

Ing. Matej Féder

Autoreferát dizertačnej práce

NÁVRH METÓD EXTRAKCIE PRÍZNAKOV A KLASIFIKÁCIE DÁT V BIOMETRII

na získanie akademickej hodnosti doktor (philosophiae doctor, PhD.)

v doktorandskom študijnom programe: Aplikovaná informatika

v študijnom odbore 9.2.9 Aplikovaná informatika

Miesto a dátum: Bratislava, 2015

**SLOVENSKÁ TECHNICKÁ UNIVERZITA
V BRATISLAVE
FAKULTA ELEKTROTECHNIKY A INFORMATIKY**

Ing. Matej Féder

Autoreferát dizertačnej práce

NÁVRH METÓD EXTRAKCIE PRÍZNAKOV A KLASIFIKÁCIE DÁT V BIOMETRII

na získanie akademickej hodnosti doktor (philosophiae doctor, PhD.)

v doktorandskom študijnom programe: Aplikovaná informatika

Miesto a dátum: Bratislava, 2015

Dizertačná práca bola vypracovaná v dennej forme doktorandského štúdia

Na Ústave informatiky a matematiky, Fakulta Elektrotechniky
a Informatiky

Predkladateľ: Ing. Matej Féder
Ústav informatiky a matematiky, FEI STU Bratislava
Ilkovičova 3, 812 19 Bratislava

Školiteľ: prof. Dr. Ing. Miloš Oravec

Oponenti: 1. prof. Ing. Dušan Levický, PhD.,
Katedra elektroniky a multimediálnych telekomunikácií,
Fakulta elektrotechniky a informatiky, Technická univerzita Košice,
Park Komenského 13, 041 20 Košice

2. Ing. Marián Beszédeš, PhD.,
Innovatrices s.r.o.,
Pri Vinohradoch 82, Bratislava

Autoreferát bol rozoslaný: 10.02.2015

Obsah

1	ÚVOD	4
2	PREHĽAD SÚČASNÉHO STAVU PROBLEMATIKY	5
2.1	NOVÉ METÓDY PRE ROZPOZNÁVANIE TVÁRÍ V NERIADENÝCH PODMIENKACH	5
2.2	NOVÉ METÓDY PRE PROBLÉM JEDINEJ TRÉNOVACEJ VZORKY.....	6
2.3	ROZPOZNÁVACIE SYSTÉMY PRACUJÚCE NA ZÁKLADE ĽUDSKEJ TVÁRE	7
3	CIELE PRÁCE.....	8
3.1	EXTRAKCIA PRÍZNAKOV.....	8
3.2	PROBLÉM JEDINEJ DOSTUPNEJ VZORKY	8
3.3	ROZPOZNÁVANIE TVÁRÍ V NERIADENÝCH PODMIENKACH	8
3.4	SYSTÉM ROZPOZNÁVANIA ĽUDSKÝCH TVÁRÍ	9
4	VYKONANÉ EXPERIMENTY A VÝSLEDKY DIZERTAČNEJ PRÁCE	9
4.1	ROZPOZNÁVANIE TVÁRÍ V RIADENÝCH PODMIENKACH.....	9
4.1.1	<i>Vplyv veľkosti obrazu a počtu trénovacích vzoriek na úspešnosť rozpoznávania vybraných metód.....</i>	<i>9</i>
4.1.2	<i>Návrh metód extrakcie príznakov HLO a INDEX pre rozpoznávanie tvárí</i>	<i>10</i>
4.2	ROZPOZNÁVANIE TVÁRÍ V NERIADENÝCH PODMIENKACH	11
4.2.1	<i>Návrh metód rozpoznávania tvárí pre multimodálne rozhranie</i>	<i>11</i>
4.2.2	<i>Návrh metód pre rozpoznávanie tvárí poškodených pri prenose komunikačným kanálom.....</i>	<i>12</i>
4.2.3	<i>Návrh metód pre rozpoznávanie tvárí čiastočne prekrytých a zašumených obrazov.....</i>	<i>13</i>
4.2.4	<i>Rozpoznávanie tvárí pre jedinú vzorku v trénovej množine.....</i>	<i>14</i>
4.3	AUTOMATICKÝ VÝBER TRÉNOVACÍCH VZORIEK POMOCOU ZHLUKOVACÍCH ALGORITMOV	15
4.4	BIOMETRICKÝ ROZPOZNÁVACÍ SYSTÉM NA ZÁKLADE ĽUDSKEJ TVÁRE.....	16
5	SPLNENIE CIEĽOV DIZERTAČNEJ PRÁCE	18
6	SUMARIZÁCIA PUBLIKOVANÝCH PRÍNOSOV A ĎALŠIE MOŽNÉ SMERY VÝSKUMU	18
7	VEDECKÝ PROJEKT AUTORA.....	19
8	ÚČASŤ AUTORA V PROJEKTOCH.....	19
9	PUBLIKÁCIE AUTORA	20
10	ZOZNAM POUŽITEJ LITERATÚRY	21

1 Úvod

Využitie biometrických charakteristík človeka sa stáva čoraz preferovanejšou metódou pre spoľahlivú identifikáciu, alebo verifikáciu používateľa v širokej škále aplikácií. Komerčné biometrické rozpoznávacie systémy používajú klasifikačne silné, ľahko merateľné a akceptovateľné biometriky, medzi ktoré sa radí aj ľudská tvár [Biom06]. Dizertačná práca sa zaoberá rozpoznávaním ľudských tvárí na základe obrazu.

Prvé automatické rozpoznávanie na základe tváre sa dostalo do povedomia a praxe v roku 1991, keď Turk a Pentland [Turk91] publikovali rozpoznávací systém, ktorý vedel spoľahlivo identifikovať osoby v reálnom čase. Publikácia [Turk91] bola pre rozpoznávanie na základe tváre významná a nasledujúce obdobie prinieslo veľký nárast prác [Zhao03] a obsiahlych porovnávacích testov v tejto oblasti. Najznámejšie testy sú organizované inštitútom NIST (National Institute of Standards and Technology) [www.nist.gov] v ktorých rôzni výrobcovia biometrických zariadení a organizácie zaoberajúce sa touto problematikou vyhodnocujú svoje algoritmy. Boli zozbierané referenčné databázy ľudských tvárí, ktoré v jednotlivých testoch FERET 1993 a 1996 (Facial Recognition Technology), MBE 2010 (Multibiometric Evaluation), FRVT 2000, 2002, 2006, 2012 a 2013 (Face Recognition Vendor Test) umožňujú objektívne porovnať vyvinuté algoritmy a metódy.

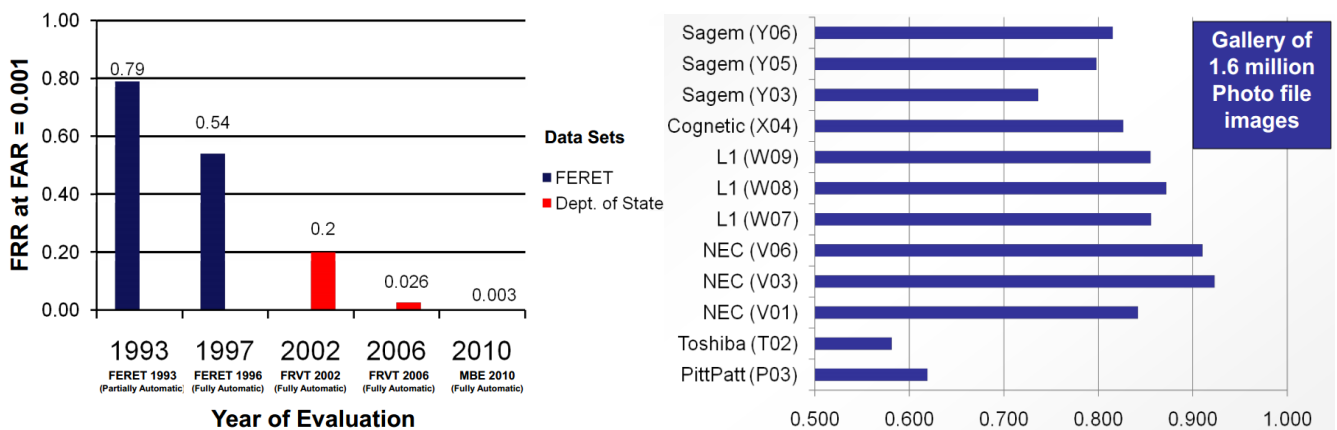
Tieto testy, viaceré prehľadové publikácie [A11], [Zhao03] a kapitoly v knihách [Ross07] uvádzajú vysokú presnosť rozpoznávania tváre (viac ako 95%) a všeobecne platí tvrdenie, že rozpoznávanie tvárí na dvojrozmernom obraze v riadených podmienkach je už vyriešená úloha. Riadené podmienky sú vopred definované a zahŕňajú kontrolované osvetlenie tváre snímaného subjektu, pozadie, vzdialenosť subjektu od snímacieho zariadenia, natočenie, alebo výraz tváre a pod. Rozpoznávacie systémy určené pre komerčné použitie často pracujú v neriadených, prirodzených podmienkach reálneho sveta. Tieto neriadené podmienky majú výrazný dopad na úspešnosť rozpoznávacích algoritmov a obmedzujú možnosti nasadenia biometrických systémov.

V dizertačnej práci sa zaoberáme problematikou rozpoznávania obrazu ľudskej tváre, pričom sa venujeme viacerým oblastiam. Zaoberáme sa rozpoznávaním tvárí v riadených podmienkach, kde sledujeme úspešnosti rozpoznania na referenčnej databáze FERET [Phil00] s použitím nových metód extrakcie príznakov a viacerých klasifikačných metód.

Podrobnejšie sa venujeme oblasti rozpoznávania v neriadených podmienkach. Tieto podmienky sú umelo vytvorené pomocou pridávania rôznych typov šumu, rôznymi prekrytiami, alebo v prípade simulácie chybujúceho prenosového kanála, náhodnými chýbajúcimi blokmi v originálnych obrazoch databázy FERET. Vplyv zmien osvetlenia na úspešnosť rozpoznania, ako aj riešenie tohto problému použitím vhodného predspracovania vstupného obrazu a vhodných metód extrakcie a klasifikácie analyzujeme na databáze CMU PIE (Carnegie Mellon University Pose, Illumination, and Expression) [http://www.cs.cmu.edu/], ktorá bola zozbieraná práve pre experimenty v neriadených podmienkach. Dôležitou súčasťou rozpoznávania na základe ľudskej tváre pri neriadených podmienkach je aj analýza dôležitosti jednotlivých tvárových črt ako sú oči a obočie pre metódy strojového učenia, ako aj porovnanie úspešnosti rozpoznania s ľudským vnímaním. Ďalej sa venujeme rozpoznávaciemu problému s jedinou dostupnou trénovacou vzorkou (snímkou, fotografiou, vzorom) na subjekt (z angl. One Sample Per Person Problem). Tento prístup poskytuje minimálne množstvo informácie o danom subjekte, avšak vhodnými algoritmami pre vytvorenie syntetickej, umelej vzorky, z práve jedinej dostupnej vzorky, dosahuje aj v porovnaní s rozpoznávaním na väčšom počte dostupných vzoriek prijateľné výsledky. Vytváranie týchto umelých vzoriek modifikáciou originálnej vzorky, či už pomocou jednoduchých modifikácií ako šum, mediánový filter, alebo waveletových transformácií zahrňujeme v experimentálnej časti tejto práce. Navrhli a zrealizovali sme komplexný biometrický systém pracujúci na základe ľudskej tváre, ktorý bol vyvinutý pre účely projektu 7 rámcového programu (FP7-ICT-2011-7-287848) s názvom HBB-NEXT [http://www.hbb-next.eu/index.php]. Pri tvorbe rozpoznávacieho systému boli využité poznatky z experimentov rozpoznávania v riadených aj neriadených podmienkach a výberu vhodných trénovacích vzoriek pomocou zhlukovacích algoritmov.

