH (*Local Binary Pattern Histograms*) had been used. Implemented algorithm had been tested on freely accesible biometric databases. Overall success rate of face detection was 93,4 %. Overall success rate of face recognition using PCA was 88,1 % and with LBPH it was 93,1 %. Of the two methods for face recognition, LBPH method has better ability to perform recognition with data, that do not possess ideal parameters for biometrics. With data suitable for biometrics, both of the methods perform well, with PCA being faster.

Keywords

Biometrics, face localization, Viola-Jones algorithm, face recognition, PCA, LBPH

Bibliografická citace

KOUPIL, Michal. *Biometrie pomocí rozpoznávání tváře* [online]. Brno, 2022 [cit. 2022-05-07]..
Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních
technologií, Ústav biomedicínského inženýrství. Vedoucí práce Ing. Jan Odstrčilík, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení studenta:	Bc. Michal Koupil
VUT ID studenta:	194 697
Typ práce:	Diplomová práce
Akademický rok:	2021/22
Téma závěrečné práce:	Biometrie pomocí rozpoznávání tváře

Prohlašuji, že svou závěrečnou práci jsem vypracoval samostatně pod vedením vedoucího závěrečné 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 závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné 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: 7. května 2021

podpis autora

Poděkování

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

V Brně dne: 7. května 2021

podpis autora

Obsah

SEZNAM OBRÁZKŮ	8
SEZNAM TABULEK	9
1. ÚVOD	10
2. BIOMETRIE	11
2.1 ROZDĚLENÍ BIOMETRICKÝCH SYSTÉMŮ.....	11
2.2 CHARAKTERISTIKY A VLASTNOSTI	12
2.3 HODNOCENÍ SPOLEHLIVOSTI.....	13
3. BIOMETRIE OBLIČEJE	15
3.1 PRINCIP BIOMETRIE NA ZÁKLADĚ 2D SNÍMKŮ OBLIČEJE	15
3.2 DETEKCE OBLIČEJE	15
3.2.1 <i>Detekce obličeje na základě barvy kůže</i>	16
3.2.2 <i>Detekce obličeje na základě předdefinovaných vzorů</i>	18
3.2.3 <i>Detekce obličeje na základě HOG</i>	21
3.2.4 <i>Detekce obličeje na základě Viola-Jones algoritmu</i>	23
3.3 ROZPOZNÁNÍ OBLIČEJE	24
3.3.1 <i>Metoda PCA</i>	24
3.3.2 <i>Metoda SIFT</i>	26
3.3.3 <i>Metoda LDA</i>	27
3.3.4 <i>Metoda ASM</i>	28
3.3.4 <i>Metoda LBPH</i>	29
4. BIOMETRICKÉ DATABÁZE	31
5. IMPLEMENTOVANÝ ALGORITMUS	34
5.1 DETEKCE OBLIČEJE – VIOLA-JONES ALGORITMUS	34
5.2 ROZPOZNÁNÍ OBLIČEJE - METODA PCA	36
5.3 ROZPOZNÁNÍ OBLIČEJE - METODA LBPH	40
6. VÝSLEDKY	42
6.1 ÚSPĚŠNOST DETEKCE	42
6.2 ÚSPĚŠNOST ROZPOZNÁNÍ	42
6.3 SROVNÁNÍ METOD.....	43
6.3.1 <i>Normální osvětlení</i>	44
6.3.2 <i>Špatné osvětlení</i>	44
6.3.3 <i>Sluneční brýle</i>	44
6.3.4 <i>Různé úhly pořízení snímku</i>	45
6.3.5 <i>Vousy / pokrývka brady</i>	45
6.3.6 <i>Časová náročnost</i>	46
6.3.7 <i>Hodnocení spolehlivosti</i>	46
7. DISKUZE	49
ZÁVĚR	51
LITERATURA	52

SEZNAM OBRÁZKŮ

3.1	Blokové schéma detekce obličeje na základě barvy kůže.....	16
3.2	Pixely označeny jako kůže v podprostorech H-S(vlevo) a H-V(vpravo).....	17
3.3	Rozložení barvy kůže pro jednotlivé kanály v $Y C_G C_R$ barevném modelu [7].....	18
3.4	Blokové schéma pro detekci obličeje metodou předdefinovaných vzorů [8]	19
3.5	Výpočet masky pomocí vlastních vektorů [9]	19
3.6	Obraz s odečtenou lokální střední hodnotou [10].....	20
3.7	Blokové schéma pro detekci obličeje na základě HOG.....	21
3.8	Aplikace Sobelovy masky na vstupní obraz [13]	22
3.9	Originální a integrální obraz [2]	22
3.10	Dvoupříznakové filtry A a B, třípříznakový filtr C, čtyřpříznakový filtr D [14].....	23
3.11	Vstupní množina dat(vlevo) a z těchto dat vypočítaná „průměrná tvář“(vpravo) [15].....	25
3.12	Body zájmu na vzorových obrazech (nahore) a nalezené shody deskriptorů (dole) [16]	27
3.13	Sady bodů dvou obrazů: sady bodů nebyly separovány(a), sady bodů byly separovány(b) [17]	27
3.14	Každý bod je při hledání proložen normálou. Upraveno [19]	28
3.15	Pozice modelu v průběhu algoritmu [19]	29
3.16	LBP procedura, upraveno [22]	30
3.17	LBPH procedura, upraveno [22].....	30
4.1	Příklad nižší vnitrotřídní variability.....	31
4.2	Příklad vyšší vnitrotřídní variability	32
4.3	Ukázka trénovacích dat ze sady 2.....	32
4.4	Ukázka testovacích dat ze sady 5	33
4.5	Ukázka testovacích dat ze sady 6	34
4.6	Ukázka testovacích dat ze sady 9	34
4.7	Ukázka testovacích dat ze sady 10	34
5.1	Ukázka průběhu algoritmu Viola-Jones na obrazu z trénovací databáze	35
5.2	Ukázka nevyhovujících obrazů.....	35
5.3	Multidetekce pomocí algoritmu Viola-Jones.....	36
5.4	Prvních 100 vlastních obličejů ze Sady 2	37
5.5	Úspěšné rozpoznání ze sady 1	38
5.6	Úspěšné rozpoznání ze sady 3	39
5.7	Úspěšné rozpoznání ze sady 5	39
5.8	Neúspěšné rozpoznání ze sady 1	40
5.9	Výsledek převedení vstupního obrazu do LBP reprezentace	41
5.10	Finální histogram vstupního obrazu	42
6.1	Nedetekovatelné snímky vlivem velmi špatného osvětlení	43
6.2	Špatně osvětlené snímky	45

SEZNAM TABULEK

4.1	Detaily o datasetech.....	31
6.1	Podíl úspěšných lokalizací obličeje	42
6.2	Úspěšnost rozpoznání testovacích obrazů metodou PCA	43
6.3	Úspěšnost rozpoznání testovacích obrazů metoudou LBPH	43
6.4	Úspěšnost algoritmu při testování na sadě se špatným osvětlením	44
6.5	Úspěšnost algoritmu při testování na sadě, kde měli lidé nasazené sluneční brýle	45
6.6	Úspěšnost algoritmu při testování na sadě snímané pod různými úhly	45
6.7	Úspěšnost algoritmu při testování na sadě, kde měli lidé zakrytou bradu	45
6.8	Časová náročnost.....	46

1. ÚVOD

Mezi biometrickými systémy jsou identifikační systémy fungující na principu získání obličejových rysů a následné práce s nimi dominantní. Oproti jiným metrikám je biometrie obličeje značně rozšířenou a populární metodou, a to z mnoha důvodů: Lidské obličeje jsou obecně jedinečné a univerzální [1], taktéž ochota lidí poskytnout snímek obličeje je vyšší než u jiných metrik. Uplatnění nalézá v kriminalistice (např. databáze hledaných), stále rozšířenější je ale i v komerčních aplikacích (např. autorizace v mobilních telefonech).

Biometrie obličeje se obecně skládá z detekce – nalezení obličeje v rámci obrazu, a poté rozpoznání – jeho identifikace v rámci poskytnuté databáze. Vstupními informacemi jsou sady obrazových dat. Metod pro detekci a rozpoznání obličeje je velké množství, a i když existuje obecné schéma biometrických systémů, jednotlivé metody se velmi liší. Rozpoznávání obličeje je pro lidi nejintuitivnější a nejpřirozenější metoda identifikace okolních jedinců. Při jeho programové realizaci se však můžeme setkat s řadou překážek. Hlavní překážkou je vysoká vnitrotřídní variabilita [1] (např. mimika, změna účesu, doplňky).

Cílem této práce je implementovat algoritmus, sloužící k biometrii obličeje, přičemž jako vstupní data bude používat volně dostupné obrazové databáze. Použitá metoda detekce obličeje se nazývá Viola-Jones algoritmus a jako metoda rozpoznání obličeje byly zvoleny metody PCA (*Principal component analysis*) a LBPH (*Local Binary Pattern Histograms*). Tyto metody jsou v obecné části této práce teoreticky popsány a poté v praktické části implementovány v programovém prostředí Python 3.7. a testovány na sadách obrazů. Je srovnána schopnost správně rozpoznat obrazy při různých zhoršených podmínkách kvality snímaných obličejů, se kterými je možné se běžně setkat – zastínění obličejů, doplňky (sluneční brýle, pokrývka brady) a snímání z různých úhlů. V závěru práce jsou shrnuty výsledky testování navrženého algoritmu na jednotlivých sadách obrazů a je také popsáno, jakým způsobem by mohla práce dále pokračovat.

2. BIOMETRIE

Biometrie představuje metody, kterými jsou měřeny a získávány určité charakteristické vlastnosti neboli rysy. Předpokladem je, že každý jedinec může být na základě těchto rysů přesně identifikován. Můžeme je rozdělit do dvou skupin. První z nich jsou anatomické rysy, mezi které patří například obličej, otisk prstu, sítnice nebo duhovka. Druhá skupina jsou behaviorální rysy, mezi které patří například chůze nebo mimika obličeje a pohyby rtů [1].

Používání biometrie k identifikaci jedinců je v současné době na vzestupu. Oblastí, ve kterých je biometrie využívána, je mnoho. Jednou z nich je autorizace, tedy spojení člověka s počítačem. Při použití identifikačních údajů jako je heslo nebo osobní číslo hrozí nebezpečí autorizace neoprávněnou osobou. Použití biometrie může těmto problémům efektivně předcházet. Příkladem z každodenního života je autorizace pomocí otisku prstu či obličeje. Z dalších oblastí, ve kterých je biometrie používána, je možné zmínit bezpečnost a její složky, tedy například kamery na letištích či v bankách, kde pomocí systémů využívajících biometrii může být detekován nebezpečný jedinec.

S výše popsanými výhodami jako jsou zvýšení bezpečnosti a pohodlí či eliminace pokusů o neoprávněnou autorizaci se ovšem pojí i nevýhody jako možnost napadení samotného biometrického systému či narušení a nezachování soukromí.

2.1 Rozdělení biometrických systémů

Obecně lze říct, že biometrický systém se skládá ze tří stavebních prvků:

- **Předzpracování** – normalizace dat (např. vyrovnání jasových hodnot u práce s databází obrazů)
- **Registrace** – uložení biometrických rysů do databáze
- **Verifikace/Identifikace** – porovnání aktuálních biometrických rysů s údaji v databázi. Provedením získáme požadovaný výsledek, tedy nalezení shody. U verifikace hovoříme o porovnání 1:1 (záznam je porovnáván s jedním výstupem). U identifikace se jedná o porovnání 1:N (záznam je porovnáván s větším množstvím ostatních). [2]

Biometrické identifikační systémy můžeme dělit podle komplexnosti na unimodální a multimodální. Unimodální systémy používají pouze jeden příznak jedné vlastnosti. Jejich přirozenou výhodou jsou nižší pořizovací náklady, ovšem za cenu nižší spolehlivosti. V praxi se setkáváme zejména s těmito systémy. Multimodální systémy pak používají buď více příznaků dané vlastnosti (např. u podpisu statická a dynamická forma), nebo více vlastností (např. rozpoznání obličeje a zároveň řeči).

2.2 Charakteristiky a vlastnosti biometrických systémů

Při výběru biometrického systému je třeba brát v potaz charakteristiky biometrických vlastností, podle kterých rozhodneme o vhodnosti nasazení systému v dané situaci.

Mezi tyto faktory mohou být zařazeny:

- Univerzalita – každý uživatel by měl mít požadovanou vlastnost
- Jedinečnost – každý uživatel by měl být mít danou vlastnost dostatečně unikátní
- Konstantnost – daná vlastnost zůstává neměnná v čase
- Měřitelnost – danou vlastnost lze získat a kvantitativně rozměřit
- Akceptance – ochota lidí poskytnout data
- Odolnost proti falšování – obtížnost data zfalšovat
- Finanční náklady na pořízení – cena pořízení systému

Neexistuje univerzální biometrická vlastnost, která by efektivně mohla splnit kritéria všech systémů. Jednotlivé vlastnosti jsou aplikovatelné na specifické systémy, které na základě vybrané vlastnosti operují. Nyní si ve stručnosti uvedeme některé biometrické vlastnosti, na základě kterých mohou vznikat detekční systémy.

Biometrie podle otisku prstů

Otisky prstů jsou nejpoužívanější a také nejvíce probádanou a zkušenostmi podloženou biometriku [1]. Tuto techniku lze použít k rozlišování velkého vzorku obyvatel s vysokou spolehlivostí, což je vhodné mimo jiné také proto, že jsou otisky prstů právně akceptovatelné. Tato metoda tedy našla uplatnění v kriminalistice. Další uplatnění nalézá jako ochrana přístupu do mobilních zařízení, je také zastoupena v přístupových či docházkových systémech.

Biometrie podle geometrie ruky

Biometrické systémy založené na geometrii ruky pracují většinou s 2D informací o geometrii ruky – její siluetou, nasnímanou zespoda (dlaň ruky) nebo shora (hřbet ruky) [1]. Výhoda těchto systémů tkví v jednoduchosti zpracování vstupního obrazu. Uplatnění tato metoda nalézá například v přístupových systémech, kde konkuruje metodě podle otisku prstů. Oproti předchozí metodě má ovšem značné omezení. Není vhodná k rozlišování velkého vzorku osob, je zde také faktor variance – informace z ruky se v průběhu života mohou měnit. Limitující je také fyzická velikost systému, která znemožňuje použití metody v přenosných zařízeních.