2 Prehľad súčasného stavu problematiky

Posledné ukončené porovnanie algoritmov rozpoznávania tváří, ktoré bolo zverejnené organizáciou NIST, je vyhodnotenie MBE 2010 [http://www.nist.gov/itl/iad/ig/mbe.cfm]. Prezentácia [Phil10], ktorá sumarizuje dosiahnuté výsledky, uvádza vývoj úspešnosti verifikácie od prvého FERET testu v roku 1993 po MBE 2010 a rovnako aj úspešnosti testov identifikácie na uzavretej množine, ktorá obsahovala 1,6 milióna obrazov tváří (Obr. 1). Ako môžeme vidieť na Obr. 1 od roku 1993 prišlo k zlepšeniu verifikácie pri riadených podmienkach o 3 rády a úspešnosť identifikácie algoritmov (vyvinuté rôznymi organizáciami ako Sagem, NEC a pod.) dosiahla 93% (treba brať na vedomie extrémne veľkú testovaciu databázu tváří).



Obr. 1 Vývoj hodnôt FRR pri konštantnej hodnote FAR=0,001 pre verifikáciu na databázach ľudských tváří FERET a Dept. of State a úspešnosti identifikácie na databáze 1,6 milióna ľudských tváří, dosiahnuté rôznymi organizáciami [Phil10]

Tieto testy verifikácie a identifikácie na základe ľudskej tváre dokazujú, že nové algoritmy rozpoznávania tváří sú schopné pri riadených podmienkach dosahovať veľmi vysokú úspešnosť a platí tvrdenie, že rozpoznávanie tváří na dvojrozmernom obraze v riadených podmienkach je už vyriešená úloha.

V dizertačnej práci preto väčšiu pozornosť venujeme rozpoznávaniu tváří v neriadených podmienkach. V nasledujúcom texte zosumarizujeme vývoj nových algoritmov a popíšeme rôzne rozšírenia štandardných metód za účelom zvýšenia odolnosti proti negatívnym vplyvom neriadených podmienok. Rovnako sa bližšie venujeme aj porovnaniu a analýze nových metód pre problém jedinej trénovacej vzorky.

2.1 Nové metódy pre rozpoznávanie tváří v neriadených podmienkach

Snímanie obrazov tváří v reálnych podmienkach, ktoré sú nazvané ako neštandardné (z angl. unconstrained), alebo neriadené (z angl. uncontrolled), prináša viacero nevýhod, negatívnych vplyvov, ktoré majú výrazný dopad na úspešnosť rozpoznávacích systémov. Tejto oblasti sa v poslednom období venovalo viacero prehľadových publikácií [Sing10], [Shao10], [Boom10], ktoré za neriadené (neštandardné) podmienky považujú zmeny osvetlenia na jednotlivých obrazoch rovnakého subjektu, zmeny výrazu ľudskej tváre, alebo polohy tváre na obraze. Ďalej sú to rôzne prekrytia tváre subjektu (napr. šalom, šatkou, okuliarmi a pod.), malé rozlíšenie, alebo prítomnosť šumu v obraze. S narastajúcou zmenou intenzity osvetlenia, uhlom natočenia tváre [Gros04], alebo percentom prekrytia obrazu [Xing12] výrazne klesá úspešnosť klasických rozpoznávacích metód.

Viacere nové prístupy dosahujú v porovnaní s klasickými metódami ako PCA, alebo LDA zvýšenú úspešnosť rozpoznania. Napríklad už použitie rozšírení týchto klasických metód na kernelovú analýzu hlavných komponentov (Kernel Principal Component Analysis, KPCA) [Wang10] a [Xie10], alebo zovšeobecnenú diskriminačnú analýzu (Generalized Discriminant Analysis, GDA) [Qing02] prinieslo zvýšenie rozpoznávacej úspešnosti na obrazoch ľudských tváří v prípadoch rozdielného výrazu tváre, alebo rôznych svetelných podmienok pri snímaní subjektu. V publikácii [Vino13] pomocou

predspracovania, následného rozkladu obrazu pomocou Fourierovej transformácie a použitií PCLDA (Principal Component Linear Discriminant Analysis) algoritmu úspešne potlačili negatívny vplyv zmeny osvetlenia. Navrhnutým postupom dosiahli zvýšenie úspešnosti verifikácie a zníženie výpočtovej náročnosti. V publikáciách [Chie10], [Dehk10] experimentálne dokázali účinnosť Gáborových filtrov na obrazoch s rôznymi výrazmi tváre. V [Zhi08] boli Gáborove filtre úspešne použité pri obrazoch s meniacou sa pózou tváre. Zaujímavé porovnanie metód bolo publikované v [Vers08]. Autori porovnali metódy LBP (Local Binary Patterns) [Ahon04], GJD (Gabor Jets Descriptors) [Zou07] a ERCF (Extremely Randomized Clustering Forest) [Moos08]. S prihliadnutím na meranie časovej náročnosti metód autori zhodnotili, že metóda LBP je spomedzi testovaných najvhodnejšia pre aplikácie pracujúce v reálnom čase a v reálnych, neriadených podmienkach. V publikácii [Suru12] označili metódu LBP ako celkovo najúspešnejšiu pre rozpoznávanie tvári a vypracovali zaujímavé porovnanie 7 rôznych rozšírení základného algoritmu LBP. Záverečné zhodnotenie autorov potvrdzuje, že metódy LTP (Local Texture Pattern) a LDP (Local Derivative Pattern) dosahujú najlepšie výsledky v porovnaní s ostatnými metódami, ktoré sú založené na LBP.

2.2 Nové metódy pre problém jedinej tréningovej vzorky

Problematika nazvaná ako "problém jedinej vzorky na subjekt" (z angl. One Sample Per Person Problem) rieši rozpoznávanie tvári s jedinou dostupnou vzorkou pre tréningový proces metód. Možností riešenia je viacero. V prehľadovom článku [Tan06], ktorý popisuje stav problematiky do roku 2006 sú metódy riešiace problém rozpoznávania s jedinou vzorkou na subjekt delené na holistické, lokálne a hybridné. Podrobný prehľad po roku 2006 a početné experimenty rôznych holistických prístupov môžeme nájsť v knižnej kapitole [A11].

Lokálne metódy sú zamerané na vyčlenenie čo najväčšej informačnej hodnoty z častí obrazu. Čiže delia obraz na podoblasti s najvyšším potenciálom získania podstatných príznakov. Lokálna metóda navrhnutá v publikácii [Yong12] delí obraz tváre na 4 hlavné oblasti, pričom je každá z nich ešte delená na viacero podoblastí. Z jednotlivých podoblastí sú následne extrahované príznaky pomocou 2D DCT (Discrete Cosine Transform) a pomocou slovníka preložené do čiastkových vektorov, ktoré spoločne tvoria výsledný vektor príznakov. Testy verifikácie pomocou takto spracovaného vstupného obrazu priniesli zvýšenie rozpoznávacej úspešnosti. V publikácii [Jiwe13] bola navrhnutá metóda DMMA (Discriminative Multimanifold Analysis), ktorá delí obraz na podoblasti, ktorých vzájomné vzdialenosti sú v podpriestore maximalizované navrhnutým algoritmom. V tejto publikácii autori vypracovali prehľadné porovnanie metód používaných pri riešení problému jedinej vzorky na subjekt.

Holistické metódy používajú celý obraz na vstup jednotlivých metód. Viacero týchto metód je založených na PCA. Ide napríklad o jej rozšírenia na 2DPCA [Yang04], alebo rozšírenia navrhnuté Z.H. Zhou a kolektívom [Wu02], [Chen04a] pomenované ako $(PC)^2A$ a Enhanced $(PC)^2A$, kde pomocou lineárnej projekcie intenzity vstupného obrazu modifikujú tento vstupný obraz, pričom sa zvyšuje rozpoznávacia úspešnosť s použitím práve tejto jedinej modifikovanej vzorky. V [Biao12] s úspechom kombinujú projekciu tréningových dát do PCA podpriestoru s projekciou do LDA podpriestoru. Výstupy z oboch projekcií následne normalizujú pomocou Z-skóre. Nová metóda extrakcie príznakov s názvom UP (Uniform Pursuit) bola navrhnutá v [Deng10]. Táto metóda využíva štandardnú PCA pre redukciu dimenzie vstupnej vzorky a následne autori použili nový postup pre projekciu dát do podpriestoru. Vo výslednom porovnaní bolo experimentálne dokázané, že metóda UP môže úspešne konkurovať ostatným novým metódam extrakcie pre účely rozpoznávania na jedinej vzorke.

Veľká skupina holistických prístupov, riešiacich problém jedinej vzorky sa zameriava na rozšírenie tréningovej množiny o syntetické, modifikované obrazy, ktoré sú vytvárané práve z jediného originálneho obrazu. Tieto nové dáta poskytujú novú informáciu o jedincovi a zvyšujú rozpoznávaciu schopnosť metód. Spôsoby, ako vytvoriť novú vzorku, sú rôzne. [Zhao03] ponúka prehľad týchto metód, kde popisuje rôzne geometrické transformácie, škálovanie mierky, bilaterálne symetrické transformácie, generovanie nových póz, alebo výrazov tváre.

2.3 Rozpoznávacie systémy pracujúce na základe ľudskej tváre

V tejto kapitole dizertačnej práce sú popísané vybrané komerčné rozpoznávacie systémy, ktoré pracujú na základe ľudskej tváre. Je zrejmé, že samotný softvér a algoritmy ktoré sú v systémoch implementované nie sú voľne dostupné. Cieľom je priblížiť rôzne scenáre tréningového a rozpoznávacieho procesu, ktoré sú pre samotný návrh komplexného rozpoznávacieho systému podstatné.

Spoločnosť Eurotech [<http://www.eurotech.com>] uviedla na trh v roku 2012 biometrický rozpoznávací systém pracujúci na základe ľudskej tváre s názvom SekuFACE [<http://www.eurotech.com/en/products/SekuFACE>]. Systém obsahuje 1,3M pixelovú CCD kameru, ktorá dokáže pracovať aj pri výrazne zhoršených svetelných podmienkach (schopnosť rozpoznávania počas dňa aj v noci) vďaka integrovanému infračervenému žiaru (žiari s vlnovou dĺžkou 850nm), ktorý osvetľuje scénu pred objektívom kamery v uhle 30°. Výrobcovia udávajú priemernú úspešnosť identifikácie 95%. Komunikácia medzi inými biometrickými systémami je zabezpečená vďaka štandardu ISO/IEC 19794-5:2005 [<http://www.ansi.org/>]. Systém pracuje v troch základných módoch (1. snímací mód, 2. záznamový mód - vytvorenie sa profil nového používateľa, 3. identifikačný mód). Vyžaduje sa približná 1m vzdialenosť tváre subjektu od kamery a frontálny pohľad priamo do objektívu kamery. Zariadenie identifikuje vždy jedného používateľa. Výrobcovia udávajú dobu trvania záznamového módu na 3 sekundy a identifikačného rovnako na 3 sekundy pri 1000 profiloch používateľov uložených v databáze systému.

Spoločnosť Lathem [<http://www.lathem.com/>] sa špecializuje na výrobu prístupových systémov. Ponúka dve riešenia pracujúce na základe ľudskej tváre označené ako FR650 a FR700. Posledný produkt FR700 z roku 2011 obsahuje, na rozdiel od staršej verzie FR650, čítačku čipových prístupových kariet, ktorá rozširuje prístupové možnosti zariadenia FR700. Používateľ môže byť systémom FR700 identifikovaný iba na základe tváre, alebo čipovej karty. Vo verifikačnom móde je používateľ verifikovaný na základe kombinácie číselného kódu, alebo čipovej karty s tvárou. Zariadenie identifikuje alebo verifikuje vždy jedného používateľa. Rozpoznávací systém používa dve snímacie kamery, ktoré spoločne vytvárajú 3D obraz detekovanej tváre. Tým sa eliminuje možnosť falošnej autentifikácie pomocou 2D fotografie oprávneného používateľa. Výrobca v špecifikácii produktu FR700 udáva jeho funkčnosť v svetelných podmienkach od 0 Lux do 5000 Lux, vďaka 14 infračerveným diódam, ktoré tvár osvetľujú. Pracovná vzdialenosť tváre subjektu od kamier je od 30,5 cm do 76 cm. Tréningový proces trvá približne 10 sekúnd, počas ktorých sa najskôr tvár v obraze detekuje a vyhodnotí úspešnosť detekcie pomocou zeleného rámu v okolí tváre. Ďalej je snímaný používateľ systémom navigovaný, aby vykonal mierne pootočená hlavy do rôznych smerov. V prípade, ak používateľ nosí dioptrické okuliare odporúča sa, aby 50% procesu snímania subjekt absolvoval s okuliarmi a 50% bez okuliarov (slnečné okuliare a okuliare s tmavými sklami nie sú povolené). Rýchlosť rozpoznania na jeden subjekt je menšia ako 1 sekunda. Maximálny počet používateľov na jedno zariadenie FR700 je 500.

Spoločnosť XID Technologies [<http://www.xidtech.com/>] vyvinula SMARTID verifikačný systém, ktorý umožňuje prístup používateľa pomocou čipovej karty a tváre. Dokáže pracovať v neriadených podmienkach a je určený na exteriérové použitie. Patentovaný algoritmus rozpoznávania pracuje na základe syntetizovaného 3D obrazu tváre a dokáže používateľa verifikovať v čase do 3 sekúnd. Novší verifikačný systém REVOFace z roku 2011 pracuje na podobnom princípe. Rovnako je určený do neriadených podmienok a výrobca udáva zlepšený čas verifikácie jedného subjektu, ktorý je do 2 sekúnd. Spoločnosť Cognitec [<http://www.cognitec-systems.de/>] je zameraná na vývoj softvéru v oblasti rozpoznávania tvárí od roku 1995. Produkt FaceVACS-VideoScan je určený pre detekciu a identifikáciu aj viacerých subjektov v reálnom čase z video záznamu. Spomínané riešenia sú založené na technológii FaceVACS [<http://www.cognitec-systems.de/Technology.24.0.html>], ktorej algoritmy boli hodnotené vo viacerých porovnávacích testoch inštitútu NIST a dosiahli takmer 100% úspešnosť rozpoznania. Sú definované minimálne požiadavky na obraz tváre: obraz musí byť ostrý, vzdialenosť medzi očami jedného subjektu musí byť väčšia ako 32 pixelov, oblasť tváre musí mať najmenej 64 odtieňov šedej farby a pod. Pre optimálne fungovanie algoritmu je odporúčané použiť obrazy v súlade so štandardom ISO/IEC 19794-5:2005 a s frontálnym pohľadom tváre.

Spoločnosť Neurotechnology [<http://www.neurotechnology.com/>] vyvinula algoritmus VeriLook, ktorého posledná verzia v5.3 bola vydaná začiatkom roku 2013. Modul detekcie tváří dokáže v čase od 0,01 sekundy do 0,86 sekundy detekovať tváre z obrazu, alebo jedného rámca video sekvencie a obsahuje aj modul extrakcie (čas extrakcie v rozmedzí od 0,03 sekundy do 0,17 sekundy). Pre VeriLook sú definované rôzne odporúčania, ktoré ovplyvňujú celkovú úspešnosť systému. Je odporúčané snímať obrazy pre trénovací a testovací proces s rovnakou kamerou s minimálnym rozlíšením 640 x 480 pixelov. Pre trénovací proces je odporúčané zosnímať viac rôznych obrazov, pri rôznych prirodzených výrazoch tváre na jeden subjekt, ale nie je definovaný presný scenár snímania. Vzdialenosť medzi očami jedného subjektu musí byť väčšia ako 50 pixelov, pričom pri 75 pixeloch a viac pixeloch je systém úspešnejší. Sú odporúčané kontrolované svetelné podmienky. Natočenie tváre +/- 15° vo všetkých smeroch oproti frontálnej póze systému neprekáža.

3 Ciele práce

Na základe doterajších poznatkov a preštudovanej literatúry v oblasti rozpoznávania ľudskej tváre v obraze sme si stanovili nasledovné ciele:

3.1 Extrakcia príznakov

Návrh metód extrakcie príznakov založených na metóde MLP (Multilayer Perceptron, viacvrstvový perceptrón) pracujúcej v autoasociačnom móde a na vektorovej kvantizácii, ktorá používa Kohonovu samoorganizujúcu mapu pre účely rozpoznávania tváří.

- Pomocou klasifikačných metód strojového učenia overiť navrhnutý prístup na databáze ľudských tváří.
- Porovnať navrhnuté metódy s priamou klasifikáciou, bez použitia metód extrakcie príznakov.
- Návrh metódy založenej na šumových modifikáciách pre vytvorenie nových syntetických vzoriek pre rozšírenie trénovacej množiny a daný prístup overiť pomocou klasifikačných metód strojového učenia.

3.2 Problém jedinej dostupnej vzorky

Návrh metód založených na rôznych waveletových a šumových modifikáciách obrazov pre vytvorenie nových syntetických vzoriek s cieľom rozšírenia trénovacej množiny.

- Na základe generovaných syntetických vzoriek zvýšiť úspešnosť rozpoznania v prípade problému jedinej vzorky na subjekt.
- Pomocou klasifikačných metód strojového učenia overiť navrhnutý prístup na vybranej databáze ľudských tváří.

3.3 Rozpoznávanie tváří v neriadených podmienkach

Návrh metód pre rozpoznávanie tváří v neriadených podmienkach.

- Navrhnuť metodológiu rozpoznávania pomocou vybraných metód strojového učenia pre prácu v neriadených podmienkach, ktoré sú reprezentované zmenami póz tváří subjektov, zmenami osvetlenia, čiastočnými prekrytiami tváří, šumovými degradáciami obrazu a poškodeniami obrazov pri prenose cez komunikačný kanál.
- Na základe navrhutej metodológie odporučiť vhodné metódy pre použitie v multimodálnom rozhraní.
- Navrhnuť metódy pre rozpoznávanie tváří poškodených pri prenose komunikačným kanálom pre architektúru klient - server bez nutnosti interpolácie poškodených oblastí obrazu z jeho nepoškodených častí (angl. error concealment technique).
- Analyzovať dôležitosť tvárových črt ako sú oči a obočie pre metódy strojového učenia a rozpoznávanie čiastočne prekrytých obrazov tváří.

3.4 Systém rozpoznávání lidských tváří

Návrh softvérové a hardvérové aplikace rozpoznávání tváří pro účely projektu HBB-NEXT, 7 rámcového programu (FP7-ICT-2011-7-287848).

- Návrh aplikace schopné detekovat a rozpoznávat viacero identít v reálnom čase.
- Návrh automatického tréningového procesu aplikácie založenom na výbere vzoriek pomocou zhlukovacieho algoritmu.

4 Vykonané experimenty a výsledky dizertačnej práce

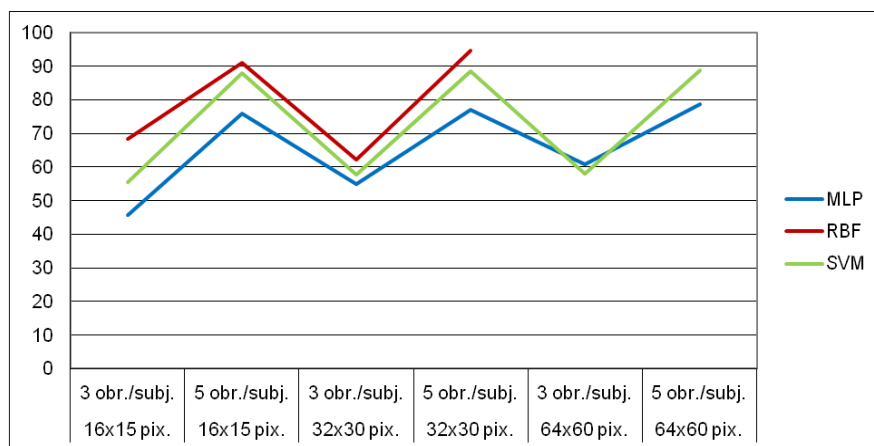
V tejto kapitole popíšeme vybrané výsledky experimentov rozpoznávania tváří v riadených a v neriadených podmienkach. Súčasťou neriadených podmienok je aj rozpoznávanie tváří s jedinou dostupnou tréningovou vzorkou na subjekt. Popíšeme navrhnutý biometrický rozpoznávací systém, ktorý je schopný rozpoznávať viacero identít v reálnom čase a obsahuje automatický tréningový proces.

4.1 Rozpoznávanie tváří v riadených podmienkach

4.1.1 Vplyv veľkosti obrazu a počtu tréningových vzoriek na úspešnosť rozpoznávania vybraných metód

Aj keď sa problematika rozpoznávania tváří na dvojrozmernom obraze v riadených podmienkach v súčasnej odbornej literatúre považuje za vyriešenú, závery z experimentov sú aplikovateľné aj pre rozpoznávacie systémy pracujúce v neriadených podmienkach. Výsledky našich experimentov pre riadené podmienky boli publikované v [A09], [A09a] a [A10].

Pri rozpoznávaní tváří v riadených podmienkach analyzujeme vplyv veľkosti vstupných obrazov na úspešnosť rozpoznania, pričom pre vyhodnotenie tejto úspešnosti používame tri klasifikačné metódy: MLP, RBF a SVM. Metódy sme implementovali do jednostupňových rozpoznávacích systémov. Vybrané výsledky úspešnosti rozpoznania na databáze MIT s rozmerom vstupného obrazu 16x15, 32x30 a 64x60 pixelov sú zobrazené na Obr. 2.




Obr. 2 Úspešnosti rozpoznania ľudskej tváre na databáze MIT s rozmerom vstupného obrazu 16x15, 32x30, 64x60 pixelov. Počet 3 a 5 obrazov na subjekt v tréningovej množine. Metódy MLP, RBF a SVM

Napr. pre metódu SVM bola pri počte 3 obrázky na subjekt v tréningovej množine a rozmere obrazu 16x15 pixelov dosiahnutá približne 55,5% úspešnosť rozpoznania. Pri rozmere 32x30 pixelov je úspešnosť pre rovnakú metódu a rovnaké rozdelenie množín 57,8% a s rozmerom obrazu 64x60 pixelov je úspešnosť 58,1%. Rovnaké závery možno uviesť aj pre iné rozdelenie vstupných dát do tréningovej a testovacej množiny a rovnako aj pre metódy RBF a MLP. Toto dokazuje, že aj výraznejší nárast veľkosti vstupného obrazu neznamená radikálne zlepšenie rozpoznávacej úspešnosti použitých metód.

Ďalší test bol zameraný na vplyv počtu tréningových vzoriek na úspešnosť rozpoznania. Test rozpoznávacej úspešnosti pomocou metódy SVM na databáze CMU PIE pri rôznom počte obrazov na

jeden subjekt v trénovacej množine je znázornený na Obr. 3. Rovnako sú zaznamenávané časové náročnosti tréningu a testu pre vyhodnotenie, či je daná metóda vhodná pre použitie v rozpoznávacom systéme, ktorý má pracovať v reálnom čase. Z uvedených výsledkov môžeme zhodnotiť, že metóda SVM je pri použití 4 až 7 obrazov na subjekt v trénovacej množine vhodná pre aplikácie pracujúce v reálnom čase. Tento výsledok je na základe testov publikovaných v [A09], [A09a] a [A10] aplikovateľný aj pre iné metódy strojového učenia pracujúcich v riadených aj v neriadených podmienkach.