Biometrie podle krevního průtoku

Jedná se o novou a slibnou metodu, která je založena na krevním průtoku pozorovaného. Jsou měřeny části cévního řečiště, které jsou pro každého jedince stejně jedinečné jako například otisk prstu [3]. Metoda má dobrou spolehlivost a akceptovatelnost, lze ji navíc obtížně zfalšovat. I když metoda zatím není považována za tak spolehlivou jako metoda podle otisku prstů, vzniká v současné době množství projektů zabývajících se registračními systémy osob, založených právě na této metodě.

Biometrie podle duhovky

Tato metoda je velice přesná a používá se v odvětvích s vysokými bezpečnostními požadavky. Pokud jde o možnost falzifikátu, je tato metoda ještě bezpečnější než otisky prstů [4]. Vznikají zde však velké bezpečnostní obavy z hlediska neoprávněného zisku dat, která lze bez souhlasu získat z velké vzdálenosti, a to i za pohybu.

Biometrie podle sítnice

Tato metoda nese velkou míru bezpečnosti proti oklamání vzorku, současně však má oproti jiným systémům nízkou uživatelskou přívětivost [1]. Je používána v odvětvích, kde jsou vysoké bezpečnostní nároky z hlediska oklamání senzorů.

Biometrie podle hlasu

Rozpoznávání uživatele podle hlasu není příliš rozšířená metoda a systémy, které fungují v praxi, většinou používají pouze verifikaci, nikoliv identifikaci. Akceptance je velmi vysoká, ale ostatní faktory neumožňují použití této techniky jako spolehlivé alternativy ověřování [1].

Biometrie podle písma

Výhodami této metody jsou značná intuitivnost pro uživatele a také nízké systémové náklady. Tuto metodu lze dělit na statickou a dynamickou [1], při dynamické metodě je třeba využít elektronického snímače, který zaznamenává pohyby během psaní. Při využití dynamického systému se systém stává robustnějším z hlediska biometrické entropie.

2.3 Hodnocení spolehlivosti jednotlivých systémů

Biometrické systémy se ve svém průběhu dopouští chyb, vzniklých na základě skóre porovnání a nastaveného prahu. Skóre porovnání je míra shody šablony z databáze registrovaných s aktuálně registrovanou šablonou. Pokud je nastavený práh příliš vysoký nebo příliš nízký, může dojít k chybnému vyhodnocení. Příčinou této chyby může být

příliš vysoká vnitrotřídní variabilita vyjadřující rozdíly při snímání jedné osoby v různých okamžicích. Další příčinou může být nízká mezitřídní variabilita označující podobnost jedinců mezi sebou.

Vzniklá chyba se může projevit v těchto variantách [1]:

- Dva odlišné vstupy jsou klasifikovány jako shodné (False Match nebo False Accept)
- Dva shodné vstupy jsou klasifikovány jako odlišné (False Non-Match nebo False Reject)

Z výše uvedených variant jsou odvozeny a udávány tyto dva parametry [5]:

- FAR (*False acceptance rate*) – míra špatného přijetí – podíl identifikací, kde byla oblast, na které není obličej, chybně jako obličej detekována
- FRR (*False rejection rate*) – míra špatného odmítnutí – podíl identifikací, kde byla oblast, na které se obličej nachází, chybně jako obličej neoznačena

3. BIOMETRIE OBLIČEJE

Obličej je nejdostupnější a nejpřirozenější biometrický rys k identifikaci osob. Pomocí něj rozpoznáváme okolní jedince v každodenním životě. Tento proces provádíme intuitivně s velmi vysokou přesností, ale sestavit biometrický systém, který by fungoval spolehlivě, skýtá řadu výzev.

Obličej každého z nás vykazuje vysokou vnitrotřídní variabilitu (např. mimika) a můžeme narazit i na vyšší mezitřídní variabilitu (např. sourozenci) [1]. Pro zvýšení biometrické entropie (tedy pravděpodobnosti shody dvou obličejů) může být klasický 2D snímek nahrazen 3D snímkem. Jeho použití také zvyšuje citlivost systému a snižuje šanci podvrhu. Při ochraně před falzifikátem typu fotografie obličeje lze použít metodu termosnímků, která tento problém eliminuje.

Hlavní výzvou při sestavování robustního biometrického systému je již zmiňovaná velká vnitrotřídní variabilita. Je způsobena těmito vlivy [1]:

- **Mimika:** vlivem mimiky se snímek výrazně mění, nejviditelněji v oblasti okolo úst, očí a čela.
- **Účes a vousy:** porost hlavy může také výrazně změnit vizáž jedince.
- **Osvětlení:** obraz se mění i vlivem osvětlení, tento problém lze do jisté míry potlačit normalizací.
- **Doplňky:** například brýle, šátky, čepice a jiné externí předměty přispívají k vyšší vnitrotřídní variabilitě.
- **Stárnutí:** vlivem stárnutí dochází ke změně textur na obličej, tento jev však není příliš prozkoumán.

3.1 Biometrie obličeje na základě 2D snímků

Nejrozšířenější metodou pro biometrii obličeje nadále zůstává rozpoznávání pomocí 2D snímků. Jeho hlavní výhodou je oproti pokročilejším způsobům velmi snadné získání dat. Z tohoto důvodu se tato práce zabývá pouze biometrií obličeje na základě 2D snímků.

Postup rozpoznávání se řídí následujícím schématem [1]:

- Detekce obličeje (příp. obličejů)
- Normalizace nalezeného obličeje – transformace dat tím způsobem, aby byla zajištěna uniformita
- Extrakce příznaků – převedení detekovaných dat do preferovaného formátu
- Vyhodnocení podobnosti – identifikace/verifikace jedince

3.2 Detekce obličeje

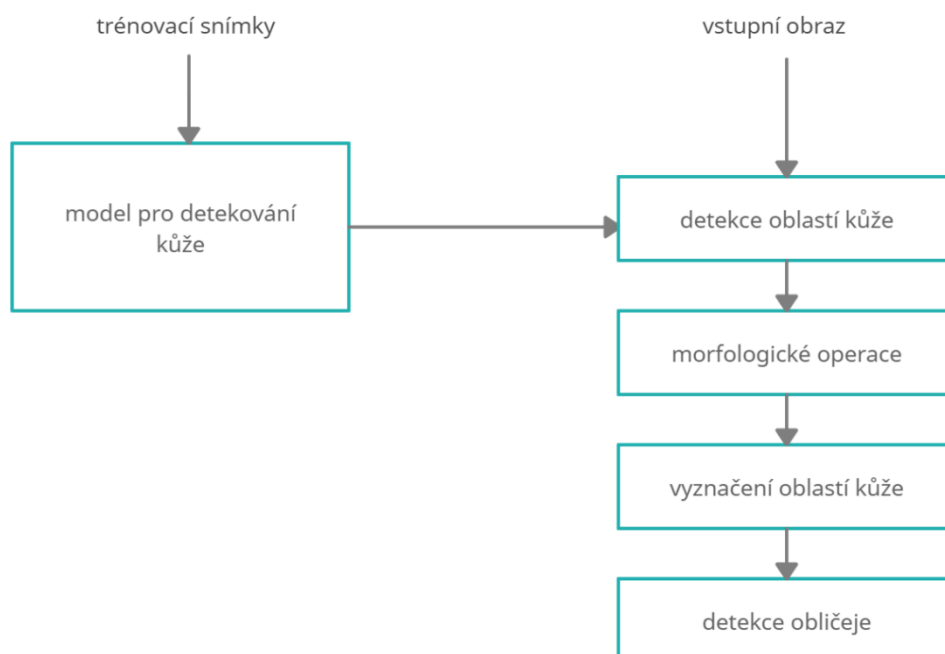
Lokalizaci obličeje v rámci snímku je možné řešit čtyřmi přístupy [6]:

- Detekce na základě expertních znalostí: Tyto metody jsou založeny na předpokladu, že lidské obličej mají některé charakteristiky společné [1]. Jsou detekovány různé části obličeje a zjišťují se vztahy mezi nimi. Na základě těchto vztahů je rozhodnuto, zda se jedná o tvář.
- Detekce na základě invariantních rysů: Tyto metody cílí na vyhledávání rysů, které jsou detekovatelné i v případě změny výrazu v obličeji, úhlu pohledu nebo osvětlení.
- Detekce na základě porovnávání se vzory: Je určeno několik standardních vzorů odpovídajících obličeji. Vstupní obrazy jsou korelovány s těmito vzory a míra korelace na výstupu určuje přítomnost obličeje.
- Detekce na základě vzhledu: Obraz je porovnáván se vzorem, který vznikl během učení algoritmu.

Některé z metod používaných k lokalizaci obličeje ve snímku jsou v následující kapitole popsány.

3.2.1 Detekce obličeje na základě barvy kůže

Tato metoda vychází z vyhledávání invariantních rysů obličeje. Do kategorie neměnných rysů spadá i lidská kůže [7]. Výhodou tohoto přístupu je invariance k úhlu natočení hlavy či mimice, tedy skutečnost, že detekce obličeje není do určité míry ovlivněna vysokou vnitrotřídní variabilitou. Pro svou neměnnost je tato vlastnost při detekci obličeje hojně využívána. Blokové schéma, podle kterého metoda funguje, je na obrázku 3.1.



Obrázek 3.1: Blokové schéma detekce obličeje na základě barvy kůže

V prvním kroku je použita sada trénovacích fotografií, kterou analyzujeme a určíme kritéria pro barvu kůže. Existuje více barevných modelů, pro které lze určit tato kritéria. Výchozí barevný model pro většinu obrazů je RGB model. Z důvodu vysoké korelace mezi jednotlivými kanály je však použití tohoto modelu pro barevnou analýzu nepříliš vhodné. Tang San ve svojí práci [7] provedl analýzu pro barevné modely HSV a $Y C_G C_R$.

Barevný prostor HSV je popsán třemi parametry: odstín (*Hue*), sytost (*Saturation*) a jas (*Value*). Tento barevný model nejvíce odpovídá lidskému vnímání barev. Převod z RGB do HSV probíhá následovně [7]:

$$V = \frac{1}{3}(R + G + B) \quad (3.1)$$


$$S = 1 \frac{3}{(R + G + B)} [\min(R, G, B)] \quad (3.2)$$

$$H = \arccos \left\{ \frac{[(R - G) + (R - B)]/2}{[\frac{R - B}{2} + (R - B)(G - B)]^{1/2}} \right\} \quad (3.3)$$

Barevný prostor $Y C_G C_R$ je rovněž popsán třemi parametry: Y odpovídá svítivosti, C_R představuje rozdíl mezi Y a červenou komponentou R a C_G představuje rozdíl mezi Y a zelenou komponentou G. Převod z RGB do $Y C_G C_R$ probíhá takto [7]:


$$\begin{bmatrix} Y \\ C_g \\ C_r \end{bmatrix} = \begin{bmatrix} 16 \\ 128 \\ 128 \end{bmatrix} + \begin{bmatrix} 0.256 & 0.5041 & 0.0979 \\ -0.318 & 0.4392 & -0.1212 \\ 0.4392 & -0.3677 & -0.0714 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (3.4)$$

V těchto barevných modelech byla na sadě tréninkových snímků určena kritéria pro barvu kůže. Byla provedena shluková analýza, a to v jednotlivých podprostorech jako H-S, H-V atd. Jak můžeme vidět na obrázku 3.2 [7], hodnota odstínu (*Hue*) se pro části obrazu obsahující kůže pohybuje mezi hodnotami 0–1 a 0.9–1.



Obrázek 3.2: Pixely označeny jako kůže v podprostorech H-S(vlevo) a H-V(vpravo) [7]

V jiné analýze [8] bylo zjištěno rozložení barvy kůže v YCGCR modelu pro jednotlivé kanály, viz obrázek 3.3.



Obrázek 3.3: Rozložení barvy kůže pro jednotlivé kanály v $Y C_G C_R$ v barevném modelu [8]

Z obrázku 3.3 lze opět snadno odvodit hodnoty, při kterých se v obrazu vyskytuje kůže. U kanálu C_B je to především mezi hodnotami 0,4 a 0,5, u kanálu C_G je tato oblast mezi hodnotami 0,5 a 0,6.

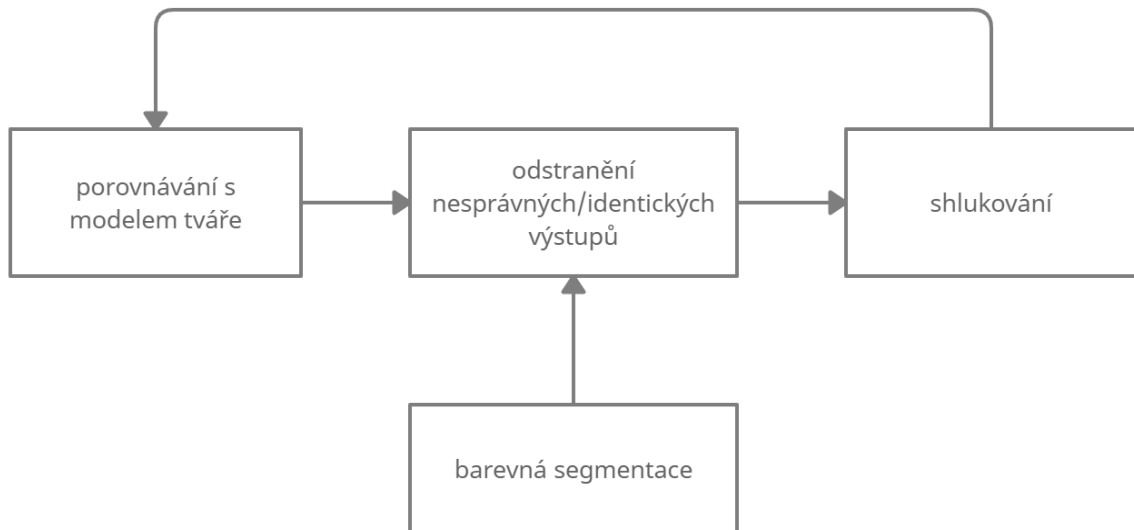
Po určení kritérií pro barvu kůže přichází na řadu samotná detekce. Obraz je na základě získaných kritérií segmentován, tedy převeden na binární obraz, který udává oblast zájmu. Oblasti kůže budou obsahovat šum, je tedy vhodné použít morfologické operace k eliminaci rušivých elementů. Používá se eroze a dilatace. Eroze dokáže odstranit malé oblasti chybně detekované jako obličej a dilatace zaplní malé oblasti v obličej, které nebyly detekovány jako kůže.