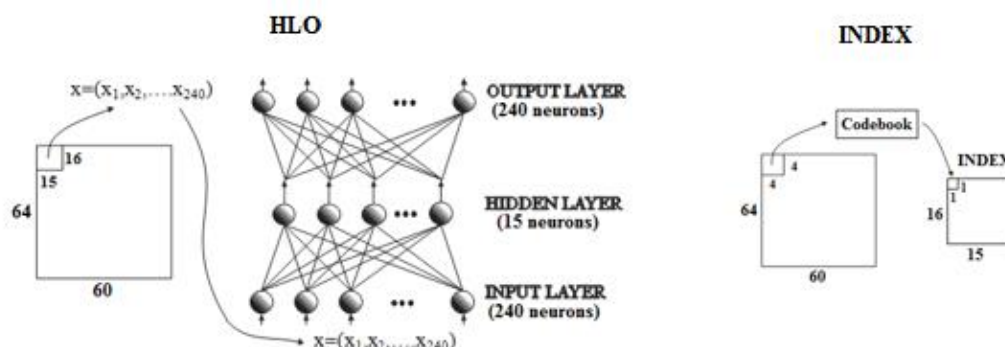


Obr. 3 Rozpoznávací úspešnosť a časová náročnosť tréningu a testu na databáze CMU PIE s rozmerom vstupného obrazu 64x64 pixelov, pre počet 1 až 10 obrazov na subjekt v trénovacej množine pomocou metódy SVM

4.1.2 Návrh metód extrakcie príznakov HLO a INDEX pre rozpoznávanie tváří

Dôležitou súčasťou rozpoznávacích systémov je extrakcia príznakov. Práca [A11a] sa zaoberá problematikou extrakcie príznakov pomocou dvoch navrhnutých metód HLO [Orav07] a INDEX [Orav99] pre rozpoznávanie ľudských tváří. Obe metódy patria medzi lokálne prístupy extrakcie, nakoľko je celý vstupný obraz tváre delený na rovnaké oblasti. HLO (Hidden Layer Outputs, HLO) metóda rozdelí obraz databázy MIT o veľkosti 64x60 pixelov na 16 oblastí. Jednotlivé oblasti predstavujú vstupné dáta MLP siete s topológiou 240-15-240. Vstupné dáta privádzame na vstupnú vrstvu MLP siete. Dáta zo skrytej vrstvy MLP predstavujú výstup HLO metódy. Jednotlivé HLO_MIT obrázky sú následne transformované do matice o rozmere 60x4 pixelov. Schematický náčrt algoritmu HLO je znázornený na Obr. 4.

INDEX je metóda založená na vektorovej kvantizácii (VQ), ktorá používa Kohonenovu samoorganizujúcu mapu (SOM) pre tvorbu kódovej knihy metódy. Originálny obraz je rozdelený na oblasti o rozmere 4x4 pixelov, ktoré sú podľa vytvorenej kódovej knihy prepísané do jedného pixelu INDEX obrazu. Po tejto vektorovej kvantizácii dostávame z pôvodného MIT obrazu o veľkosti 64x60 pixelov INDEX obraz o rozmere 16x15 pixelov. Schematický náčrt algoritmu INDEX je znázornený na Obr. 4.



Obr. 4 Schematický náčrt algoritmov HLO a INDEX

Na obrazoch INDEX_MIT a HLO_MIT je v publikácii [A11a] vykonaných viacero simulácií pomocou klasifikačných metód MLP, RBF a SVM. Na základe porovnania testov na originálnych obrazoch

databázy MIT s testami po redukcii dimenzie vstupných obrazov pomocou metód HLO a INDEX je vyhodnotená úspešnosť navrhnutých metód extrakcie príznakov (Tab. 1).

Tab. 1 Úspešnosti rozpoznania ľudskej tváre na originálnych obrazoch MIT (64x60pixelov) a na obrazoch získaných extrakciou príznakov HLO a INDEX pomocou klasifikačných metód MLP, RBF a SVM

	5 orig. obrazov/subjekt v trénovacej množine		
	MIT 64x60 [%]	HLO [%]	INDEX [%]
SVM	88.92	93.18	84.38
RBF	53.98	86.08	82.10
MLP	78.69	48.86	41.76

Vyššie 4% nárast úspešnosti klasifikácie, v porovnaní s testom na originálnom obraze MIT, dosiahla metóda SVM pri použití HLO extrakcie príznakov. Metóda RBF prekonala testy na originálnych obrazoch pri oboch metódach extrakcie príznakov, a to s približne 30% vyššou úspešnosťou v porovnaní s úspešnosťou 53.98% dosiahnutou na originálnych obrazoch MIT. Z uvedeného môžeme zhodnotiť, že aj napriek 16-násobnej dátovej úspore na jeden obraz pri použití extrakcie príznakov pomocou metód HLO a INDEX a tým spojenej menšej výpočtovej a časovej náročnosti pri procese tréningu a testu použitých klasifikačných metód sa vo viacerých simuláciách, hlavne pri metódach SVM a RBF preukázali extrahované obrazy ako úspešnejšie.

4.2 Rozpoznávanie tvári v neriadených podmienkach

Hlavnou motiváciou výskumu rozpoznávania v takýchto podmienkach je tvorba komerčných identifikačných a verifikačných systémov, ktoré sú schopné pracovať v reálnom čase, v reálnom prostredí a samozrejme dosahovať vysokú rozpoznávaciu úspešnosť. Experimenty uvedené v tejto kapitole a viaceré publikácie [A12], [A12a], [A13c] sú rovnako motivované tvorbou rozpoznávacieho systému schopného identifikovať viacero používateľov, ktorý je vyvíjaný v rámci HBB-NEXT projektu 7. rámcového programu (FP7-ICT-2011-7-287848) [<http://www.hbb-next.eu/index.php>].

4.2.1 Návrh metód rozpoznávania tvári pre multimodálne rozhranie

Publikácia [A12a] sa zaoberá hodnotením rôznych metód pre využitie v multimodálnom rozhraní. Multimodálne rozhranie využíva viacero autentifikačných procesov ako rozpoznávanie na základe reči, rozpoznávanie na základe tváre a pod. pre prihlásenie oprávneného používateľa do systému. Vybrané metódy extrakcie príznakov, ako PCA, KPCA, GDA v kombinácii s Euklidovou metrikou a klasifikačné metódy SVM a RBF sú testované na databáze CMU PIE. Cieľom je vyhodnotiť úspešnosť jednotlivých metód v neriadených podmienkach v závislosti na výpočtovej náročnosti metód a tým určiť vhodnú metódu pre multimodálne rozhranie systému pracujúceho v reálnom čase. Úspešnosti rozpoznania ľudskej tváre sú znázornené v Tab. 2 a meranie časovej náročnosti je zobrazené v Tab. 3.

Tab. 2 Úspešnosti rozpoznania ľudskej tváre na obrazoch databázy CMU PIE (64x64 pixelov) pre rôzne natočenia tváre v obraze (C29, C9, C27, C7 a C5). Metódy PCA, KPCA, GDA, SVM a RBF (označenie *_HistEq* je použité pre výsledky na obrazoch CMU PIE s aplikáciou úplného priespracovania (histogramová ekvalizácia))

Metóda\Póza tváre	C29 [%]	C9 [%]	C27 [%]	C7 [%]	C5 [%]
PCA_HistEq	67.26	67.30	63.61	65.80	68.29
KPCA_HistEq	67.29	67.40	63.07	66.37	67.46
GDA_HistEq	86.41	88.20	88.13	90.64	87.79
SVM_HistEq	87.88	90.11	89.90	91.06	90.34
RBF_HistEq	91.01	92.88	93.25	93.10	91.96
PCA	49.60	48.05	41.05	46.81	43.97
KPCA	49.88	48.13	41.09	46.78	44.17
GDA	81.84	82.26	78.89	82.13	79.53
SVM	79.63	80.91	78.54	80.94	79.29
RBF	85.63	85.71	84.45	86.38	81.90

Tab. 3 Časová náročnosť tréningu a testu na databáze CMU PIE s rozmerom vstupného obrazu 64x64 pixelov, pre metódy PCA, KPCA, GDA, SVM a RBF

Metóda	Trénovací čas [s]	Testovací čas [s]
PCA	62,92	4,54
KPCA	0,92	6,6
GDA	1,01	5,82
SVM	48,21	5,81
RBF	418,48	33,72

Pre frontálnu pózu tváre C27 je najúspešnejšou metóda RBF, ktorá dosiahla úspešnosť 93,25%, nasledovaná je metódou SVM (89,9%) a metódou GDA (88,13%). Rovnako vysokú úspešnosť dosahujú tieto metódy aj pri ostatných pózach tváre, čo dokazuje, že sú vhodné pre rozpoznávanie v neriadených podmienkach a dokážu eliminovať meniace sa osvetlenie, výraz a pózu tváre. Naopak metódy extrakcie PCA a KPCA dosiahli len približne 63% úspešnosť rozpoznania. Metódy SVM a GDA, ktoré v teste úspešnosti zaostávali za metódou RBF približne o 4% a 5%, dosiahli testovací čas približne 5,8s. Na základe uvedeného môžeme zhodnotiť, že metódy SVM a GDA najlepšie spĺňajú požiadavky pre využitie v multimodálnom rozhraní, ktoré má pracovať v neriadených podmienkach a v reálnom čase.

4.2.2 Návrh metód pre rozpoznávanie tvárí poškodených pri prenose komunikačným kanálom

S problematikou rozpoznávania tvárí na snímkach, ktoré sú poškodené prenosom cez komunikačný kanál sa zaoberá publikácia [A12]. V tejto publikácii simulujeme chyby pri prenose komunikačným kanálom rôznymi blokovými poškodeniami obrazov tváre. Nevyužívame techniky syntetickej interpolácie poškodených častí, ale navrhujeme priamo rozpoznávať poškodené obrazy tvárí novými metódami strojového učenia. Chyby na obraze vzniknuté pri prenose komunikačným kanálom boli simulované pomocou náhodne generovaných chýbajúcich blokov. Pre možnosť vyhodnotenia, či sú vybrané metódy schopné dosahovať prijateľnú rozpoznávaciu úspešnosť aj bez použitia EC (Error Concealment), techník boli vykonané testy rozpoznávacích metód na obrazoch nazvaných *Obrazy poškodené blokmi (priemerná intenzita)* a *Obrazy poškodené blokmi (intenzita 0)*. Pre možnosť porovnania s bezchybným prenosom boli vykonané testy aj na nepoškodených (originálnych) obrazoch s názvom *Originál FERET* (rovnaké označenie je použité v tabuľke dosiahnutých úspešností Tab. 4).

Tab. 4 Úspešnosti rozpoznania ľudskej tváre pre 1 až 4 obrazy na subjekt v trénovacej množine. Testy na originálnych obrazoch databázy FERET (75x65 pixelov), umelo poškodených obrazoch s blokmi, ktorých intenzita jasu je určená ako priemerná hodnota intenzity každého obrazu a umelo poškodených obrazoch s blokmi s nulovou intenzitou. Metódy PCA, KPCA, SVM a RBF

Použité obrazy	Počet obrazov/subj. v trénovacej množ.	RBF	SVM	PCA	KPCA
Originál FERET	1 obr./subj.	68,61062	79,6455	73,0703	73,4992
	2 obr./subj.	87,98404	90,8184	82,6014	82,6028
	3 obr./subj.	94,55846	94,8687	87,7486	86,5951
	4 obr./subj.	97,03262	96,2908	90,4056	90,7517
Obrazy poškodené blokmi (priemerná intenzita)	1 obr./subj.	50,3602	79,3825	72,6528	72,1096
	2 obr./subj.	70,5389	90,3825	82,4351	81,4371
	3 obr./subj.	87,0167	92,8878	86,6826	85,9666
	4 obr./subj.	96,6765	95,7896	90,089	89,911
Obrazy poškodené blokmi (intenzita 0)	1 obr./subj.	35,163	76,5009	72,7379	73,013
	2 obr./subj.	69,6208	88,9422	82,169	80,6054
	3 obr./subj.	73,8425	93,031	87,152	86,5553
	4 obr./subj.	81,1276	95,905	89,7626	89,1197

Porovnajme výsledky na originálnych obrazoch s testami na obrazoch, ktoré boli poškodené chýbajúcimi blokmi. RBF metóda dosiahla 0,36% pokles úspešnosti pri teste na obrazoch, ktoré sú poškodené blokmi s priemernou intenzitou jasu (z 97,03262% na 96,6765%), ale až takmer 16% pokles (z 97,03262% na 81,1276%) pri teste na obrazoch, ktoré sú poškodené blokmi s nulovou intenzitou jasu. Naopak metódy PCA, KPCA a SVM dosahujú približne 1% rozdiely úspešnosti rozpoznania medzi testami na

originálnych a poškodených obrazoch FERET. Toto dokazuje ich schopnosť rozpoznávať obrazy tváří aj pri blokmi poškodených obrazoch, bez akejkol'vek rekonštrukcie poškodených častí.