Oblasti detekované jako kůže mohou odpovídat obličej, může to také ale být kůže na jiném místě než na obličej, případně dokonce pozadí s podobnou barvou. Podle literatury a statistických experimentů [7] může být za část lidského obličej prohlášena oblast, která:

- Splňuje podmínku, že podíl výšky a šířky je v rozsahu 0,8 až 1,8
- Splňuje podmínku minimálního rozlišení pro obličej, který je 16x16. Oblast menší než 256 pixelů může být odstraněna
- Splňuje tuto podmínku – $0,5 < N/A < 0,9$, přičemž A je oblast regionu (výška*šířka) a N je počet pixelů v A

3.2.2 Detekce obličeje na základě předdefinovaných vzorů

Tato metoda je založena na principu porovnávání se vzory. Je vytvořen model, v našem případě tváře, se kterým je pak v obraze hledána podobnost. Pokud je míra podobnosti vysoká, můžeme usoudit, že v dané lokaci se nachází obličej. Blokové schéma algoritmu [7] pro detekci obličeje je znázorněno na obrázku 3.4.



Obrázek 3.4: Blokové schéma pro detekci obličeje metodou předdefinovaných vzorů

Nejdříve je provedeno porovnání se vzorem, aby bylo zjištěno, v jakých oblastech obrazu je vysoká míra podobnosti. Poté jsou pomocí masky vytvořené barevnou segmentací odstraněny nevyhovující výstupy. Dalším krokem je shlukovací procedura, kde jsou body splňující danou euklidovskou vzdálenost spojeny v jeden bod. Celý tento proces je opakován v rozličných měřítkách a rozlišeních. Výstupy jednotlivých variant různých měřítek a rozlišení jsou poté rekombinovány do jediné masky.

Porovnávání se vzory je ve své podstatě prostá vzájemná korelace dvou 2D signálů – šedotónového obrazu se šedotónovým vzorem. Existuje nicméně mnoho faktorů, které budou mít na celkový výkon systému vliv.

Je nutné zvolit vzor, který bude obsahovat všechny důležité rysy, ale zároveň nebude příliš specifický. Jako jedna z metod, jak vhodný vzor získat, se osvědčila metoda vlastních vektorů. Vstupní sada obrazů byla normalizována tak, aby měly stejnou orientaci a měřítko. Poté jsou pomocí metody PCA (analýza hlavních komponent) extrahovány vlastní vektory. Vzor, který hledáme, bude vyjádřen součtem průměrného obličeje a lineární kombinace vlastních vektorů. Toto je vyjádřeno na obrázku 3.5 [9].

$$\hat{x} = \mu + w_1 u_1 + w_2 u_2 + w_3 u_3 + w_4 u_4 + \dots$$

Obrázek 3.5: Výpočet masky pomocí vlastních vektorů [9]

Kde \hat{X} je maska, μ je průměrný obličej, jednotlivé vlastní u_i vektory jsou váhovány váhami w_i . Robustnost algoritmu můžeme zvýšit použitím vzoru, od kterého odečteme jeho střední hodnotu a z obrazu odstraníme lokální střední hodnotu o velikosti vzoru. Abychom předešli procházení celého obrazu oknem o velikosti vzoru, kvůli výpočtu lokálních středních hodnot, můžeme použít tzv. nízkopásmovou aproximaci [10] střední hodnoty. Tedy filtrujeme obraz vhodným nízkopásmovým filtrem a výstup odečteme od původního obrazu. Algoritmus se tímto stává odolnějším proti různým světelným podmínkám. Výsledek je vidět na obrázku 3.6 [10].



Obrázek 3.6: Obraz s odečtenou lokální střední hodnotou [10]

2D korelace obrazu s vysokým rozlišením je časově velmi náročná. Tento problém lze vyřešit převedením obrazu pomocí 2D Fourierovy transformace a korelaci provést ve frekvenční doméně. Poté je zpětnou 2D Fourierovou transformací obraz převeden zpět a tím je získán výstupní obraz.

Falešné a identické výstupy korelace jsou odstraněny barvenou maskou. Barevná maska je aplikována na výstup korelace, čímž je získána indikace toho, kde se na obrázku nachází kůže. Byla získána informace o tvaru nalezených oblastí. Detekované části neodpovídající obličejům tedy mohou být odstraněny. Pro odstranění identických výstupů je provedena další forma metody porovnání se vzory. Na výstup korelace, na který byla již aplikována barevná maska, je aplikována další – binární maska. Tato maska má přibližný tvar obličeje a je aplikována na centroidy všech oblastí s vysokou korelací. Součet pixelů odpovídající hodnotě 1 je podělen součtem pixelů o hodnotě 1 s binární maskou. Takto je získán koeficient, který pokud bude nižší než určený práh, korelace bude neplatná a oblast nebude označena jako obličej.


I přes použití barevné masky může být v obraze stále detekován ten samý obličej vícekrát. Aby bylo identickým detekcím zabráněno, je provedeno shlukování. Použitý algoritmus je podobný metodě K-means. Nalezené regiony jsou označeny a je jim přiřazena váha. Mezi centroidy jednotlivých regionů jsou zkoumány vzdálenosti a při nesplnění podmínek jsou pomocí výpočtu zahrnujícího jejich váhy sloučeny do jednoho na pozici [10]:

$$[x_3 \ y_3] = (w_1 + w_2)^{-1}(w_1[x_1 \ x_2] + w_2[x_1 \ x_2]) \quad (3.4)$$

Bylo řečeno, že je algoritmus proveden v rozličných měřítkách. Důvodem je, že některé obličeje jsou menší či větší než jiné a vzhledem k tomu, že tento proces využívá vzor s fixní velikostí, je opakované provedení v různých měřítkách nezbytné. Při jeho nepoužití by tváře, které by velikostně neodpovídaly dané masce, nebyly během korelačního procesu označeny.

3.2.3 Detekce obličeje na základě HOG

Tato metoda, patřící do skupiny metod založených na vzhledu, funguje na principu histogramů orientovaných gradientů (HOG). Obraz je rozdělen do malých oblastí, tzv. buněk, ve kterých je vypočítán histogram gradientních směrů pro všechny pixely v dané buňce. Blokové schéma algoritmu ukazuje obrázek 3.7.

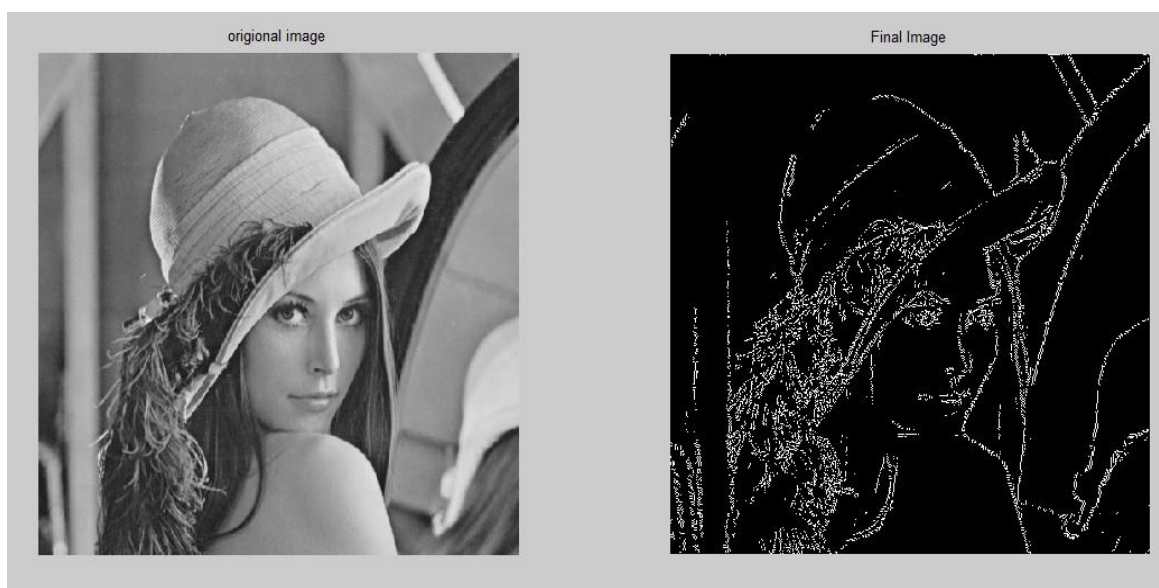


Obrázek 3.7: Blokové schéma pro detekci obličeje na základě HOG

Prvním krokem je předzpracování obrazu. Je tedy jako obvykle nutné vstupní sadu dat normalizovat. Vstupní data jsou v barevném modelu RGB, případně v šedotónovém. U některých metod převedení RGB do šedotónového modelu významným způsobem zvyšuje úspěšnost detekce. Zde však bylo zjištěno, že tato změna nemá na výsledek téměř žádný vliv [11].

Stěžejním krokem pro detekci obličeje je výpočet gradientů. Abychom je mohli určit, je nutné obraz převést na jeho hranovou reprezentaci. Hrany můžeme detekovat například aplikací Sobelovy nebo Prewittové masky, lze také použít je 1-D derivační masku $[-1, 0, 1]$, která ze zmiňovaných masek funguje nejlépe (viz obrázek 3.8). Při použití jednoduché 1-D masky je výstup získán konvolucí vstupního obrazu s maskou ve vertikálním i horizontálním směru.

Jak již bylo řečeno, obraz je rozdělen na síť buněk (o velikosti např. 8×8 pixelů). Máme tedy síť buněk a gradientní obraz. Nyní je třeba pro každou buňku určit histogram orientovaných gradientů. Pro detekci obličeje je buňka rozdělena na 12 tzv. binů o rozsahu 0° – 360° [12]. Z jednotlivých binů je vytvořen lokální histogram pro danou buňku a výsledný vektor je určen složením všech histogramů.



Obrázek 3.8: Aplikace Sobelovy masky na vstupní obraz [13]

Jednotlivé histogramy se vlivem nerovnoměrného osvětlení a jasu mohou značně lišit, je proto vhodné provést normalizaci. Více buněk (např. 3×3) je seskupeno v tzv. bloky a ty jsou normalizovány jako celek. Poté můžeme provést blokovou normalizaci. Její rovnice je následující [11]:

$$v \rightarrow v / \sqrt{\|v\|_2^2 + e^2} \quad (3.5)$$

Kde v je vektor všech histogramů daného bloku a e je nenulová konstanta.

Ke klasifikaci dat je použit klasifikační algoritmus SVM (support vector machine). Jedná se o jednoduchý klasifikátor, oddělující data lineární funkcí. Chceme tedy nalézt rovinu, která bude dělit data náležející odlišným třídám. Jelikož se jedná o metodu učení s učitelem, klasifikátor je nejdříve na testovacích datech naučen rozpoznávat obličej. Na testovacích datech poté klasifikátor vyhodnotí, která data v obraze popisují obličej a která ne.

3.2.4 Detekce obličeje na základě Viola-Jones algoritmu


Nejpoužívanějším detektorem používaným pro detekci obličeje je Viola-Jones algoritmus. Svou povahou spadá do metod založených na vzhledu. Jeho vstupem jsou šedotónové obrazy a skládá se ze tří částí: integrálního obrazu, Haarových příznaků a klasifikátoru, založeném na metodě AdaBoost [1], [14]. Tento detektor má vysokou spolehlivost a rychlost, a jeho výsledky nejsou ovlivněny okolním osvětlením či velikostí hledaného obličeje.

Charakteristické rysy mohou být vypočítány velmi rychle, pokud převedeme vstupní obraz na takzvaný integrální obraz. Jde o reprezentaci vstupního obrazu, v níž jsou kumulativně sečteny jasové hodnoty pixelů v řádcích a sloupcích. To je vyjádřeno těmito rovnicemi:

$$s(x, y) = s(x, y - 1) + i(x, y) \quad (3.6)$$


$$ii(x, y) = ii(x - 1, y) + s(x, y) \quad (3.7)$$

Příklad výpočtu integrálního obrazu můžeme vidět na obrázku 3.9 [2].



Obrázek 3.9: Originální a integrální obraz [2]

Detektory charakteristických rysů se nazývají Haarovy filtry. Existuje více variant, základní forma je znázorněna na obrázku 3.10 [14]. Haarovy filtry prochází postupně integrální obraz. Odezva na aktuální výřez je skalár, který udává rozdíl sum jasových hodnot pod světlou a tmavou částí. Filtry projdou v různých měřítkách celý obraz, čímž je získán soubor Haarových příznaků.



Obrázek 3.10: Dvoupříznakové filtry A a B, třípříznakový filtr C, čtyřpříznakový filtr D [14]

Haarovy příznaky jsou použity jako slabé klasifikátory. Jsou tak nazývány, protože samy o sobě jsou nedostatečně spolehlivé. Je použit klasifikační algoritmus *AdaBoost* který z velkého množství slabých klasifikátorů vytvoří jeden silný klasifikátor. Postup učení klasifikátoru je následující [1]:

Máme trénovací množinu dat a sadu slabých klasifikátorů.

- Váhy trénovacích dat jsou nastaveny na výchozí hodnotu.
- Z množiny trénovacích dat je vybrán klasifikátor, který dosahuje nejlepšího výsledku na trénovacích datech (v závislosti na vahách).
- Na základě úspěšnosti je pro vybraný klasifikátor vypočítán koeficient.
- Váhy trénovacích dat jsou upraveny tak, aby rostla váha pro špatně klasifikovaná data a naopak.
- Pokračujeme druhým krokem, dokud není výsledný klasifikátor dostatečně přesný.

Můžeme předpokládat [1], že většina výřezů nebude obsahovat obličejovou část, ale pouze pozadí. Vzniká tedy požadavek, aby byl výpočet klasifikace daného výřezu rychle ukončen, jestliže nebude obsahovat obličej. Viola-Jones algoritmus používá více silných klasifikátorů, které jsou vhodně uspořádány do kaskády. Vzniká tak kaskádní filtr, díky kterému bude algoritmus fungovat velmi rychle. První člen kaskády klasifikátorů vyřadí výřezy, na kterých se žádná část obličeje nenachází. Další člen kaskády už detekuje pouze ty výřezy, které nebyly v předcházejícím kroku vyřazeny a zároveň vyloučí další, které neodpovídají části obličeje. Výstupem bude pouze oblast detekovaná jako obličej.

3.3 Rozpoznání obličeje

V předcházejícím kroku byly v obrazech detekovány obličeje. V dalším kroku přichází na řadu jejich rozpoznání. Existují tři hlavní skupiny metod:

- Lokální metody – zaměřují se jednotlivé části obličeje (obočí, nos, koutky úst, oči...), jsou citlivější na změnu osvětlení či výrazu v obličeji.
- Holistické metody – zaměřují se na obličej jako celek, na rozdíl od lokálních metod potřebují velké množství trénovacích dat.

- Hybridní metody – kombinují lokální a holistické metody za účelem využití výhod obou přístupů.

3.3.1 Metoda PCA

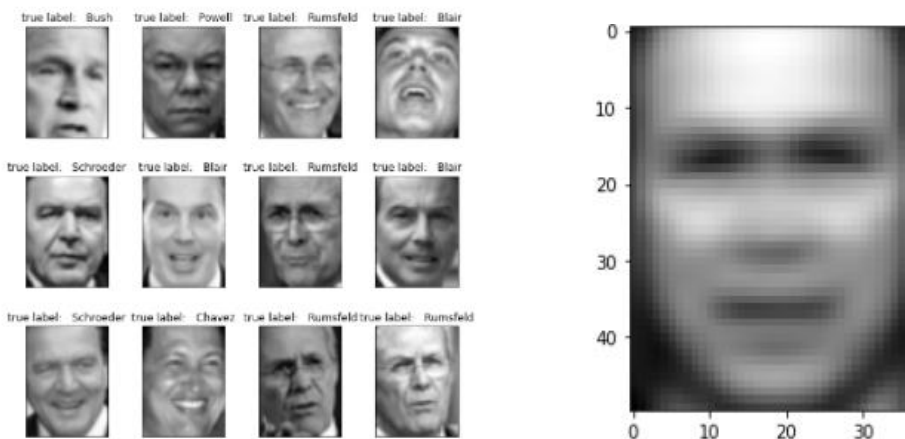
Analýza hlavních komponent (PCA) svou povahou spadá do kategorie holistických metod. Tato metoda již byla zmíněna v podkapitole o detekci pomocí předdefinovaných vzorů, nyní bude popsána podrobněji.

Metoda PCA převádí vstupní sadu obrazů do nového prostoru, kde jsou jednotlivé obrazy ve formě vektoru řazeny podle rozptylu od vektoru středního obrazu. Těchto vektorů je velké množství a mnohé z nich si budou podobné. Úkolem PCA je najít ty vektory, které nejlépe tento nový prostor charakterizují. Ty méně charakteristické je možné vynechat – odtud redukce dimenzionality. Tyto vektory se nazývají vlastní vektory (= *eigenfaces*) a v literatuře je takto někdy označována celá metoda PCA.

Výpočet PCA

První krok metody PCA je převedení vstupních obrazů do vektorů. Obraz o formátu $N \times N$ je reprezentován vektorem o délce N^2 a každý bod v místě svého indexu reprezentuje jasovou hodnotu obrazového bodu. Následně je spočítán průměr ze všech obličejových vektorů a poté je odečten od každého vektoru [15]. Pro jednotlivé vektory $X_1, X_2, X_3 \dots X_N$:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N X_i \quad (3.8)$$



Obrázek 3.11: Vstupní množina dat (vlevo) a z těchto dat vypočítaná „průměrná tvář“ (vpravo) [15]

Nyní je spočítána kovarianční matice C :

$$C = \frac{1}{N} \sum_{i=1}^N (\bar{x} - X_i)(\bar{x} - X_i)^T \quad (3.9)$$

Tato matice reprezentuje míru rozptylu vektorů kolem průměru všech obličejových vektorů. Pomocí té jsou spočítány vlastní hodnoty a vektory kovarianční matice C pomocí této rovnice:

$$Cv = \lambda v, \quad (v \in \mathbb{R}, v \neq 0) \quad (3.10)$$

Vlastní hodnoty a jim odpovídající vlastní vektory jsou dále vzestupně seřazeny. V rámci redukce dimenzionality je z nich vybráno L vlastních vektorů, přičemž tento počet musí být menší nebo roven celkovému počtu vstupních vektorů.

Registrace pomocí PCA

Jakýkoliv obličej z databáze lze zpětně rekonstruovat lineární kombinací vlastních obličejů a průměrného obličejového obrázku [1]. Samotná registrace pak probíhá následovně: neznámý obraz je nejprve předzpracován, aby dimenzionálně odpovídal trénovací množině dat, od tohoto obrazu je následně odečten průměr \underline{x} . Poté je tento obraz projektován do vlastního prostoru (soubor vlastních obličejů). Váhy pro jednotlivé vlastní hodnoty lze v tomto vektoru popsat takto:

$$\Omega_i = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_k \end{bmatrix} \quad (3.11)$$

Tento vektor vah Ω určíme pro každý obraz v trénovací množině a v následujícím kroku jednoduše porovnáme vzdálenosti jednotlivých vektorů. Použit lze euklidovskou vzdálenost. Nastavený práh bude určovat, zda má neznámý obraz shodu s obrazem v trénovací databázi.

3.3.2 Metoda SIFT

Tato metoda je používána k detekci a popisu lokálních vlastností obličejů. Hlavní myšlenka metody je převést obraz na reprezentaci, skládající se z tzv. bodů zájmu. Výhodou této metody je invariance k měřítku a rotaci. Jedna z nevýhod je pomalá rychlost při srovnávání bodů zájmu.


Pro detekci bodů zájmu metoda používá metodu rozdíl Gaussiánů (DOG). Jedná se o metodu, při které je Gaussovsky rozostřený obraz odečten od jiné, méně rozostřené verze původního obrazu [16]:

$$D(x, y, \sigma) = (G(x, y, \sigma) - G(x, y, \sigma)) * I(x, y) \quad (3.12)$$

Jsou spočítány body zájmu – lokální maxima a minima $D(x, y, \sigma)$ – porovnáním s osmi sousedy v současném obrazu a devíti sousedy v tom samém obrazu s menším a větším měřítkem. Celkově tedy bude porovnávat každý bod s 26 body. V tomto momentě jsou spočítány velikost gradientu $m(x, y)$ a orientace $\Phi(x, y)$ pomocí rozdílů mezi pixely:

$$m(x, y) = \sqrt{(L(x + 1, y) - L(x - 1, y))^2 + (L(x, y + 1) - L(x, y - 1))^2} \quad (3.13)$$

$$\Phi(x, y) = \tan^{-1} \left(\frac{L(x, y + 1) - L(x, y - 1)}{L(x + 1, y) - L(x - 1, y)} \right) \quad (3.14)$$




Obrázek 3.12: Body zájmu na vzorových obrazech (nahore) a nalezené shody deskriptorů (dole) [16]

Velikost a orientace jsou přiřazeny bodům zájmu. Následně je v okolí bodů zájmu vypočítáno 16×16 gradientů. Relativně k jejich orientaci a velikost je vypočítán histogram těchto gradientů – tzv. deskriptor. Každý bod zájmu je nyní popsán deskriptorem a dalším krokem je porovnat body zájmu na jiném obrázku a hledat podobné deskriptory.

3.3.3 Metoda LDA

Tato holistická metoda funguje na podobném principu jako PCA – určí obrazům nový prostor, ve kterém následně provádí redukci dimenzionality, přičemž zachovává relevantní data. Hlavní rozdíl oproti PCA je vytváření tohoto prostoru [1]. Na rozdíl od metody PCA se navíc jedná o učení s učitelem, u každého snímku je tedy uvedeno, kdo je na něm zobrazen. Tato metoda je z důvodu použití Fisherových diskriminantů, v literatuře někdy označována jako *Fisherfaces*.

Nové prostory vznikají tak, že obličejové stejné osob jsou pomocí Fisherových diskriminantů odděleny do své vlastní třídy. LDA se poté snaží nalézt prostor, který nejlépe jednotlivé třídy separuje. Rozdíly mezi jednotlivými třídami chceme maximalizovat, zatímco rozdíly uvnitř jednotlivých tříd by měly být minimální.



Obrázek 3.13: Sady bodů dvou obrazů: sady bodů nebyly separovány (a), sady bodů byly separovány (b) [17]

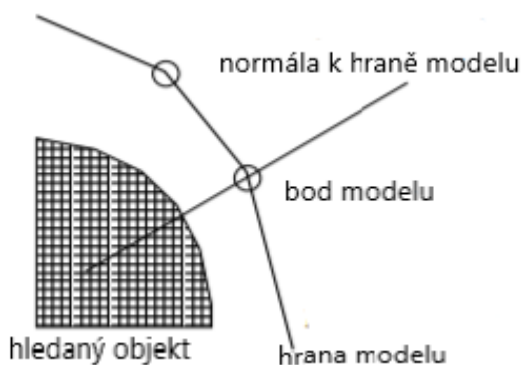
3.3.4 Metoda ASM

Metoda ASM (active shape model) se řadí mezi lokální metody a podobně jako u metody předdefinovaných vzorů u detekce obličeje pracuje se šablonami. Ty sestávají obvykle z dvaceti až třiceti bodů, které si určitých částech obličeje (např. špička nosu, koutek úst) budou významově odpovídat [1]. Je třeba vybrat parametry, které budou hledaný model v obrázku vhodně popisovat. Mezi tyto parametry řadíme parametr **b**, který definuje tvar a souhrn parametrů **X**, pod které spadá pozice, orientace a měřítko [18].

Nejprve je třeba vybrat počáteční body, které jsou umístěny shodně ve všech obrázcích. Jako vhodné se jeví vybírat body, které v obrazu leží v rohu hrany nebo v takzvané T-junkci, tedy uprostřed křižovatky ve tvaru T [19]. Jelikož jich často není v obraze dostatečně velké množství na vypovídající popis, jsou mezi určenými body rovnoměrně umístěny podél hrany další body.

V předchozím kroku byl získán výchozí model, který nyní bude iterativně optimalizován podle následujícího postupu [18]:

- Je prozkoumán region okolo každého bodu a pro každý z těchto bodů je nalezen nejbližší bod v obrazu reprezentující obličej.
- Jsou aktualizovány parametry definující šablonu a to tak, aby byla přizpůsobena pozicím nově nalezených bodů.
- Předchozí dva body jsou opakovány, dokud nedojde ke konvergenci.



Obrázek 3.14: Každý bod je při hledání proložen normálou.
Upraveno [19]

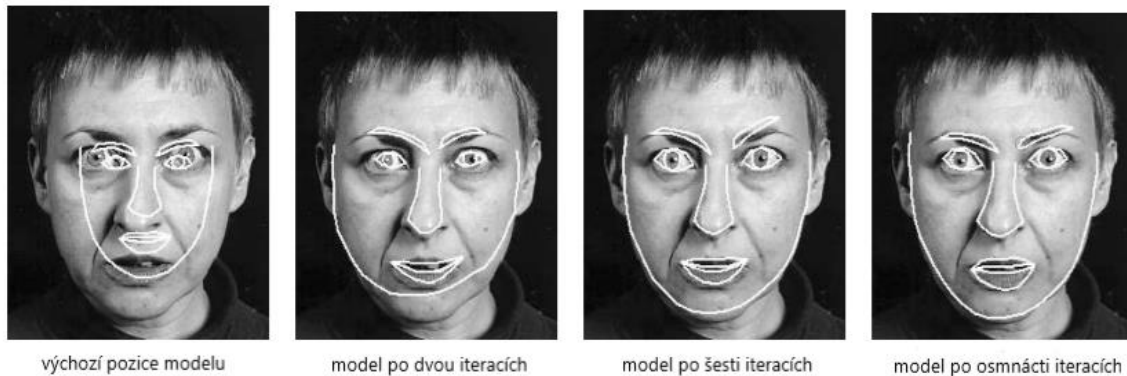
K určení pozic nových bodů jsou využity jasové hodnoty jednotlivých pixelů obrazů ze vstupní trénovací sady. V okolí jednotlivých bodů modelu jsou brány k pixelů z obou stran. Máme tedy sadu vektorů o délce $2k + 1$, které jsou uloženy do vektoru g_i . Do vektorů jsou zapisovány hodnoty změn intenzity, nikoliv jejich skutečná hodnota. Intenzity tak nejsou ovlivněny globálním osvětlením [18]. Vektor g_i je normalizován dělením sumou profilů všech obrazů v trénovací sadě:

$$g_i \rightarrow \frac{1}{\sum_j |g_{ij}|} g_i \quad (3.15)$$

Pro další výpočet je potřeba znát průměrný vzorek normalizované intenzity g' a kovarianční matici S_g . Kvalita optimalizace nového vzorku je dána rovnicí [18]:

$$f(g_s) = f(g_s - g')^T S_g^{-1} (g_s - g') \quad (3.16)$$

Tzv. Mahalanobisova vzdálenost je vzdálenost vzorku v obraze od průměrného vzorku g' . U každého bodu je vzato několik vzorků od délce větší než jeden pixel podél kolmice k hraně obrazu. Pro každý z těchto vzorků je spočítána Mahalanobisova vzdálenost a souřadnice vzorku s nejmenší hodnotou určují nový bod.



Obrázek 3.15: Pozice modelu v průběhu algoritmu [19]


Na obrázku 3.15 můžeme vidět optimalizaci modelu při použití ASM v různých iteracích. Po dvou iteracích se změny parametrů týkaly především měřítka a orientace, pozice modelu se tak posunula přibližně na správné místo. Při dalších orientacích byly parametry měněny jemněji a nové pozice bodů se nelišily o mnoho, docházelo tak k menšímu posunu měřítka. Po osmnácti iteracích byl model optimalizován uspokojivě.