4.2.3 Návrh metód pre rozpoznávanie tváří čiastočne prekrytých a zašumených obrazov

Ďalšia oblasť rozpoznávania tváří v neriadených podmienkach sa zameriava na čiastočne zakryté a zašumené ľudské tváre v obraze. V experimentoch publikovaných v práci [A13c] prekryvame informačne dôležité oblasti tváre ako oči, alebo ústa. Rovnako degradujeme obrazy tváre pomocou pridania umelého šumu čím simulujeme chyby ktoré môžu vzniknúť pri snímaní, kompresii, alebo prenose obrazov. Snažíme sa poukázať na schopnosť metód strojového učenia (metódy PCA, RBF a nové kernelové metódy KPCA, GDA a SVM.) úspešne rozpoznávať identitu aj pri takto poškodených obrazoch. Na obrazoch z databázy FERET s predspracovaním typu BIGface sme prekrytia simulovali pomocou čiernych blokov. Použili sme päť rôznych prekrytí: oči (prekrytie ~ 6%), obočie (prekrytie ~ 6%), ústa (prekrytie ~ 11%), oči& nos (prekrytie ~ 9%), okuliare (prekrytie ~ 15.5%). Degradáciu šumom sme simulovali pridaním troch typov šumov s konštantnou intenzitou 0,05: Gaussov šum, salt&pepper šum, speckle šum. Súčasťou návrhu vhodných metód pre rozpoznávanie tváří čiastočne prekrytých a zašumených obrazov bol aj experiment, ktorý hodnotil dôležitosť očí alebo obočia pre metódy strojového učenia. Hlavnou motiváciou tohto výskumu bola publikácia [Sadr03], kde autori popísali experiment o dôležitosti očí alebo obočia pre ľudské vnímanie. Prekvapivo viac respondentov správne určilo identitu známej osobnosti keď na obraze tváre boli umelo odstránené oči. Toto dokazuje, že pre ľudské vnímanie je dôležitejšia tvárová čiara obočia.

Výsledky dosiahnuté na obrazoch, ktoré boli degradované šumom preukázali schopnosť niektorých metód spoľahlivo eliminovať takéto poškodenie. Približne rovnaké výsledky dosiahli metódy PCA a jej kernelové rozšírenie KPCA. V porovnaní s testami na originálnych (nemodifikovaných) obrazoch je rozdiel v dosiahnutej úspešnosti minimálny a v niektorých testoch dokonca pridanie šumu (Gaussov šum, alebo salt&pepper šum) do obrazu zvýšilo rozpoznávaciu úspešnosť. Je zrejmé, že s narastajúcou intenzitou šumu v obraze by úspešnosť rozpoznania klesala. Kernelové metódy SVM a GDA rovnako dobre eliminovali prítomnosť šumu v obraze t.j. v porovnaní s testami na originálnych (nemodifikovaných) obrazoch je rozdiel v dosiahnutej úspešnosti minimálny. Rovnako nastali aj prípady s dosiahnutou vyššou úspešnosťou pri modifikovaných obrazoch ako pri originálnych obrazoch. Metóda SVM dosiahla spomedzi všetkých metód najvyššiu úspešnosť rozpoznania práve pri šumom modifikovaných obrazoch.

Experimenty na čiastočne prekrytých obrazoch dokázali, že prekrytie očí na ľudskej tvári nespôsobilo žiadny výrazný pokles rozpoznávacej úspešnosti metód. Najnižší rozdiel medzi testom na originálnom obraze a testom s obrazmi "prekryté oči" dosiahla metóda KPCA s poklesom iba 0,24% v porovnaní s úspešnosťou 91,22% dosiahnutej na originálnych obrazoch. Všetky použité metódy strojového učenia (PCA, RBF, KPCA, GDA a SVM) dosiahli v testoch úspešnosti rozpoznania na obrazoch tváří s prekrytým obočím horší výsledok ako pri testoch úspešnosti na obrazoch s prekrytými očami. Vybrané výsledky úspešnosti pre testy s čiastočnými prekrytiami očí a obočí sú sumarizované v Tab. 5. Berme na vedomie, že blok ktorý umelo prekryval oči, alebo obočie bol v oboch prípadoch rovnakého rozmeru aj intenzity (blok s nulovou intenzitou prekryva približne 6% celkovej plochy obrazu tvár). Z uvedeného môžeme zhodnotiť, že rovnako ako pre ľudské vnímanie (experiment popísaný v publikácii [Sadr03]) aj pre metódy strojového učenia je dôležitejšia tvárová čiara obočia.

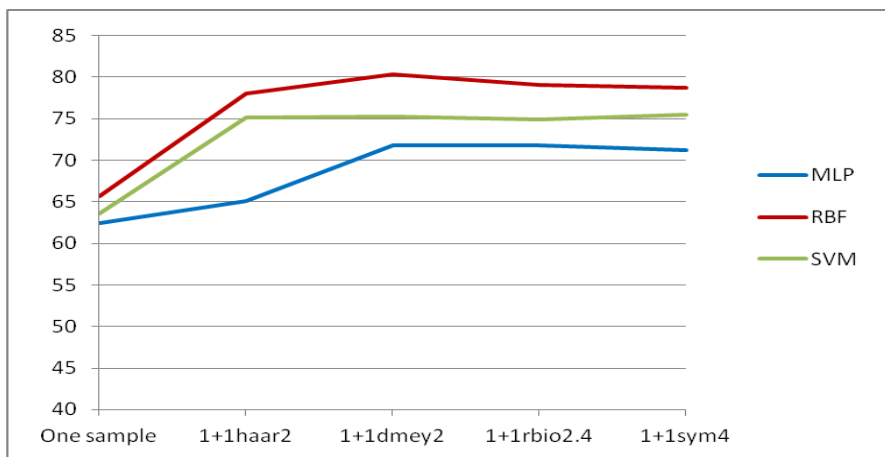
Tab. 5 Vybrané úspešnosti rozpoznania ľudskej tváre pre 4 obrazy na subjekt v tréningovej množine. Testy na originálnych obrazoch databázy FERET (bez prekrytia) a rôzne čiastočne prekrytých obrazoch. Metódy PCA, KPCA, GDA, SVM a RBF

Prekrytie obrazu\Metóda	PCA	KPCA	GDA	RBF	SVM
Bez prekrytia (originál)	90.41	91.22	94.72	97.03	96.29
Oči	90.06	90.98	92.88	93.47	94.90
Obočie	89.20	89.20	89.91	84.93	93.83
Oči&nos	88.96	88.96	83.98	59.41	91.93
Ústa	83.80	83.80	84.15	59.05	88.90
Okuliare	77.63	77.63	80.00	53.41	81.55

Môžeme zhodnotiť, že metóda založená na neurónovej sieti RBF dosiahla pre originálne (nemodifikované) obrazy tváří najvyššiu rozpoznávaciu úspešnosť 97,03%, ale preukázala výrazný pokles v prípade šumových modifikácií a rovnako v prípade všetkých čiastočných prekrytí obrazov tváří. Ako stabilnú metódu pre rozpoznávanie tváří čiastočne prekrytých a zašumených obrazov sme navrhli metódu SVM.

4.2.4 Rozpoznávanie tváří pre jedinú vzorku v trénovacej množine

V tejto kapitole sa budeme venovať návrhu metód pre tvorbu syntetických (umelých) vzoriek z pôvodnej jedinej dostupnej vzorky. Cieľom je rozšíriť trénovaciu množinu o tieto nové syntetické vzorky a zvýšiť rozpoznávaciu úspešnosť klasifikačných metód. V knižnej kapitole [A11] a v publikácii [A11b] navrhujeme viacero spôsobov ako modifikovať jedinú dostupnú obraz a generovať syntetickú vzorku pre rozšírenie trénovacej množiny. V oboch sme navrhli viaceré modifikácie založené na Gaussovom šume, mean filtrácii a waveletových transformáciách. Pomocou klasifikačných metód neurónových sietí MLP a RBF a metódou SVM sledujeme úspešnosť rozpoznania pri zmene parametrov jednotlivých modifikácií s cieľom navrhnúť optimálny algoritmus pre tvorbu nových syntetických vzoriek. V prípade Gaussovho šumu nastavujeme jeho intenzitu, v prípade mean filtra nastavujeme veľkosť filtračného okna a v prípade waveletovej transformácie meníme typ waveletu a modifikujeme koeficienty vo frekvenčnom spektre. Vybrané výsledky pre rozšírenie trénovacej množiny o waveletom modifikované vzorky môžeme vidieť na Obr. 5. Výsledky experimentov s metódami RBF, SVM a MLP a s rozšírenými trénovacími množinami o syntetické vzorky prekonalí úspešnosti dosiahnuté na originálnej jedinej vzorke. Z Obr. 5 je ďalej vidieť, že rozšírenie o syntetické vzorky vytvorené waveletovou transformáciou prinieslo ustálené výsledky pre všetky použité metódy.



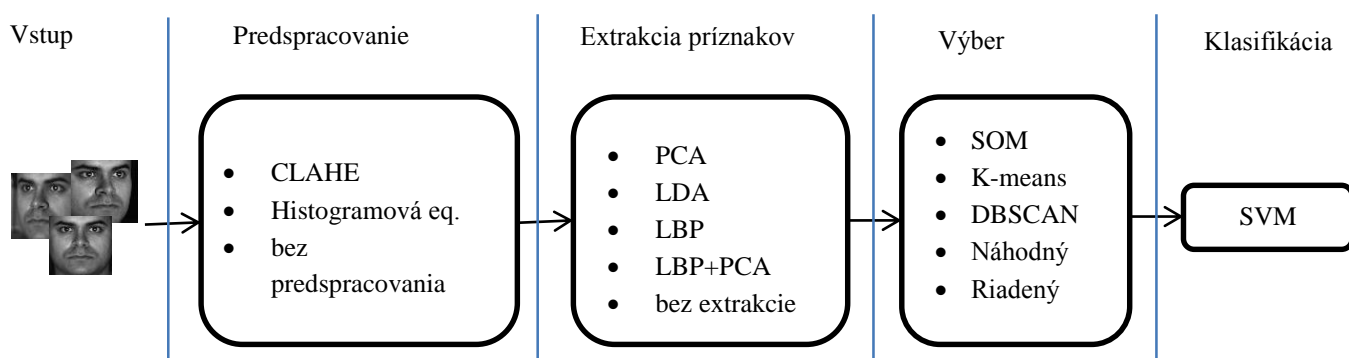
Obr. 5 Porovnanie výsledkov testu rozpoznania tváre pri jedinej dostupnej trénovacej vzorke a pri rozšírení trénovacej množiny o waveletom modifikované obrazy s použitím rôznych typov waveletových funkcií. Metódy RBF, MLP a SVM

V práci [A11] sme navrhli aj ďalšie modifikácie jediného dostupného obrazu a vykonali viacero experimentov s cieľom zistiť, či rozšírenie trénovacej množiny o viac ako jednu syntetickú vzorku má výrazne pozitívny vplyv na úspešnosť rozpoznania, alebo sme hodnotili informačnú hodnotu novej syntetickej vzorky v porovnaní s originálnou vzorkou.

Na základe experimentov sme vyvodili závery, že pridávanie viac ako 2 syntetických vzoriek nemá výraznejší vplyv na úspešnosť rozpoznania jednotlivých metód a v prípade dostupnosti viacerých originálnych obrazov je ich informačná hodnota pre metódy strojového učenia vyššia ako informačná hodnota umelo vytvorených vzoriek. Testované metódy RBF, MLP a SVM preukázali schopnosť pracovať s umelo rozšírenými trénovacími množinami. Najvyššiu rozpoznávaciu úspešnosť dosahovali metódy RBF a SVM.