3.3.5 Metoda LBPH

Metoda LBPH (*Local Binary Patterns Histograms*) je známá svou jednoduchostí a je využívána k extrakci příznaků nejen na poli detekce obličeje. Metoda se skládá ze dvou částí: převedení obrazu pomocí LBP do reprezentace lokálních binárních vzorů a v druhé části jsou z těchto vzorů získány histogramy. Pracuje se 4 parametry [20]:

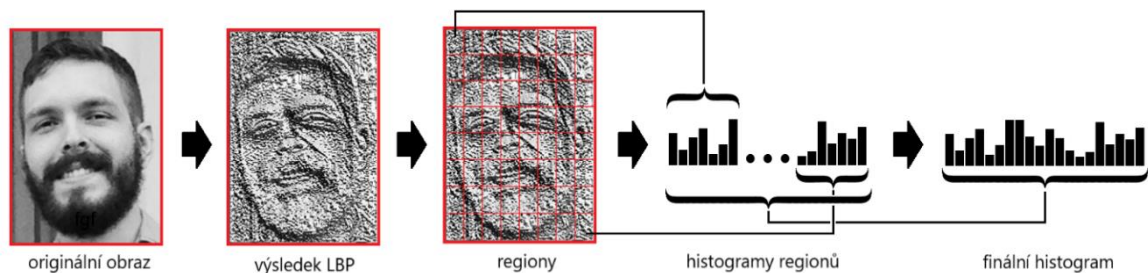
- Poloměr – je použit k tomu, aby byl vytvořen lokální vzor, který je poloměrem charakterizován, většinou nabývá hodnoty 1
- Sousedství – počet sousedů okolo poloměru, ze kterých se skládá lokální vzor, většinou je jejich počet 8
- Tabulka X – počet buněk v horizontálním směru
- Tabulka Y – počet buněk ve vertikálním směru

Postup první částí je následující: z šedotónového obrazu je vzato okno o velikosti 3x3 pixelů s intenzitami 0–255. Prostřední hodnota slouží jako práh, podle kterého jsou definovány nové binární hodnoty v jeho okolí. Hodnoty, které jsou větší než daný práh, budou nastaveny na 1, a ty, které jsou nižší než daný práh, budou nastaveny na 0. Nyní jsou tyto hodnoty řádek po řádku spojeny a je z nich získána binární hodnota (např. 10011011). V některých člancích jsou binární hodnoty získávány jinými způsoby, např. po směru hodinových ručiček okolo střední hodnoty [21], na konečný výsledek to nemá vliv. Tato binární hodnota je posléze převedena na decimální a dosazena na střední pixel jako jeho nová hodnota. Tento postup je znázorněn na obrázku 3.16.



Obrázek 3.16]: LBP procedura, upraveno z [22]

V druhé části jsou využity parametry tabulka X a tabulka Y, s jejichž pomocí je obraz rozdělen na jednotlivé regiony, viz. obrázek 3.17.



Obrázek 3.17: LBPH procedura, upraveno z [22]

Z informací v každém regionu je vytvořen histogram, který bude obsahovat 256 pozic (0–255), reprezentujících počty pixelů o jednotlivých intenzitách. Histogramy jsou sloučeny do finálního histogramu, který bude reprezentovat charakteristiku originálního obrazu.

Tímto způsobem je naučena trénovací sada obrázků. Každý obraz v sadě je reprezentován finálním histogramem. Při rozpoznání obrazu je pro něj vytvořen podle stejného postupu finální histogram a ten je srovnán se vstupní sadou a hledá nejpodobnější histogram podle různých metrik, například chi-square nebo euklidovské vzdálenosti [20]:

$$D = \sqrt{\sum_{i=1}^n (hist1_i - hist2_i)^2} \quad (3.17)$$

Nejbližší histogram z trénovací databáze bude označen a registrován jako hledaný obličej.

4. BIOMETRICKÉ DATABÁZE

V rámci testování implementovaného algoritmu na lokalizaci a rozpoznání obličeje v obraze byly použity obrazy z volně dostupných biometrických databází [23], [24], [25]. Algoritmus byl testován na pěti setech obrazů z těchto databází. Pro účely algoritmu byly zvoleny snímky, které byly pořízeny frontálně. Jednotlivé datové sady však zachovávají vyšší vnitrotřídní variabilitu (lidé mají na snímcích různé grimasy, nosí různé pokrývky hlavy, jiné doplňky,...). Detaily o jednotlivých datových sadách jsou udány v tabulce:

Tabulka 4.1: Detaily o jednotlivých databázích

Sada	Počet osob	Počet trénovacích obrazů na osobu	Rozměry vstupních obrazů [px]
Sada 1	27	10	416-496×480-588
Sada 2	10	13	640×480
Sada 3	20	15	180×200
Sada 4	20	15	180×200
Sada 5	20	15	180×200
Sada 6	25	30	640×480
Sada 7	25	36	640×480
Sada 8	25	30	640×480
Sada 9	10	48	115×115
Sada 10	100	25	120×165

V sadě 1 se nachází 27 osob, z nichž každá má v trénovací sadě 10 obrazů. Jedná se výhradně o osoby světlé pleti, mezitřídní variabilita tedy není příliš vysoká. Vnitrotřídní variabilita je však u některých osob poměrně vyšší a osvětlení obrazů, mimika či gesta a doplňky hlavy se na jednotlivých snímcích liší. Na obrázku 4.1 můžeme vidět příklad nižší vnitrotřídní variability mezi jednotlivými snímky.



Obrázek 4.1: Příklad nižší vnitrotřídní variability

Na obrázku 4.2 vidíme naopak příklad vyšší vnitrotřídní variability, liší se účes, osvětlení, mimika i doplňky:




Obrázek 4.2: Příklad vyšší vnitrotřídní variability

Sada 2 obsahuje 14 osob asijského původu, z nich každá má 12 obrazů v trénovací sadě. Vnitrotřídní ani mezitřídní variabilita není v této sadě příliš vysoká.



Obrázek 4.3: Ukázka trénovacích dat ze sady 2

Sady 3, 4, 5 obsahují po 20 osobách s 15 trénovacími obrazy pro každou z nich. Zejména v sadě 5 (obrázek 4.4) se nachází obrazy lidí jak světlé, tak tmavé pleti, stejně jako asiátů. Lidé na fotkách mají také navíc vysokou vnitrotřídní variabilitu.



Obrázek 4.4: Ukázka testovacích dat ze sady 5

Sady 6, 7 a 8 obsahují stejné osoby, v jednotlivých trénovacích datech pro tyto sady jsou však jiné obrazy. Snímky v těchto sadách se liší stínováním a různé jsou i úhly, ze kterých jsou fotografie zepředu pořizovány. Počet jednotlivců v těchto sadách je 25.



Obrázek 4.5: Ukázka testovacích dat ze sady 6

Sada 9 (obrázek 4.6) obsahuje 10 osob, pro každou z nich se v trénovací sadě nachází 48 snímků.



Obrázek 4.6: Ukázka testovacích dat ze sady 9

Sada 10 (obrázek 4.7) se od předcházejících sad liší tím, že obsahuje obrazy již s výřezy lokalizovaných obličejů. Na tuto sadu tedy nebyl aplikován algoritmus pro detekci obličeje. V sadě se nachází 100 osob, z nichž každá má v trénovací sadě 25 snímků.



Obrázek 4.7: Ukázka testovacích dat ze sady 10

5. IMPLEMENTOVANÝ ALGORITMUS

Vytvořený algoritmus na biometrii obličeje se skládá ze dvou částí – detekce obličeje, tedy jeho lokalizace v rámci snímku, a rozpoznání obličeje, tedy jeho identifikace v rámci trénovací sady. Algoritmus byl implementován v programovém prostředí Python verze 3.7. Mezi knihovny a rozšíření, které byly dále použity, patří OpenCV, matplotlib, NumPy a Scikit-learn.

OpenCV

OpenCV je *open source* knihovna zaměřená na počítačové vidění a strojové učení. Zahrnuje rozsáhlé množství algoritmů, které lze mimo jiné použít při detekci a rozpoznání obličeje, případně i jeho části (oči, ústa...). Je napsána v programovacím jazyce C++, má rozhraní pro Python, Javu a Matlab a mimo Windows podporuje i operační systémy Linux, Android a Mac OS. V implementovaném algoritmu je použita při načítání a ukládání sad obrazů. Dále při detekci obličejů pomocí Viola-Jones algoritmu a při rozpoznání obrazů metodou LBPH.

Matplotlib

Matplotlib je *open source* knihovna sloužící pro generování grafů a jiných interaktivních vizualizací. Její rozhraní je designované tak, aby graficky připomínalo vizualizační vybavení MATLABu. V algoritmu implementovaném v této práci byla tato knihovna využita pro zobrazování plotů v průběhu algoritmu, a to jak u detekce obličeje, tak i u obou metod pro rozpoznání obličeje.

NumPy

NumPy je *open source* knihovna, která se zaměřuje na práci s vícerozměrnými maticemi a vektory. Poskytuje nástroje pro jejich načtení a také funkce, které s nimi umožní provádět matematické operace. V této práci má knihovna využití u převodu obrazů na vektory při výpočtech rozpoznání obličeje a porovnávání jednotlivých vektorů.


Scikit-learn

Scikit-learn je knihovna, která se specializuje na strojové učení. Obsahuje algoritmy zaměřené na klasifikaci, regresi či shlukování. Mezi tyto algoritmy patří například podpůrné vektory, náhodné lesy, k-means a další. Tato knihovna je v algoritmu využita při implementaci metody PCA pro rozpoznání obličeje.

5.1 Detekce obličeje – Viola-Jones algoritmus

Pro implementaci první části algoritmu byla použita knihovna openCV. Před samotnou detekcí jsou obrazy načteny pomocí funkce *imread*. Pro detekci obličeje v obraze je použit předučený model *haarcascade_frontalface_alt.xml* [26]. Tento model byl načten funkcí


CascadeClassifier a lze jej použít obecně na jakýkoliv dataset obrazů, protože významné Haarovy filtry budou pro každý obličej podobné. Použitím toho modelu je významně zredukován počet použitých příznaků (při rozměrech obrazu 24×24 pixelů by to znamenalo redukci z cca 160 000 filtrů na 6 000), což se odrazí na nižší početní náročnosti. Pro ještě vyšší urychlení algoritmu je obraz, převedený do integrální formy, vždy procházen v sub-oknech a rychle se zbavuje míst, kde se nenachází obličej. Tento tzv. kaskádní filtr je popsán v kapitole 3.2.4. V algoritmu je realizován funkcí *detectMultiScale*. Ukázka implementovaného algoritmu je na obrázku 5.1. Snímek na obrázku je ze sady 1.



Obrázek 5.1: Ukázka průběhu algoritmu Viola-Jones na obrazu z trénovací databáze

Vzhledem ke skutečnosti, že byly využity Haarovy filtry typu *frontal face*, tedy ty, selektované pro detekci obličeje snímaného z frontálního pohledu, některé detekce nebyly provedeny. Důvody pro jejich neprovedení bylo například nezachycení celého obličeje nebo zachycení ze špatného úhlu. V implementovaném algoritmu funkce *viola_jones* vytváří podmínku, která označuje obrazy, u kterých detekce nebyla úspěšná.

Obrazy, na nichž nebyla detekce obličeje úspěšná, byly ze sady vyjmuty. Jelikož se jednalo o malé množství obrazů, pozdější kroky algoritmu to nijak nenarušilo. Ukázky takových snímků jsou na obrázku 5.2.



Obrázek 5.2: Ukázka nevyhovujících obrazů

V použitých databázích jsou jednotlivé obrazy, jak již bylo řečeno, pořizovány z frontální pozice vzhledem ke snímanému a je na nich vždy jedna osoba. Implementovaný algoritmus je však schopen i detekce více obličejů, což je znázorněno na obrázku 5.3 [27]:




Obrázek 5.3: Multidetekce pomocí algoritmu Viola-Jones

5.2 Rozpoznání obličeje – metoda PCA

Po lokalizaci jsou obličeje z obrazu vyříznuty a normalizovány tak, aby měla celá sada stejné rozměry. Po nalezení vyhovujících rozměrů je sada výřezů normalizována pomocí funkce *resize*. S těmito výřezy se dále pracuje.

Při trénování byly obrazy z trénovacích sad vždy převedeny do vektorové formy pomocí funkce *flatten*. Pro získání potřebných výsledků byla využita databáze knihoven pro strojové učení *scikit-learn* [28]. Funkce *PCA* převede vstupní data do nového prostoru způsobem, který je v této práci popsán v kapitole 3.3.1.

Obrazy ve vektorové formě byly převedeny do prostoru hlavních komponent a sestupně seřazeny podle své vypovídající hodnoty pro daný dataset. Každý z vlastních vektorů lze prezentovat ve 2D formě, tedy jako obrázek (od toho název vlastní obličej – *eigenface*). Na obrázku 5.4 vidíme prvních 100 vlastních vektorů ve 2D formě ze sady 2. Při zobrazení těchto obrazů byly použity funkce *subplots* a *imshow*. Tyto obrazy se jeví jako zašuměné, ale každý z nich obsahuje informace, které mohou být použity k rekonstrukci obličeje.



Obrázek 5.4: Prvních 100 vlastních obličejů ze sady 2

Vlastní vektory jsou na obrázku seřazeny podle významnosti pro daný dataset po sloupcích, dvacet nejvýznamnějších vlastních vektorů jsou tedy první dva sloupce. V rámci redukce dimenzionality je možné heuristicky určit [29] počet vlastních nejvýznamnějších vektorů. Pokud bychom nyní chtěli provést zpětnou rekonstrukci libovolného obrazu, ztratili bychom drobné detaily o obrazu, nicméně za cenu redukce dimenzionality a tedy zmenšení výpočetní náročnosti.


Abychom mohli rozpoznávat testovací obličej, je nejprve třeba vypočítat pro každý obraz v trénovacím datasetu vektor vah. Výsledkem je 2D vektor o rozměru $M \times N$, kde M je počet vybraných charakteristických vlastních vektorů (v sadě 2 určen jako 40) a N je počet vzorků. V algoritmu je tento 2D vektor získán výpočtem 5.1.

$$weights = sig @ (vec_pictures - pca.mean)^T \quad (5.1)$$


Kde *weights* je výsledný 2D vektor, *sig* jsou nejvýznamnější komponenty z vlastního prostoru, *vec_pictures* vstupní obrazy trénovací sady v 1D formě a *pca.mean* střední hodnota hlavních komponent. Symbol @ značí maticové násobení.

Pro každý vzorek v trénovací sadě tedy máme váhy. V následující fázi je načtena testovací sada, v níž jsou posléze detekovány obličeje, které jsou normalizovány tak, aby svými rozměry odpovídaly trénovací sadě. Při rozpoznání testovacích obrazů v rámci dané trénovací sady je vždy vypočítána vzdálenost mezi vahami jednotlivého testovacího obrazu a vahami obrazů v trénovací sadě. V této práci byla využita pro výpočet vzdálenosti euklidovská metrika, v algoritmu byla realizována příkazem *linalg.norm*. Obraz z trénovací sady, se kterým měl testovací obraz nejmenší vzdálenost, byl stanoven jako hledaný obraz.

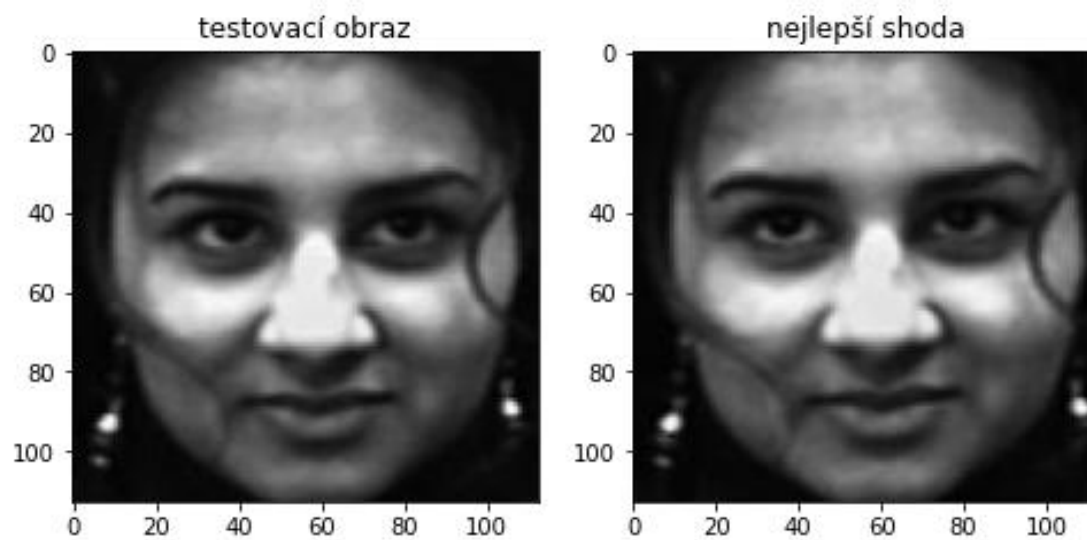
Na obrázcích 5.5, 5.6, 5.7 jsou zobrazeny příklady úspěšných rozpoznání ze sad 1, 3 a 5.



Obrázek 5.5: Úspěšné rozpoznání ze sady 1




Obrázek 5.6: Úspěšné rozpoznání ze sady 3



Obrázek 5.6: Úspěšné rozpoznání ze sady 3

Na obrázku 5.8 je příklad neúspěšného rozpoznání. Testovací a trénovací obraz pochází ze sady 1.

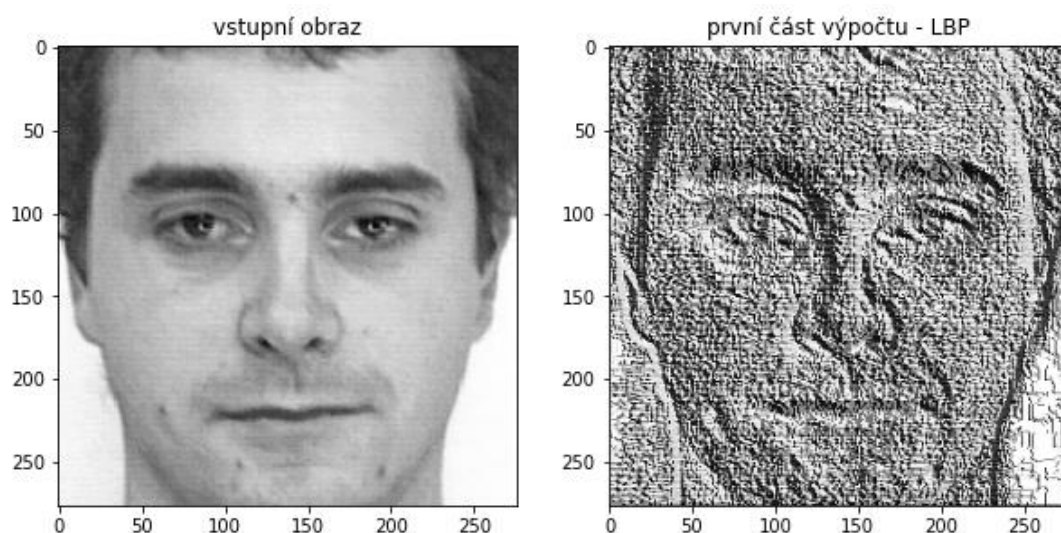


Obrázek 5.8: Neúspěšné rozpoznání ze sady 1

5.3 Rozpoznání obličeje – metoda LBPH

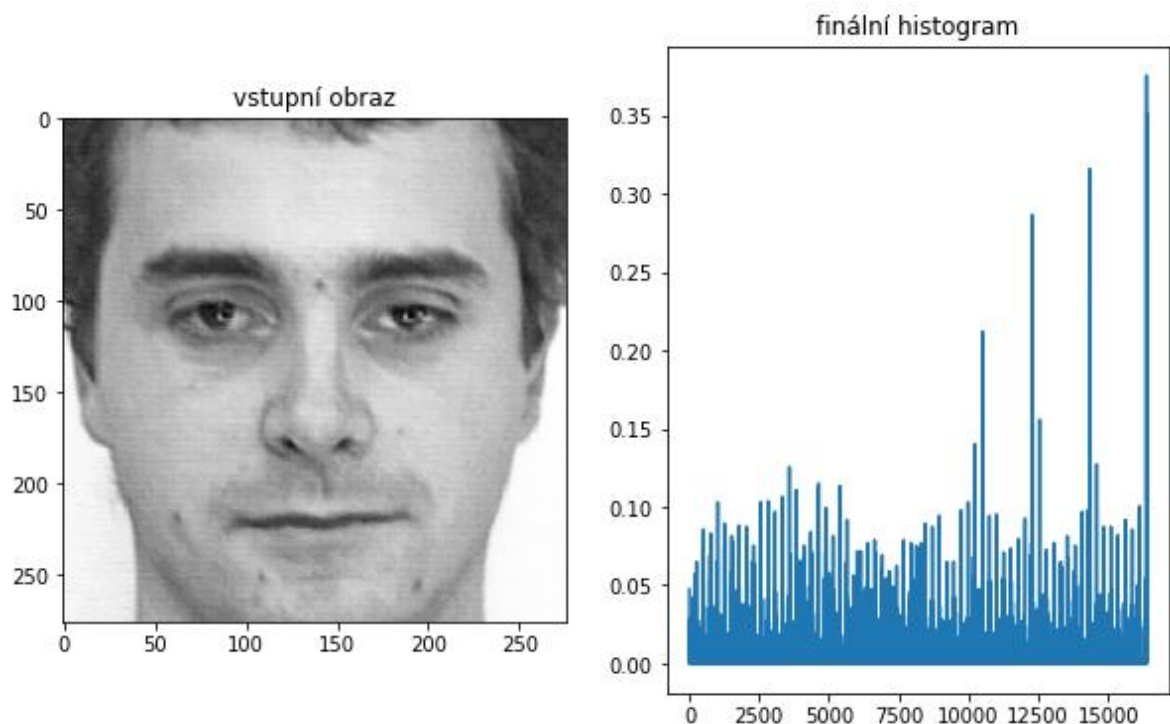
Druhou implementovanou metodou pro rozpoznání obličeje je metoda *Local binary patterns histograms*. Narozdíl od předchozí PCA se jedná o lokální metodu, při výpočtech tedy obraz nebere jako celek, ale zaměřuje se na obraz po částech. Tato metoda je popsána v teoretické části této práce, v kapitole 3.3.5., a byla testována na stejných sadách obrazů jako předchozí PCA. Pro vytvoření modelu byly použity knihovny z portálu *OpenCV*.

Výpočet LBPH byl v algoritmu realizován funkcí *LBPHFaceRecognizer_create*. Vstupují do ní tyto parametry: poloměr, sousedství, počet buněk ve vertikálním směru a počet buněk v horizontálním směru. Parametry poloměr a sousedství jsou použity v první fázi výpočtu. Jednotlivé obrazy jsou procházeny oknem, v němž jsou jednotlivé pixely převedeny na binární hodnoty. Poloměr udává velikost poloměru „kruhu“ pixelů okolo centrálního pixelu. Sousedství potom udává počet pixelů okolo centrálního vzorku. Výsledek této části výpočtu je znázorněn na obrázku 5.9. Použité parametry byly v tomto případě poloměr – 1 a sousedství – 8.



Obrázek 5.9: Výsledek převedení vstupního obrazu do LBP reprezentace

V následující fázi výpočtu jsou použity parametry počet buněk ve vertikálním směru a počet buněk v horizontálním směru. Tyto parametry určují velikost mřížky, kterou je obraz rozdělen. Histogramy jednotlivých buněk jsou poté spojeny ve finální histogram. Finální histogram kteréhokoliv ze vstupních obrazů je možné získat funkcí *getHistograms* a následně si jej zobrazit. Příklad finálního histogramu je znázorněn na obrázku 5.10. Histogram každé buňky obsahuje 256 hodnot, jež reprezentují výskyt jednotlivých intenzit. Pro tento příklad byly zvoleny parametry počet buněk pro oba směry 8. Celkem tedy bylo pro získání finálního histogramu použito 64 dílčích histogramů z jednotlivých buněk. Po spojení dílčích histogramů má finální histogram 16384 hodnot, viz. osa X na obrázku 5.10.



Obrázek 5.10: Finální histogram vstupního obrazu

Pro každý jednotlivý obraz tedy získáme finální histogram. Histogramy obrazů z testovací sady porovnáváme euklidovskou metrikou s trénovací sadou. Porovnání histogramů je v tomto případě realizováno funkcí *predict*. Ty obrazy, jejichž histogramy mají mezi sebou nejmenší vzdálenost, jsou vyhodnoceny jako shoda.

6. VÝSLEDKY

V následující kapitole jsou shrnuty úspěšnosti detekcí a rozpoznání na použitých obrazových sadách. Dále je srovnána účinnost rozpoznání jednotlivých metod v případech, kde se v trénovacích sadách obrazů vyskytovaly snímky s neideálními parametry. Následně je pomocí metrik FAR a FRR vyhodnocena bezpečnost systému.

6.1 Úspěšnost detekcí

Úspěšnost detekcí v trénovací sadě obrazů je popsána v tabulce 6.1.

Tabulka 6.1.: Podíl úspěšných detekcí obličeje

Sada	Podíl úspěšných detekcí	Procentuální podíl
Sada 1	240/240	100 %
Sada 2	129/130	99,2 %
Sada 3	300/300	100 %
Sada 4	297/300	99 %
Sada 5	298/300	99,3 %
Sada 6	668/780	85,6 %
Sada 7	787/968	81,3 %
Sada 8	582/728	79,9 %
Sada 9	463/480	96,4 %

V sadách 6,7,8 byla úspěšnost detekce nižší než ostatních sadách. Je to z toho důvodu, že v těchto sadách se nacházelo větší množství zastíněných snímků. Některé byly úplně nebo téměř úplně ponořeny do stínu, čímž se staly nedetekovatelnými. Příklad takových snímků je na obrázku 6.1.



Obrázek 6.1: Nedetekovatelné snímky vlivem velmi špatného osvětlení

6.2 Úspěšnost rozpoznání

Úspěšnost rozpoznání testovacích obrazů v rámci jejich trénovacích sad metodou PCA je popsána v Tabulce 6.2 a metodou LBPH v Tabulce 6.3.

Tabulka 6.2.: Úspěšnost rozpoznání testovacích obrazů pomocí metody PCA

Sada	Podíl úspěšných rozpoznání	Procentuální úspěšnost
Sada 1	17/24	74 %
Sada 2	9/10	90 %
Sada 3	20/20	100 %
Sada 4	19/20	95 %
Sada 5	20/20	100 %
Sada 6	22/25	88 %
Sada 7	23/25	92 %
Sada 8	11/25	44 %
Sada 9	8/10	80 %
Sada 10	97/100	97 %
CELKOVÁ ÚSPĚŠNOST	246/279	88,1 %

Tabulka 6.3.: Úspěšnost rozpoznání testovacích obrazů pomocí metody LBPH

Sada	Podíl úspěšných rozpoznání	Procentuální úspěšnost
Sada 1	18/24	75 %
Sada 2	9/10	90 %
Sada 3	20/20	100 %
Sada 4	19/20	95 %
Sada 5	20/20	100 %
Sada 6	25/25	100 %
Sada 7	25/25	100 %
Sada 8	14/25	64 %
Sada 9	10/10	100 %
Sada 10	100/100	100 %
CELKOVÁ ÚSPĚŠNOST	260/279	93,1 %

6.3 Srovnání metod

Úspěšnost metod PCA a LBPH při rozpoznání obličeje záleží především na kvalitě trénovacích dat. Jestliže je trénovací sada snímků pořízena z frontálního úhlu, snímky jsou kvalitně osvětleny a mají nízkou vnitřní variabilitu, budou metody dosahovat velmi dobrých výsledků. Při praktickém využití ale dostupná data vždy nemusí mít ideální parametry. V praktické části této práce bylo testováno deset obrazových sad. Nyní z těchto sad budou vyjmuty určité obrazy, aby bylo možné otestovat některé z těchto parametrů. Tímto způsobem bylo zjištěno, pro která data jsou metody vhodné. Byly testovány tyto parametry – normální osvětlení, špatné osvětlení, různé úhly, sluneční brýle, vousy / pokrývka brady. Porovnány byly také časové intervaly provedení algoritmu a byla vyhodnocena spolehlivost.