4.3 Automatický výber tréningových vzoriek pomocou zhlukovacích algoritmov

Automatické rozpoznávanie, alebo tiež automatický rozpoznávací systém nevyžaduje od používateľa systému akúkoľvek selekciu (výber), alebo úpravu vstupných obrazov tváre pri záznamovom procese. Algoritmom vybrané obrazy reprezentujú rôzne pózy tváre, výrazy tváre subjektu a pod. V publikáciách [A13d], [A14], [A14a], [A14b] sa venujeme návrhu metód pre automatický tréningový proces rozpoznávacieho systému. Navrhujeme metódy pre predspracovanie zosnímaných obrazov, následnú redukciu ich dimenzie pomocou metód extrakcie príznakov a automatický výber reprezentatívnych obrazov pomocou zhlukovacích algoritmov. Následne vyhodnocujeme úspešnosti rozpoznania navrhnutých postupov s klasifikačnou metódou SVM. Simulačná schéma je zobrazená na Obr. 6.



Obr. 6 Simulačná schéma systému automatického výberu tréningových vzoriek

Vstupné obrazy CMU PIE sú snímané v 43 rôznych svetelných podmienkach a preto je vhodné použiť techniky úpravy kontrastu obrazu. Použili sme histogramovú ekvalizáciu a adaptívnu histogramovú ekvalizáciu tzv. CLAHE (Contrast Limited Adaptive Histogram Equalization). Pre extrakciu príznakov sme vybrali metódy PCA, LDA, LBP a kombináciu LBP+PCA. Zhlukovacie algoritmy SOM, K-means a DBSCAN sme porovnali s náhodným a riadeným výberom. Náhodný výber predstavuje náhodnú selekciu 6 obrazov z celkového počtu 97 vstupných obrazov bez žiadnej kontroly. Riadený výber čiastočne simuluje ľudský výber vhodných vzoriek. Výsledky klasifikácie metódy SVM sú zobrazené v Tab. 6.

Tab. 6 Výsledky klasifikácie pomocou metódy SVM. Výber 6 obrazov zo 68 subjektov databázy CMU PIE s použitím zhlukovacích algoritmov SOM, K-means a DBSCAN, náhodného a riadeného výberu. Šedo zvýraznené výsledky predstavujú najlepší výsledok pre danú metódu výberu tréningových obrazov

Extrakcia príznakov	Predspracovanie	Výber				
		SOM	K-means	DBSCAN	Náhodný	Riadený
Originál (bez extrakcie príznakov)	CLAHE	92.71	93.76	87.99	81.45	86.65
	Hist. eq.	90.51	90.92	91.72	81.30	86.07
	bez predspracovania	78.47	79.91	81.80	69.67	73.50
PCA	CLAHE	92.84	91.69	86.43	81.40	86.59
	Hist. eq.	90.21	91.01	91.37	81.24	86.01
	bez predspracovania	77.89	80.16	79.12	69.33	73.29
LDA	CLAHE	77.39	77.02	73.67	61.47	68.63
	Hist. eq.	72.35	76.21	71.05	61.88	69.17
	bez predspracovania	68.97	68.50	65.99	54.99	60.02
LBP	CLAHE	88.56	88.33	83.05	75.16	81.00
	Hist. eq.	89.48	89.84	83.38	77.84	81.17
	bez predspracovania	89.79	89.90	84.48	77.63	81.17
LBP+PCA	CLAHE	93.70	93.33	88.42	84.70	90.66
	Hist. eq.	93.65	93.50	87.76	85.23	89.24
	bez predspracovania	94.47	93.20	87.67	85.31	89.37

Na základe uvedených výsledkov môžeme uviesť viacero záverov. Z pohľadu metód predspracovania a extrakcie príznakov je vhodné použiť CLAHE predspracovanie v kombinácii s klasickými metódami extrakcie príznakov PCA a LDA, alebo aj pri priamej klasifikácii bez použitia extrakcie príznakov. Klasifikácia po extrakcii príznakov metódou LBP alebo po kaskádovom prístupe s použitím LBP+PCA dosiahla najlepšie výsledky úspešnosti rozpoznania bez predspracovania vstupných obrazov. T.j. vďaka odolnosti metódy LBP voči zmenám osvetlenia je samotné použitie metódy LBP, alebo LBP+PCA účinnejšie (aj keď sa dá polemizovať o nutnosti použitia histogramovej ekvalizácie pri výrazne tmavých, alebo svetlých obrazoch tváre). Z pohľadu metód výberu tréningových obrazov je zrejmé, že algoritmy SOM, K-means a DBSCAN sú účinnejšie pri výbere vhodných obrazov pre klasifikáciu ako náhodný a dokonca aj čiastočne riadený výber (obsahuje obrazy každej tvárovej pózy). Algoritmy SOM a K-means potvrdili, že sú vhodnejšie pre použitie ako algoritmus DBSCAN (najvyššie hodnoty úspešnosti rozpoznania: SOM – 94,47%; K-means – 93,76%; DBSCAN – 91,72%). Z pohľadu univerzálnosti automatického systému sme ako vhodnú kombináciu metódy extrakcie príznakov a metódy pre automatický výber tréningových vzoriek navrhli algoritmus LBP+PCA a zhlukovací algoritmus K-means. Zhlukovací algoritmus SOM nebol odporúčaný z dôvodu nutnosti nastavovania viacerých parametrov pri inicializácii tréningu samoorganizujúcej mapy.

4.4 Biometrický rozpoznávací systém na základe ľudskej tváre


Podstatná časť dizertačnej práce bola motivovaná prácou na projekte HBB-NEXT. Projekt 7. rámcového programu (FP7-ICT-2011-7-287848) HBB-NEXT (Hybrid Broadcast Broadband Next Generation) [<http://www.hbb-next.eu/index.php>] sa zaoberá problematikou inteligentnej televízie HBB TV. V tejto kapitole sa budeme venovať návrhu a realizácii softvérovej a hardvérovej aplikácie rozpoznávania tváří ako časti multimodálneho rozhrania vytvorenej pre účely projektu.

Navrhnutý a implementovaný systém pracuje v dvoch základných módoch. Prvý je tréningový mód, ktorý slúži na riadený záznamový proces obrazov tváří, automatický výber reprezentatívnych tréningových obrazov a tréning (učenie) klasifikačného algoritmu SVM. Druhý je rozpoznávací mód, ktorý zahŕňa samotnú identifikáciu používateľov, temporálne filtrovanie (filtrácia chybných detekcií alebo sledovania tváre) a výstupný blok, ktorý zobrazuje výsledok rozpoznania na obrazovke a posiela informáciu o identite používateľa HBB-NEXT aplikáciám. V nasledujúcom texte popíšeme základné princípy a funkcionality jednotlivých módov systému z pohľadu grafického používateľského rozhrania a aj z pohľadu použitých algoritmov.

Tréningový mód

Architektúru môžeme rozdeliť na jednotlivé funkčné bloky.

- Vstupný blok.
 - Zadanie identity používateľa.
 - Snímanie 2D RGB obrazu a 3D hĺbkového obrazu používateľa.
 - Výstupom bloku je zosnímaný 2D a 3D obraz a identita snímaného používateľa.
- Lokalizácia tváre používateľa.
 - S použitím *Kinect Toolkit Face Detector*, ktorý je súčasťou Windows Developer Toolkit [<http://www.microsoft.com/en-us/download/details.aspx?id=29865>] a 3D infračervenou hĺbkovou kamerou prebieha lokalizácia tváre v obraze.
 - Uloženie koordinátov tváre na obraze na základe lokalizácie.
 - Navrhnutý rozpoznávací systém dokáže pracovať aj bez zariadenia Kinect. V takom prípade používa pre lokalizáciu tváre *OpenCV Cascade detector* [<http://opencv.org/>], ktorý je vhodný na použitie s bežnými kamerami.
 - Výstupom bloku je 2D obraz, koordináty tváre na obraze a identita používateľa.
- Predspracovanie (Obr. 7).
 - Prevod RGB vstupného obrazu na šedotónový.
 - Vyrezanie obrazu tváre na základe koordinátov a prispôbenie rozmeru obrazu.
 - Histogramová ekvalizácia.



Obr. 7 Príklady zosnímaných obrazov tvári pomocou zariadenia Kinect, po lokalizácii, úprave rozmeru a histogramovej ekvalizácii

- Výstupom bloku je predspracovaný obraz tváre a identita používateľa.
- Extrakcia príznakov LBP.
 - Výstupom bloku je LBP vzorka a identita používateľa.

Popísané procesy pracujú v cykle podľa riadeného snímania. Riadené snímanie naviguje prostredníctvom grafického rozhrania používateľa a sníma jeho tvár z rôznych uhlov. Výstupom cyklu je 250 LBP vzoriek a identita používateľa.

- Automatický výber tréningových vzoriek.
 - Výber 6 reprezentatívnych tréningových vzoriek (z 250 uložených vzoriek) pomocou zhlukovacieho algoritmu K-means.
 - Výstupom bloku je 6 reprezentatívnych tréningových vzoriek a identita používateľa.
- Tréning klasifikátora SVM.
 - Vstup klasifikátora predstavujú vzorky všetkých používateľov systému, t.j. 6 vzoriek aktuálne snímaného používateľa a aj vzorky ostatných používateľov, ktoré sú uložené v databáze systému.
 - Výstupom bloku je množina podporných vektorov, ktoré definujú hranice medzi vzorkami jednotlivých používateľov. Na základe ktorých je možná neskoršia klasifikácia nových vstupných vzoriek v rozpoznávacom móde systému.

Rozpoznávací mód

Po natrénovaní rozpoznávacieho systému môžeme pracovať v rozpoznávacom móde, ktorý vykonáva samotnú identifikáciu používateľov HBB-NEXT aplikácií. Podobne ako pri tréningovom móde môžeme architektúru rozdeliť na jednotlivé funkčné bloky. Architektúra je veľmi podobná. Zásadný rozdiel je v neznámej identite snímaných používateľov na vstupe systému. Aktuálna verzia rozpoznávacieho systému dokáže identifikovať dvoch používateľov súčasne (Obr. 8), pričom vie detekovať aj neznámeho používateľa (používateľ, ktorý nie je v databáze systému – nepodrobil sa tréningovému procesu).



Obr. 8 Ukážka výstupu na obrazovku identifikácie jedného a dvoch používateľov automatického rozpoznávacieho systému

5 Splnenie cieľov dizertačnej práce

Pomocou vybraných klasifikačných metód strojového učenia MLP, RBF a SVM a databázy MIT sme overili navrhnutý prístup rozpoznávania tváří s použitím nových metód extrakcie príznakov HLO a INDEX. Metóda RBF prekonala testy na originálnych obrazoch pri oboch navrhnutých metódach extrakcie príznakov s približne 30% vyššou úspešnosťou v porovnaní s úspešnosťou dosiahnutou na originálnych obrazoch MIT. Ďalej sme navrhli metódu založenú na modifikácii Gaussovým šumom pre vytvorenie nových syntetických vzoriek z dostupných HLO a INDEX príznakov. Rozšírenie trénovacej množiny o takéto syntetické vzorky prinieslo v prípade klasifikačnej metódy SVM približne 5% nárast úspešnosti klasifikácie v kombinácii s metódou HLO a dokonca vyše 8% nárast úspešnosti klasifikácie v kombinácii s metódou INDEX v porovnaní s dosiahnutou úspešnosťou pomocou priamej klasifikácie. Výsledky experimentov boli publikované v publikácii [A11a].