6.3.1 Normální osvětlení

Většina originálních sad obrazů, na kterých byly algoritmy testovány, obsahovala snímky, na nichž byli jedinci osvětleni tak, že byl jasně viditelný celý obličej. Při použití metody PCA na rozpoznání obličejů u první sady obrazových dat bylo úspěšně rozpoznáno 17 z 24 testovacích obrazů, při použití LBPH jich bylo úspěšně rozpoznáno 18 z 24. U poslední, tedy desáté sady obrazových dat, bylo za použití PCA úspěšně rozpoznáno 96 ze 100 testovaných obrazů, při použití LBPH bylo rozpoznáno 100 ze 100 testovaných obrazů.

6.3.2 Špatné osvětlení

Zde byl algoritmus otestován na obrazových datech, kde snímky nebyly ideálně osvětleny, příklad takových snímků je na obrázku 6.2.



Obrázek 6.2: Špatně osvětlené snímky

Na snímcích nebyly zachovány některé důležité charakteristické znaky. Metoda PCA se pro tato data ukázala jako nevhodná. Při použití LBPH bylo nicméně dosaženo dobrých výsledků, viz. tabulka 6.4.

Tabulka 6.4: Úspěšnost algoritmu při testování na sadě se špatným osvětlením

	Počet testovaných osob	Počet trénovacích obrazů na osobu	Úspěšnost rozpoznání – PCA	Úspěšnost rozpoznání – LBPH
Sada 1	20	6	5/20 (25 %)	19/20 (95 %)
Sada 2	15	6	4/15 (26,67 %)	12/15 (80 %)
Sada 3	11	6	3/11 (27,27 %)	9/11 (81,81 %)

6.3.3 Sluneční brýle

Poměrně často se vyskytující doplněk jsou sluneční brýle. Byla otestována sada obrazů, na kterých je lidé měli nasazené. Metodami PCA i LBPH bylo dosaženo velmi dobrých výsledků, viz. tabulka 6.5.

Tabulka 6.5: Úspěšnost algoritmu při testování na sadě, kde měli lidé nasazené sluneční brýle

	Počet testovaných osob	Počet trénovacích obrazů na osobu	Úspěšnost rozpoznání – PCA	Úspěšnost rozpoznání – LBPH
Sada 1	20	6	17/20 (85 %)	19/20 (95 %)
Sada 2	18	6	17/18 (94,4 %)	17/18 (94,4 %)
Sada 3	20	6	17/20 (85 %)	20/20 (100 %)

6.3.4 Různé úhly pořízení snímku

Snímky také nemusí být vždy pořízeny všechny pod stejným úhlem. Byla tedy otestována sada obrazů, které byly pořízeny pod různými úhly. Lepších výsledků bylo dosaženo použitím LBPH.

Tabulka 6.6: Úspěšnost algoritmu při testování na sadě snímané pod různými úhly

	Počet testovaných osob	Počet trénovacích obrazů na osobu	Úspěšnost rozpoznání – PCA	Úspěšnost rozpoznání – LBPH
Sada 1	14	7	8/14 (57 %)	11/14 (78,5 %)
Sada 2	16	7	11/16 (68,75 %)	14/16 (87,5 %)
Sada 3	8	7	5/8 (62,5 %)	6/8 (75 %)

6.3.5 Vousy / pokrývka brady

Dále byla otestována sada obrazů, na kterých měli testovaní jednotlivci zakrytou bradu. Metoda PCA pro rozpoznání jedinců na základě těchto trénovacích dat není vhodná.

Tabulka 6.7: Úspěšnost algoritmu při testování sadě, kde měli lidé zakrytou bradu

	Počet testovaných osob	Počet trénovacích obrazů na osobu	Úspěšnost rozpoznání – PCA	Úspěšnost rozpoznání – LBPH
Sada 1	20	3	6/20 (30 %)	18/20 (90 %)
Sada 2	18	6	8/18 (44,44 %)	14/18 (77,8 %)
Sada 3	14	6	8/14 (57,14 %)	14/14 (100 %)

6.3.6 Časová náročnost

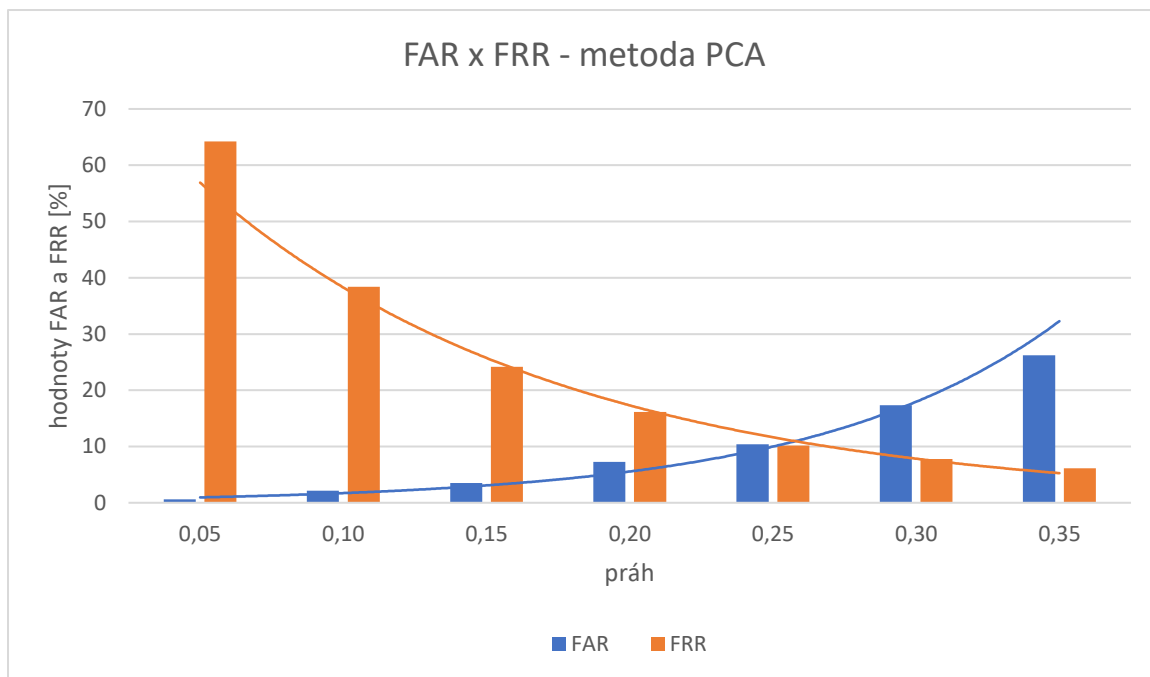
Dalším parametrem, který je při praktickém využití posuzován, je čas, za jaký je algoritmus vykonán. V tabulce 5.9 jsou časové úseky pro původní sady obrazů 1–10, za jaké byl algoritmus uskutečněn. Metoda PCA provedla rozpoznání ve všech případech rychleji.

Tabulka 6.8: Časová náročnost

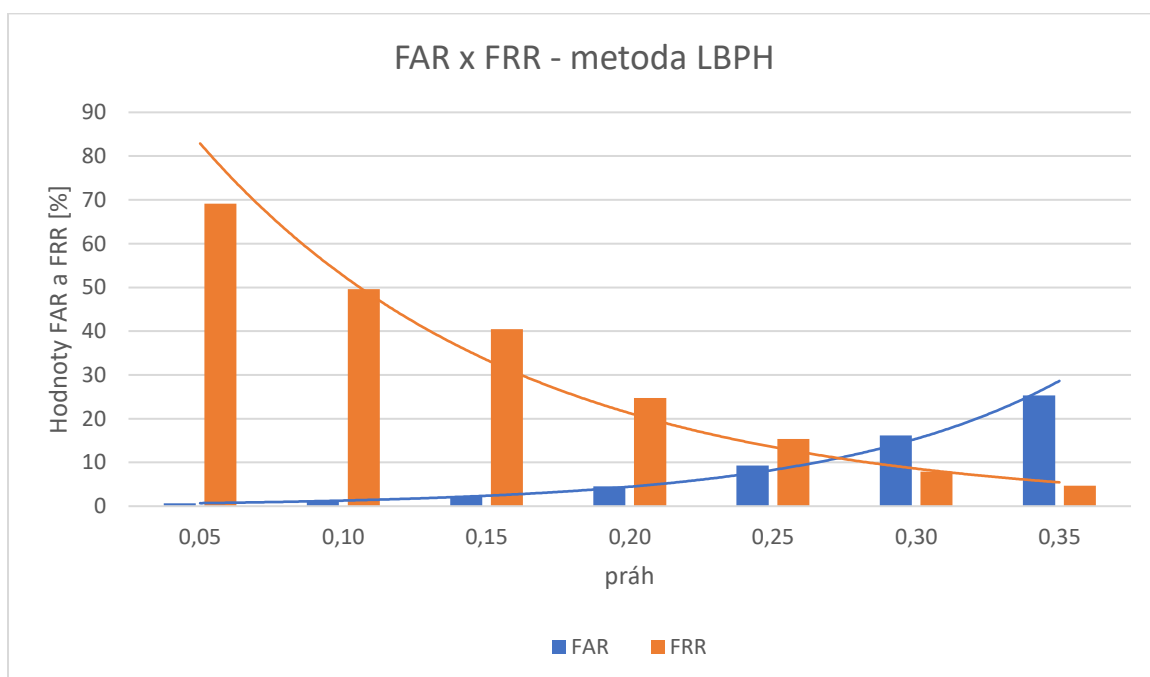
	PCA [s]	LBPH [s]
Sada 1	22.82	24.24
Sada 2	11.25	12.59
Sada 3	17.31	19.78
Sada 4	18.68	19.30
Sada 5	16.76	18.80
Sada 6	59.52	71.50
Sada 7	69.69	78.52
Sada 8	53.77	78.89
Sada 9	21.41	29.75
Sada 10	39.50	41.83

6.3.7 Hodnocení spolehlivosti

Jako parametry pro hodnocení bezpečnosti systému byly pro metody PCA a LBPH vyhodnoceny metriky FAR a FRR [30]. Metrika FAR je standardně vyjádřena jako počet rozdílných obrazů, které byly chybně přijaty jako shoda / celkový počet porovnání. FRR bývá vyjadřována jako počet shodných obrazů, které byly chybně přijaty jako neshoda / celkový počet porovnání. U obou metod pro rozpoznání obličeje je podobnost obrazů mezi testovací a trénovací sadou určena euklidovskou vzdáleností. Tyto vzdálenosti byly pro účely tohoto vyhodnocení normalizovány do intervalu 0–1 a posouváním tohoto prahu byly získány grafy, popisující FAR a FRR pro hodnoty daných prahů. Tyto parametry byly otestovány na sadě, která vznikla spojením dat z původních deseti obrazových sad, na kterých byl algoritmus testován. Výsledná sada pro vyhodnocení FAR a FRR má 21 testovacích obrazů, každá osoba má v trénovací sadě po deseti trénovacích obrazech. Na horizontální ose grafu jsou hodnoty prahů a na vertikální ose jsou hodnoty metrik FAR a FRR v procentech pro dané prahy.



Obrázek 6.3: Graf FAR x FRR pro PCA



Obrázek 6.4: Graf FAR x FRR pro LBPH

Z grafů je patrné, že s rostoucí FAR klesá FRR a naopak. Systém, který má velmi nízkou FAR, tedy bude vykazovat minimální chybné přijetí, ovšem za cenu vysokého FRR, tedy velkého rizika chybného odmítnutí. Je vhodné mezi těmito parametry najít kompromis. Bod kde se hypotetické křivky FAR a FRR protnou má název EER – *Equal Error Rate* [5]. Obecně lze říct, že čím je tato hodnota nižší, tím je daný biometrický systém spolehlivější. U metody PCA je tato hodnota EER = 11,28 % a u metody LBPH tato hodnota vyšla EER = 11,07 %. Tomu zjištění odpovídají výsledky testování úspěšnosti

rozpoznání – obě metody dosahují při použití standardních biometrických sad dobrých výsledků, u metody LBPH jsou výsledky mírně lepší.

7. DISKUZE

Algoritmus byl testován na deseti obrazových sadách. Pro detekci obličeje byl implementován Viola-Jones algoritmus tak, aby vytvořil *bounding box*, který bude značit detekovaný obličej. U detekce obličeje byla průměrná úspěšnost správné detekce 93,4 %. U prvních pěti obrazových sad byla úspěšnost velmi vysoká, dosahovala téměř 100 %. Na snímcích v těchto sadách byli jednotlivci dobře osvětleni a na snímcích se nacházel celý obličej. U sad 6–8 byla úspěšnost detekce nižší z důvodu nedostatečného osvětlení některých snímků. U sady 6 byla tato úspěšnost 85,6 %, u sady 7 83,1 % a u sady 8 79,9 %.

Aby mohly být metody rozpoznání obličeje aplikovány, byly lokalizované obličeje před zahájením rozpoznání normalizovány na stejnou velikost. U metody PCA figuruje jako nastavitelný parametr počet vlastních vektorů, ze kterých jsou poté spočítány váhy. Tyto váhy slouží k výpočtu podobností mezi trénovací a testovací sadou. Pro testování metody PCA byl počet vlastních vektorů v algoritmu nastaven na jednu šestinu počtu trénovací sady obrazů. PCA extrahuje z trénovacího datasetu charakteristické rysy pro daný dataset a bylo zjištěno, že při použití většího počtu vlastních vektorů se výsledky nezlepšují a při použití menšího počtu může úspěšnost klesat, charakteristických rysů by totiž nebylo dostatečné množství pro správné rozpoznání.

Metoda PCA pracuje s celým datasetem narozdíl od metody LBPH, která pracuje s každým obrazem zvlášť a lokálně extrahuje charakteristické rysy. Pro každý obraz v trénovací sadě je vytvořen finální histogram, který je srovnáván s testovací sadou. Bylo zjištěno, že parametry jsou pro rychlost a přesnost výpočtu ideální na hodnotách poloměr = 1 sousedství = 8 a počet buněk ve vertikálním i horizontálním směru = 8.