V knižnej kapitole [A11] a v publikácii [A11b] navrhujeme viaceré modifikácie pre vytvorenie nových syntetických vzoriek založené na Gaussovom šume, mean filtrácii a waveletových transformáciách. Metóda RBF siete dosiahla pri rozšírení o syntetické vzorky vytvorené pomocou Gaussovho šumu až 15% nárast úspešnosti identifikácie. Rozšírenie o syntetické obrazy, ktoré boli vytvorené pomocou waveletovej transformácie bolo z pohľadu rozpoznávacej úspešnosti ustálené výsledky pre všetky použité metódy. Metóda RBF zaznamenala nárast úspešnosti v porovnaní s "One sample" testom približne o 14,6%, metóda SVM približne o 11,8% a metóda MLP približne o 9,3%.

S cieľom navrhnuť metodológiu rozpoznávania tváří v neriadených podmienkach sme hodnotili vybrané metódy strojového učenia. Na základe testov rozpoznania a meraní časovej náročnosti sme navrhli metódy SVM a GDA pre využitie v multimodálnom rozhraní z dôvodu naplnenia požiadaviek pre prácu v neriadených podmienkach a v reálnom čase. Pre architektúru klient - server sme navrhli metódy SVM a KPCA, ako vhodných kandidátov pre použitie v rozpoznávacích systémoch, ktoré majú pracovať v reálnom čase a sú odolné aj voči možným chybám na obraze spôsobené prenosom cez komunikačný kanál. Metóda SVM je vhodná aj v prípade rozpoznávania čiastočne prekrytých obrazoch tváří a preukázala vysokú odolnosť voči miernemu šumu v obraze. Navrhnuté metódy dosahovali vyše 90% hodnoty úspešnosti rozpoznania. Ďalej sme na základe experimentov uviedli, že rovnako ako pre ľudské vnímanie (experiment popísaný v publikácii [Sadr03]) je aj pre metódy strojového učenia dôležitejšia tvárová črta obočie. Uvedené výsledky boli publikované v [A12], [A12a] a [A13c].

Pre účely projektu HBB-NEXT, 7. rámcového programu (FP7-ICT-2011-7-287848) sme navrhli a zrealizovali softvérovú a hardvérovú aplikáciu rozpoznávania tváří. Navrhli a zrealizovali sme systém schopný detekovať a rozpoznávať viacero identít v reálnom čase, ktorý obsahuje lokalizáciu tváří v obraze, predpracovanie obrazu tváre, extrakciu príznakov, automatický trénovací proces založený na zhlukovacom algoritme, klasifikátor a výstupný modul, ktorý filtruje najčastejšie typy zlyhania systému a poskytuje výsledky rozpoznania ďalším HBB-NEXT aplikáciám. Rozpoznávací systém pracuje v neriadených podmienkach. Je schopný rozpoznávať aj nie frontálne tváre. Systém je odolný proti chybnéj správnej identifikácii neoprávneného používateľa, ktorý disponuje 2D obrazom tváre oprávneného používateľa, čo je z pohľadu bezpečnosti dôležitá vlastnosť. Počas tvorby systému boli jeho časti bližšie popísané vo viacerých publikáciách [A13d], [A14], [A14a], [A14b].

6 Sumarizácia publikovaných prínosov a ďalšie možné smery výskumu

Pomocou implementácie rôznych klasifikačných metód sme optimalizovali počet a veľkosť vstupných vzoriek pre úspešnú klasifikáciu pri riadených podmienkach. Tieto poznatky boli využité aj v ďalšej práci. V publikácii [A11a] sa zaoberáme problematikou extrakcie príznakov pomocou dvoch navrhnutých metód HLO a INDEX pre účely rozpoznávania ľudských tváří. Pri porovnávacích testoch úspešnosti rozpoznania medzi priamou klasifikáciou (bez použitia extrakcie) a klasifikáciou po extrakcii príznakov sa vo viacerých simuláciách metód SVM a RBF preukázali extrahované obrazy HLO a INDEX

ako úspešnejšie. Navrhnutý prístup extrakcie je využiteľný pre rôzne iné biometriky ako dúhovka, odtlačok prsta a pod. Nakoľko sú metódy schopné spätne rekonštruovať extrahované príznaky na pôvodný obraz, zaujímavým smerom výskumu môže byť aplikácia metód HLO a INDEX na problematiku kompresie, prenosu dát a následnej rekonštrukcie dát. Stupeň kompresie výstupných obrazov bol pri našich experimentoch 16-násobný. Ďalšou úlohou je overiť možnosť vyššieho stupňa kompresie, čo by umožnilo použiť nižšiu šírku pásma pri prenose dát, alebo rýchlejší proces klasifikácie napr. pri rozpoznávaní tváří.

V experimentálnej časti, ktorá sa venuje rozpoznávaniu tváří v neriadených podmienkach sme navrhli klasifikačnú metódu SVM a metódy extrakcie KPCA a GDA, ako metódy ktoré spĺňajú požiadavky pre spoľahlivé rozpoznávanie tváří v neriadených podmienkach a v reálnom čase. Tieto metódy dosahovali vyše 90% hodnoty úspešnosti rozpoznania. Možnými smermi ďalšieho výskumu sú overenie spoľahlivosti navrhnutých metód pre multimodálne rozhranie aj pri použití inej vstupnej biometriky napr. odtlačku prsta, alebo dúhovky. Zaujímavá aplikácia rozpoznávania tváří s architektúrou klient - server má v súčasnosti uplatnenie hlavne pre rozvíjajúce sa server (cloud) riešenia. Víziou je autentifikácia používateľa domáceho zariadenia (napr. smart TV) na základe údajov, ktoré sú uložené na serveri, čím sa umožňuje autentifikácia a následné prihlásenie používateľa k svojmu účtu z akéhokoľvek zariadenia, ktoré komunikuje so serverom.

Zaujímavým experimentom pri návrhu metód pre rozpoznávanie tváří čiastočne prekrytých a zašumených obrazov bol test dôležitosti tvárových črt oči a obočie pre metódy strojového učenia. V našich testoch sme potvrdili, že pre metódy strojového učenia je dôležitejšia tvárová črta obočie. Overenie dôležitosti iných tvárových črt pre strojové učenie by mohlo viesť k návrhu novej lokálnej metódy, ktorá by bola zameraná na selekciu dôležitých tvárových črt.

Samostatná časť patriaca do problematiky neriadených podmienok je rozpoznávanie tváří pre jedinú vzorku v trénovacej množine. S cieľom rozšírenia trénovacej množiny pre zvýšenie rozpoznávacej úspešnosti klasifikačných metód sme navrhli viacero metód pre tvorbu syntetických (umelých) vzoriek z pôvodnej jedinej dostupnej vzorky. Navrhnuté syntetické vzorky vo väčšine prípadov výrazne zvýšili rozpoznávaciu úspešnosť klasifikačných metód. Ďalšími možnosťami ako vytvoriť novú syntetickú vzorku z jedinej originálnej je zmena parametrov Gaussovho šumu, mean filtra, iné nastavenie horizontálnych, diagonálnych a vertikálnych detailov vo frekvenčnom spektre v prípade waveletových transformácií, alebo použitie širokej škály iných filtrov a transformácií.

Navrhnutý automatický rozpoznávací systém je popísaný v poslednej kapitole experimentálnej časti dizertačnej práce. Možnými smermi výskumu v tejto oblasti sú generovanie nových vzoriek z vytvorených centier po aplikácii zhlukovacieho algoritmu, alebo experimentálne otestovať iné typy zhlukovacích algoritmov pre výber reprezentatívnych vzoriek v automatickom trénovacom procese. Ďalšie úlohy, ktoré vyplynuli pri tvorbe systému sú spoľahlivé rozpoznávanie väčšieho počtu používateľov súčasne, možnosť presunúť proces rozpoznávania na vzdialený server a tým odľahčiť nutnosť potrebného hardvérového vybavenia na strane používateľa, alebo prepracovanejší filtračný modul na výstupe systému (ktorý ošetruje ďalšie možné zlyhania rozpoznávacieho systému).

7 Vedecký projekt autora

Projekt NerBioT (Neriadené podmienky a biometrické rozpoznávanie ľudskej tváre). Projekt v rámci Programu na podporu mladých výskumníkov. Zadávatel' projektu: STU BA. Termín riešenia projektu: Január 2013 – Január 2014. Vedúci projektu: M. Féder

8 Účasť autora v projektoch

E-Talent - Grantový program podpory výskumnej činnosti v odbore aplikovanej a priemyselnej informatiky. Projekt BioDaT (Biometrické rozpoznávanie na základe obrazov dúhovky a tváre) 2013. Vedúci projektu: M. Oravec

VEGA 1/0529/13 Návrh pokročilých metód biometrického rozpoznávania na základe obrazov tváre a dúhovky. Vedúci projektu: M. Oravec

HBB-NEXT, Next-Generation Hybrid Broadcast Broadband, project of 7th Frame Program FP7-ICT-2011-7-287848. Koordinátor projektu: Rundfunk Berlin-Brandenburg, Germany

VEGA 1/0961/11 Pokročilé algoritmy spracovania obrazov na efektívne vyhľadávanie a kódovanie ľudských tvárí. Vedúci projektu: J. Pavlovičová

VEGA 1/0214/10 Návrh metód analýzy a klasifikácie pre biometrické rozpoznávanie obrazov ľudských tvárí a prevádzku komunikačných sietí. Vedúci projektu: M. Oravec

9 Publikácie autora

[A14] Jirka V., Oravec M., Pavlovičová J., Féder M.: Experiments with Automatic Training-Sample Selection Using Self-organizing Map, 8th International Workshop on Multimedia and Signal Processing Redžúr 2014, 13 May 2014, Dubrovnik, Croatia, pp. 53-56, ISBN 978-80-227-4162-0

[A14a] Loderer M., Pavlovičová J., Oravec M., Féder M.: Data Dimension Reduction in Training Strategy for Face Recognition System. In 21th International Conference on Systems, Signals and Image Processing IWSSIP 2014. 12.-15. May, Dubrovnik, Croatia, pp. 263-266, ISSN 2157-8672, ISBN 978-953-184-191-7 (Scopus)

[A14b] Jirka V., Féder M., Pavlovičová J., Oravec M.: Face Recognition System with Automatic Training Samples Selection Using Self-organizing Map, 56th International Symposium ELMAR-2014, 10-12 September 2014, Zadar, Croatia, pp. 23-26, ISBN 978-953-184-199-3

[A13] Oravec, M., Pavlovičová, J., Mazanec, J., Omelina, L., Féder, M., Ban, J., Mazanec, J., Valčo, M., Zelina, M.: Metódy strojového učenia na extrakciu príznakov a rozpoznávanie vzorov 2: Rozpoznávanie tvárí v biometrii, monografia, vydavateľstvo Felia, Bratislava, 2013, ISBN 978-80-971512-0-1

[A13a] Oravec M., Féder M., Zelina M.: Strojové učenie a neurónové siete– učebné texty, RT systems Bratislava, 2013, ISBN 978-80-970519-5-2

[A13c] Ban J., Féder M., Omelina L., Oravec M., Pavlovičová J.: Face Recognition Under Partial Occlusion and Noise, IEEE EUROCON, Zagreb, Croatia, 1-4 July 2013, ISBN: 978-1-4673-2231-7, pp. 2072-2079

[A13d] Ban J., Féder M., Jirka V., Loderer M., Omelina L., Oravec M., Pavlovičová J.: An Automatic Training Process Using Clustering Algorithms for Face Recognition System, 55th International Symposium ELMAR-2013, 25-27 September 2013, Zadar, Croatia, pp. 15-18, ISBN 978-953-7044-14-5 (Scopus)

[A12] Ban J., Féder M., Oravec M., Pavlovičová J.: Face Recognition of Images Corrupted by Transmission Errors, Proceedings Redžúr 2012: 6th International Workshop on Multimedia and Signal Processing April 11, 2012, Vienna, Austria

[A12a] Ban J., Féder M., Omelina L., Oravec M., Pavlovičová J.: Face Recognition Methods for Multimodal Interface. 5th joint IFIP Wireless and Mobile Networking Conference, 19-20th September 2012, Bratislava, Slovakia, ISBN: 978-1-4673-2994-1, pp. 110-113 (**Web of Science**)

[A11] Oravec M., Pavlovičová J., Mazanec J., Omelina L., Féder M., Ban J.: Efficiency of Recognition Methods for Single Sample per Person Based Face Recognition, chapter in monograph Reviews, Refinements and New Ideas in Face Recognition (Ed. Peter M. Corcoran), ISBN 978-953-307-368-2, IN-TECH, Croatia, 2011, pp. 181-206

Citácie:

- Krulikovská L., Polec J., Hirner T.: Fast Algorithm of Shot Cut Detection, World Academy of Science, Engineering and Technology 67 2012, Issue 67, July 2012, Stockholm, Sweden pp.395-398, eISSN 2010-3778

- Polec J., Hirner T.: Unequal Error Protection for Region of Interest with Embedded Zerotree Wavelet, World Academy of Science, Engineering and Technology 67 2012, Issue 67, July 2012, Stockholm, Sweden, pp.427-32, eISSN 201-3778
- Gaynor P., Coore D.: Towards Distributed Face Recognition on Self Organized Storage built from Wireless Sensor Nodes, 12th Annual Wireless Telecommunications Symposium (WTS) - Global Wireless Communications - Future Directions Location: Phoenix, AZ Date: APR 17-19, 2013

[A11a] Ban J., Féder M., Oravec M., Pavlovičová J.: Non-conventional Approaches to Feature Extraction for Face Recognition, Acta Polytechnica Hungarica, Journal of Applied Sciences, Budapest, Hungary, ISSN 1785-8860, Vol. 8, No. 4, 2011, pp. 75-90 (Web of Science)

Citácie:

- Kerem P., Oguz T.: Real-time Traffic Sign Recognition with Map Fusion on Multicore/Many-core Architectures, Acta Polytechnica Hungarica, Journal of Applied Sciences, Budapest, Hungary, ISSN 1785-8860, Volume 9, Number 2, 2012
- Varkonyi-Koczy A.R., Tusor B., Dineva A.: Determination of the Complexity Fitted Model Structure of Radial Basis Function Neural Networks, Intelligent Engineering Systems (INES), 2013 IEEE 17th International Conference, pp.237,242, 19-21 June 2013
- Par K., Tosun O.: Parallelization of Particle Filter Based Localization and Map Matching Algorithms on Multicore/Manycore Architectures, IEEE Intelligent Vehicles Symposium, Proceedings, Vol. 9, No. 2, 2012 art. no. 5940475, Baden-Baden, Germany, pp. 820-826, 2011

[A11b] Ban J., Féder M., Oravec M., Pavlovičová J.: Enhancement of One Sample per Person Face Recognition Accuracy by Training Sets Extension, Proc. ELMAR-2011, 53rd International Symposium ELMAR-2011, 14-16 September 2011, Zadar, Croatia, ISSN 1334-2630, ISBN 978-953-7044-12-1, pp. 25-28, 2011 (Scopus)

[A10] Ban J., Féder M., Oravec M.: Biometrické metódy pre rozpoznávanie obrazov ľudských tvárí. Posterus : Internetový časopis marec. ISSN 1338-0087, 2010

[A10a] Féder, M.: Biometrické rozpoznávanie tvárí z databáz MIT a FERET pomocou strojov s podpornými vektormi SVM a sietí RBF. Diplomová práca. Bratislava: STU FEI, 2010. 67 s

[A09] Ban J., Féder M., Oravec M.: Experiments with Selected Machine Learning Methods for Biometric Face Recognition, Proc. of Redžúr 2009, 3rd International Workshop on Speech and Signal processing, September 24, 2009, Bratislava, Slovak Republic, Edited by: Gregor Rozinaj, Juraj Vojtko, Ján Kőrösi, zborník CD, ISBN 978-80-227-3137-9, pp. 28-33

[A09a] Ban J., Féder M., Oravec M.: Biometrické metódy pre rozpoznávanie obrazov ľudských tvárí, Študentská vedecká a odborná činnosť ŠVOČ 2009, fakultné kolo, sekcia Aplikovaná informatika, 29. apríl 2009, Fakulta elektrotechniky a informatiky STU Bratislava, CD, editori Šagátová A., Stacho M., Pavlovičová J., ISBN 978-80-227-3094-5

- ocenené cenou Literárneho fondu (sekcia pre vedeckú a odbornú literatúru a počítačové programy) v roku 2009

10 Zoznam použitej literatúry

[Ahon04] Ahonen T., Hadid A., Pietikainen M.: Face Recognition with Local Binary Patterns, European Conference on Computer Vision – ECCV 2004, pp. 469–481, 2004

[Biao12] Biao W., Fei Z., Weifeng L., Zhimin L., Qingmin L.: Combining Specific Learning and Generic Learning for Single-Sample Face Recognition, Image and Signal Processing (CISP), 2012 5th International Congress, pp.1219,1223, 16-18 Oct. 2012

[Biom06] Biometrics History, NSTC Subcommittee on Biometrics and Identity Management, <http://www.biometrics.gov/Documents/BioHistory.pdf>, 2006, pp. 1-27

[Boom10] Boom, B.J.: Face Recognition's Grand Challenge: Uncontrolled Conditions Under Control, PhD thesis, University of Twente. CTIT Ph.D.-thesis series No. 10-185 ISBN 978-90-365-2987-7, 2010

- [Dehk10] Dehkordi B.K., Haddadnia J.: Facial Expression Recognition with Optimum Accuracy Based on Gabor filters and Geometric Features, Signal Processing Systems (ICSPS), 2010, pp.V1-731-V1-733, July 2010
- [Deng10] Deng W., Hu J., Guo J., Cai W., Feng D.: Robust, Accurate and Efficient Face Recognition From a Single Training Image: A Uniform Pursuit Approach. Pattern Recognition, Vol. 43 Issue 5, May 2010, pp. 1748–1762, ISSN:0031-3203
- [Gros04] Gross R., Baker S., Matthews I., Kanade T.: Face Recognition Across Pose and Illumination, Handbook of Face Recognition, Stan Z. Li and Anil K. Jain, ed., Springer-Verlag, 2004
- [Chen04a] Chen S., Zhang D., Zhou Z.-H.: Enhanced (PC)²A for Face Recognition with One Training Image per Person, Pattern Recognition Letters, 25(10): 1173-1181, 2004
- [Chie10] Chien-Cheng L., Cheng-Yuan S.: Gabor Feature Selection and Improved Radial Basis Function Networks for Facial Expression Recognition, Information Science and Applications (ICISA), pp.1-8, April 2010
- [Jiwe13] Jiwen L., Yap-Peng T., Gang W.: Discriminative Multimanifold Analysis for Face Recognition from a Single Training Sample per Person, Pattern Analysis and Machine Intelligence, IEEE Transactions, vol.35, no.1, pp.39,51, Jan. 2013
- [Moos08] Moosmann F., Nowak E., Jurie F.: Randomized Clustering Forests for Image Classification, Pattern Analysis and Machine Intelligence, IEEE Transactions, vol.30, no.9, pp.1632,1646, Sept. 2008
- [Orav07] Oravec M., Pavlovičová J.: Feature Extraction by Multilayer Perceptron Visualization of Internal Representation of Input Data, The Seventh IASTED International Conference on Visualization, Imaging, and Image Processing (VIIP 2007), August 29 – 31, 2007, Palma de Mallorca, Spain, ISBN Hardcopy: 978-0-88986-691-1 / CD: 978-0-88986-692-8, pp. 112-117
- [Orav99] Oravec M.: A Method for Feature Extraction from Image Data by Neural Network Vector Quantization, Proc. of the 6th International Workshop on Systems, Signals and Image Processing, June 2-4, 1999, Bratislava, Slovakia, pp. 73-76
- [Phil00] Phillips J., Moon H., Rizvi S., Rauss P.: The FERET Evaluation Methodology for Face-Recognition Algorithms, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 22, 2000, pp. 1090 – 1104
- [Qing02] Qingshan L., Rui H., Hanqing L., Songde M.: Face Recognition using Kernel-based Fisher Discriminant Analysis, Automatic Face and Gesture Recognition, Fifth IEEE International Conference, pp.197-201, 21-21 May 2002
- [Ross07] Ross A.A, Jain A.K., Patrick F.: Handbook of Biometrics, Springer Publishers, 2007. ISBN: 978-0-387-71040-2
- [Sadr03] J. Sadr, I. Jarudi, P. Sinha: The Role of Eyebrows in Face Recognition, Perception, vol. 32, pp. 285–293, 2003
- [Shao10] Shaokang Ch.: Face Recognition under Uncontrolled Conditions: Robust Discriminative Principal Component Analysis, Lap Lambert Acad. Publ., 01/2010
- [Sing10] Singh K., Zaveri M., Raghuvanshi M.: Illumination and Pose Invariant Face Recognition: A Technical Review, International Journal of Computer Information Systems and Industrial Management Applications (IJCSIM), ISSN: 2150-7988 Vol.2, pp.029-038, 2010
- [Suru12] Suruliandi A., Meena K., Reena Rose R.: Local Binary Pattern and its Derivatives for Face Recognition, Computer Vision, IET , vol.6, no.5, pp.480,488, Sept. 2012
- [Tan06] Tan X., Chen S., Zhou Z.-H., Zhang F.: Face Recognition from a Single Image per Person: A survey. Pattern Recognition, Vol. 39 (9), pp. 1725-1745. ISSN:0031-3203, 2006
- [Turk91] Turk M., Pentland A.: Eigenfaces for Recognition, Journal of Cognitive Neuroscience, vol. 3, 1991, pp. 71-86
- [Vers08] Verschae R., Ruiz-del-Solar J., Correa M.: Face Recognition in Unconstrained Environments: A Comparative Study, Workshop on Faces in 'Real-Life' Images: Detection, Alignment, and Recognition, Marseille, France, 2008
- [Vino13] Vinothkumar B., Kumar P.: A Novel Preprocessing Method and PCLDA Algorithm for Face Recognition under Difficult Lighting Conditions, Emerging Trends in VLSI, Embedded System, Nano Electronics and Telecommunication System (ICEVENT), International Conference, pp.1,4, 7-9 Jan. 2013
- [Wang10] Wang Y., Zhang Y.: The Facial Expression Recognition Based on KPCA, Intelligent Control and Information Processing (ICICIP), pp.365-368, 13-15 Aug. 2010

- [Wu02] Wu J., Zhou Z.-H.: Face Recognition with One Training Image per Person, *Pattern Recognition Letters*, 23(14): 1711-1719, 2002
- [Xie10] Xie X., Zheng W-S., Lai J-H., Suen C.Y.: Restoration of a Frontal Illuminated Face Image Based on KPCA, *Pattern Recognition (ICPR)*, pp.2150-2153, 23-26 Aug. 2010
- [Xing12] Xingjie W., Chang-Tsun L., Yongjian H.: Robust Face Recognition under Varying Illumination and Occlusion Considering Structured Sparsity, *Digital Image Computing Techniques and Applications (DICTA)*, 2012 International Conference, pp.1,7, 3-5 Dec. 2012
- [Yang04] Yang J., Zhang D.: Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.28, pp.131-137, 2004
- [Yong12] Yongkang W., Harandi M.T., Sanderson C., Lovell B.C.: On Robust Biometric Identity Verification via Sparse Encoding of Faces: Holistic vs local approaches, *Neural Networks (IJCNN)*, The 2012 International Joint Conference, pp.1,8, 10-15 June 2012
- [Zhao03] Zhao W., Chellappa R., Phillips P.J.: Face Recognition: A Literature Survey, *ACM Computing Surveys*, Vol. 35, No. 4, December 2003
- [Zhi08] Zhi-Kai H., Wei-Zhong Z., Hui-Ming H., Ling-Ying H.: Using Gabor Filters Features for Multi-Pose Face Recognition in Color Images, *Intelligent Information Technology Application*, 2008. IITA '08. Second International Symposium, vol.1, pp.399,402, 20-22 Dec. 2008
- [Zou07] Zou J., Ji Q., Nagy G.: A Comparative Study of Local Matching Approach for Face Recognition, *IEEE Transactions on Image Processing*, Vol. 16, Issue 10, Oct. 2007, pp. 2617-2628