U rozpoznání obličeje dosahovala metoda PCA i LBPH velmi dobrých výsledků na kvalitních sadách obrazů. Celková úspěšnost testování originálních sad byla u PCA 88,1 % a u LBPH 93,1 %. Pro účely testování byly některé obrazové sady přeskupeny tak, aby na nich bylo možné otestovat přizpůsobivost metod na různé parametry. Pokud jednotlivci na snímcích nejsou dostatečně osvětleni, metoda PCA selhává, její průměrná úspěšnost byla v tomto případě 26,31 %. Je tomu z toho důvodu, že při nedostatečném osvětlení obličejů v trénovací sadě nemohou být extrahovány rysy, vypovídající o dané databázi. Metoda LBPH prochází jednotlivé obrazy po částech a pokud jsou obličeje osvětleny alespoň částečně, lze ji na rozpoznání použít. Průměrná úspěšnost LBPH byla v tomto případě 85,61 %.

Při testování s trénovací sadou, kde měli lidé na snímcích sluneční brýle, dosáhly obě metody dobrých výsledků. Jedná se o doplněk zakrývající oči, zbytek obrazu je viditelný a proto metoda PCA může extrahovat dostatečné množství rysů pro rozpoznání. Metoda PCA zde dosáhla průměrného úspěšného rozpoznání 88,13 % a metoda LBPH 96,46 %. Jako nevhodná se ukázala metoda PCA pro testovací sadu, kde měli lidé zakrytou spodní část obličeje. Zde už oproti slunečním brýlím byla zakryta příliš velká část obličeje pro úspěšné rozpoznání a průměrná úspěšnost tedy dosáhla 43,71 %. Metodou LBPH bylo u této sady nicméně dosaženo dobrého výsledku, a to průměrné úspěšnosti 89,26 %.

Podobně jako o u obrazů, které nebyly dostatečně osvětleny, i v tomto případě je LBPH svým lokálním přístupem schopna obrazy rozpoznat. Při testování sady, kde snímky byly pořízené z různých úhlů, nedosáhla ani jedna z metod příliš uspokojivých výsledků, o něco lépe si vedla metoda LBPH s průměrnou úspěšností rozpoznání 80,3 %. Při rozpoznávání pomocí metody PCA byla tato úspěšnost 63,5 %.

Na originálních deseti sadách, na kterých byly testovány metody PCA a LBPH, byl také zaznamenán čas, za který algoritmus provede rozměření. Metoda PCA provedla rozměření ve všech případech za menší časový úsek než metoda LBPH. Přehled časových intervalů, za které jednotlivé metody proběhly, je uveden v kapitole 5.4.5.

Metoda LBPH tedy stejně dobře nebo lépe pracuje s datsety, které nemají ideální trénovací data. Pokud je tedy k dispozici trénovací sada dat, která nemá ideální osvětlení fotografií nebo mají jedinci na hlavách různé artefakty (sluneční brýle, pokrývku brady...), je na základě výsledků testování lepší použít metodu LBPH. Při kvalitním trénovacím datsetu je preferovaná metoda PCA, protože výsledky budou stejně dobré, a za rychlejší časový úsek.

Jako statistické vyhodnocení spolehlivosti daných metod, byly použity metriky FAR – *False acceptance rate* a FRR – *False rejection rate*. Hodnoty podobností mezi obrazy testovací a trénovací sady byly normalizovány do intervalu 0 – 1 a v tomto intervalu byl stanoven práh přijetí. Posouváním tohoto prahu byly stanoveny grafy, kde byly tyto hodnoty vyhodnoceny. O celkové spolehlivosti daného systému vypovídá hodnota EER, tedy hodnota, kde se metriky FAR a FRR prolínají. Čím je tato hodnota nižší, tím je daný systém spolehlivější. Pro PCA je tato hodnota 11,28 % pro LBPH 11,07 %. Metoda LBPH byla teda na základě metriky EER vyhodnocena jako mírně spolehlivější.

ZÁVĚR

V první části této diplomové práce byla popsána teorie biometrie. Byly popsány charakteristiky a vlastnosti, na základě kterých mohou biometrické systémy vznikat. Důkladněji byla poté popsána biometrie obličeje – obecný postup při detekci a rozpoznání a poté vybrané metody, pomocí kterých může být biometrie obličeje realizována.

V praktické části byly nejdříve představeny sady obrazů, na kterých byl implementovaný algoritmus testován. Obrazová data pocházejí z různých zdrojů, vždy však jde o volně dostupné internetové databáze. Jednotlivé databáze obsahují biometricky rozmanitá data, včetně mužů i žen různých odstínů kůže s různými obličejovými doplňky. Sady se mezi sebou velikostí jednotlivých obrazů liší, pro potřeby biometrie jsou obrazy normalizovány.

V další části byl implementován algoritmus pro biometrii obličeje, a to ve dvou již zmiňovaných krocích – detekce a rozpoznání obličeje. K detekci byl použit Viola-Jones algoritmus a k rozpoznání dvě metody – analýza hlavních komponent (PCA) a lokální binární vzory histogramů (LBPH).

Úspěšná detekce pomocí Viola-Jones algoritmu byla v 93,4 % celkového počtu případů. Rozpoznání bylo úspěšné pomocí metody PCA v 88,1 % celkového počtu případů a pomocí metody LBPH v 93,1 % celkového počtu případů.

Algoritmus pro biometrii obličeje pomocí rozpoznání tváře byl implementován v programovacím prostředí Python, verze 3.7. Pro vytvoření funkčního biometrického systému byly použity knihovny strojového učení OpenCV a Scikit-learn a matematické knihovny NumPy a Matplotlib.

Metoda PCA funguje spolehlivě při použití kvalitních trénovacích databází, nicméně selhává při použití s databázemi, které jsou méně vyhovující, zejména u špatně osvětlených databází. Proto byla práce pro větší robustnost doplněna o metodu LBPH. Pracuje lokálně, narozdíl od holistické metody PCA, a funguje i se snímky, které jsou hůře osvětleny, je však časově náročnější. Na základě kvality poskytnutých trénovacích dat tak může být zvolen algoritmus, který by bylo vhodnější nasadit v dané situaci. Po dalších vylepšeních by tak program mohl nalézt využití v biometrických přístupových systémech.

Tato práce by mohla být v budoucnu rozšiřována testováním na dalších obrazových sadách a zefektivněním jednotlivých kroků implementovaného algoritmu. Dále by program mohl vyhodnocovat, kterou metodu by bylo vhodné použít, na základě hlubší analýzy trénovacího datasetu.

LITERATURA

- [1] DRAHANSKÝ, Martin a Filip ORSÁG. *Biometrie*. Brno, 2011.
- [2] UTKARSH, Sinha. *Integral images in OpenCV* [online]. , 1 [cit. 2021-11-22]. Dostupné z: <https://aishack.in/tutorials/integral-images-opencv/>
- [3] PERALA, Alex. *V2 Smart Card Uses FPC Sensor, Precise Biometrics Software* [online]. 2017 [cit. 2021-11-27]. Dostupné z: <https://findbiometrics.com/v2-smart-card-fpc-precise-biometrics-406091/>
- [4] BUDINGTON, William. *Iris Recognition* [online]. 2019 [cit. 2021-11-26]. Dostupné z: <https://www.eff.org/pages/iris-recognition>
- [5] DE KNECHT, Eduard. *FAR and FRR: security level versus user convenience* [online]. [cit. 2021-12-09]. Dostupné z: <https://www.recogtech.com/en/knowledge-base/security-level-versus-user-convenience>
- [6] RIZVI, Qaim, Bal AGARWAL a Rizwal BEG. *A review on face detection methods* [online]. 2011, , 12 [cit. 2021-11-25]. Dostupné z: https://www.researchgate.net/publication/257338580_A_Review_on_Face_Detection_Methods/link/00b7d524f090ac1bc4000000/download
- [7] SAN, Tang. *Human Face Detection Method Based on Skin Color Model* [online]. 2013, 6 [cit. 2021-11-22]. Dostupné z: https://www.researchgate.net/publication/269375611_Human_Face_Detection_Method_Based_on_Skin_Color_Model
- [8] Nusirwan Anwar, Abdul Rahman, Kit Chong a John See. *RGB-H-CbCr Skin Colour Model for Human Face Detection* [online]. 2005, , 6 [cit. 2021-12-28]. Dostupné z: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.718.1964&rep=rep1&type=pdf>
- [9] *Introduction to Computer Vision* [online]. [cit. 2021-12-28]. Dostupné z: <https://www.udacity.com/course/introduction-to-computer-vision--ud810>
- [10] Scott Tan Yeh Ping. *Face detection through template matching and color segmentation* [online]. 2002, 19 [cit. 2021-11-25]. Dostupné z: https://web.stanford.edu/class/ee368/Project_03/Project/reports/ee368group04.pdf
- [11] DALAL, Navneet a Bill TRIGGS. *Histograms of Oriented Gradients for Human Detection* [online]. 2005, , 8 [cit. 2021-11-25]. Dostupné z: <http://www.warse.org/IJETER/static/pdf/file/ijeter244892020.pdf>
- [12] BECALEL, Nabil, Abdel SALHI a Mustapha KARDOUCHI. *Histograms of fuzzy Oriented Gradients for Human Detection* [online]. 2013, 6 [cit. 2021-11-25]. Dostupné z: https://www.researchgate.net/publication/261377941_Histograms_of_fuzzy_oriented_gradients_for_face_recognition/download
- [13] ASHISH. *Understanding Edge Detection (Sobel Operator)* [online]. 2018 [cit. 2021-11-25]. Dostupné z: <https://medium.datadriveninvestor.com/understanding-edge-detection-sobel-operator-2aada303b900>

- [14] VIOLA, Paul a Michael JONES. *Rapid Object Detection using a Boosted Cascade of Simple Features* [online]. 2001, 9 [cit. 2021-11-22]. Dostupné z: <https://www.cs.cmu.edu/~efros/courses/LBMV07/Papers/viola-cvpr-01.pdf>
- [15] SAXENA, Pawan. *Face Recognition Using Eigenfaces (PCA Algorithm)* [online]. 2021 [cit. 2021-11-30]. Dostupné z: <https://www.geeksforgeeks.org/ml-face-recognition-using-eigenfaces-pca-algorithm/>
- [16] GUPTA, Surbhi, Kutub THAKUR a Munish KUMAR. SIFT Features for Face Recognition. *School of Electrical and Electronic Engineering Nanyang Technological University* [online]. 2020, 2020, 5 [cit. 2022-05-19]. Dostupné z: <https://ieeexplore.ieee.org/document/5256630>
- [17] CHERALI, Fatma, A. DJERADI a R. *Linear discriminant analysis for face recognition* [online]. 2009 [cit. 2021-12-05]. Dostupné z: <https://ieeexplore.ieee.org/document/5256630>
- [18] COOTES, T.F. a C.J. TAYLOR. *Statistical models of appearance for medical image analysis and computer vision* [online]. 2001, , 14 [cit. 2021-12-05]. Dostupné z: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.5.7256&rep=rep1&type=pdf>
- [19] COOTES, Tim. *An introduction to active shape models* [online]. 1999 [cit. 2021-12-08]. Dostupné z: https://person.hst.aau.dk/lasse/teaching/IACV/doc/asm_overview.pdf
- [20] PRADO, Kelvin. *Face Recognition: Understanding LBPH Algorithm* [online]. 2017 [cit. 2021-12-01]. Dostupné z: <https://towardsdatascience.com/face-recognition-how-lbph-works-90ec258c3d6b>
- [21] SINGH, Parth. *Understanding Face Recognition using LBPH algorithm* [online]. 2021 [cit. 2021-12-01]. Dostupné z: <https://www.analyticsvidhya.com/blog/2021/07/understanding-face-recognition-using-lbph-algorithm>
- [22] SIGH, Swarnima a Durgesh SIGH *Face Recognition Using HOG Feature Extraction and SVM Classifier* [online]. 2020, 8(9), 4 [cit. 2021-11-25]. Dostupné z: <http://www.warse.org/IJETER/static/pdf/file/ijeter244892020.pdf>
- [23] *Face Databases* [online]. [cit. 2021-12-08]. Dostupné z: http://web.mit.edu/emeyers/www/face_databases.html
- [24] SPACEK, Libor. *Libor Spacek's Facial Images Databases* [online]. 2009 [cit. 2021-12-08]. Dostupné z: <https://cmp.felk.cvut.cz/~spacelib/faces/>
- [25] DELAC, Kresimir a Mislav GRGIC. *FACE RECOGNITION HOMEPAGE* [online]. [cit. 2022-05-05]. Dostupné z: <https://www.face-rec.org/databases/>
- [26] *OpenCV: Cascade Classifier* [online]. [cit. 2021-12-07]. Dostupné z: https://docs.opencv.org/3.4/db/d28/tutorial_cascade_classifier.html
- [27] *Istock Photo* [online]. [cit. 2021-12-07]. Dostupné z: <https://www.istockphoto.com/cs/search/2/image?phrase=group+of+people+standing>
- [28] Pedregosa et al. *Scikit learn* [online]. 2011 [cit. 2021-12-09]. Dostupné z: <https://scikit-learn.org/stable/modules/generated/sklearn.decomposition.PCA.html>

- [29] TRIVEDI, Shubhendu. *Face Recognition using Eigenfaces and Distance Classifiers: A Tutorial* [online]. 2009 [cit. 2021-12-09]. Dostupné z: https://onionesquereality.wordpress.com/2009/02/11/face-recognition-using-eigenfaces-and-distance-classifiers-a-tutorial/?fbclid=IwAR3PU9VYE0n250aeDUAv-xoGljvsfqEyri_yqvJFoUwXHckB6IFov5CbxTU
- [30] ABDULLAH, Manal, Majda WAZZAN a Sahar BO-SAEED. OPTIMIZING FACE RECOGNITION USING PCA. *International Journal of Artificial Intelligence & Applications* [online]. 2012, 9 [cit. 2022-05-05]. Dostupné z: <https://arxiv.org/ftp/arxiv/papers/1206/1206.1515.pdf>