

Ing. Jozef Ban

Autoreferát dizertačnej práce

ROZPOZNÁVANIE ĽUDSKÝCH TVÁRÍ

na získanie akademického titulu doktor (philosophiae doctor, PhD.)

v doktorandskom študijnom programe: Kybernetika

v študijnom odbore 9.2.7 Kybernetika

Miesto a dátum: Bratislava, 24.9.2014

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

Ing. Jozef Ban

Autoreferát dizertačnej práce

ROZPOZNÁVANIE ĽUDSKÝCH TVÁRÍ

na získanie akademického titulu doktor (philosophiae doctor, PhD.)

v doktorandskom študijnom programe:

Kybernetika

Miesto a dátum: Bratislava, 24.9.2014

Dizertačná práca bola vypracovaná v dennej forme doktorandského štúdia

Na Ústave robotiky a kybernetiky, Fakulta Elektrotechniky a Informatiky

Predkladateľ: Ing. Jozef Ban
Ústav robotiky a kybernetiky, FEI STU Bratislava
Ilkovičova 3, 812 19 Bratislava

Školiteľ: doc. Ing. Jarmila Pavlovičová, PhD.

Oponenti:

1. Prof. RNDr. Ing. Ivan Bajla, PhD., Ústav merania SAV
Dúbravská cesta 9, 841 04 Bratislava
2. Ing. Vanda Benešová, PhD., Ústav aplikovanej informatiky
Fakulta informatiky a informačných technológií, STU Bratislava
Ilkovičova 2, 842 16 Bratislava

Autoreferát bol rozoslaný: 28.8.2014

Obhajoba dizertačnej práce sa koná: 24.9.2014, 9:00

Na v miestnosti D424, FEI STU v Bratislave,
Ilkovičova 3, 812 19 Bratislava

prof. RNDr. Gabriel Juhás, PhD.
dekan FEI STU Bratislava
Ilkovičova 3, 812 19 Bratislava

Obsah

1	ÚVOD	4
2	PREHĽAD SÚČASNÉHO STAVU PROBLEMATIKY	4
2.1	EXTRAKCIA PRÍZNAKOV.....	6
2.2	ROZPOZNÁVANIE NA ZÁKLADE JEDNEJ VZORKY	6
2.3	ROZPOZNÁVANIE TVÁRÍ V NERIADENÝCH PODMIENKACH	7
2.4	PREKRYTIA A POŠKODENIA VZORIEK	7
2.5	SYSTÉM NA ROZPOZNÁVANIE ĽUDSKÝCH TVÁRÍ.....	7
3	CIELE PRÁCE.....	8
3.1	EXTRAKCIA PRÍZNAKOV A KLASIFIKÁCIA	8
3.2	PROBLÉM JEDNEJ VZORKY	8
3.3	ROZPOZNÁVANIE TVÁRÍ V NERIADENÝCH PODMIENKACH	8
3.4	SYSTÉM NA ROZPOZNÁVANIE ĽUDSKÝCH TVÁRÍ.....	8
4	VYKONANÉ EXPERIMENTY A VÝSLEDKY DIZERTAČNEJ PRÁCE	9
4.1	EXTRAKCIA PRÍZNAKOV A KLASIFIKÁCIA	9
4.2	PROBLÉM JEDNEJ VZORKY	10
4.3	ROZPOZNÁVANIE TVÁRÍ V NERIADENÝCH PODMIENKACH	10
4.4	SYSTÉM NA ROZPOZNÁVANIE ĽUDSKÝCH TVÁRÍ.....	11
5	SUMARIZÁCIA PUBLIKOVANÝCH PRÍNOSOV	13
5.1	EXTRAKCIA PRÍZNAKOV A KLASIFIKÁCIA	13
5.2	PROBLÉM JEDNEJ VZORKY	13
5.3	ROZPOZNÁVANIE TVÁRÍ V NERIADENÝCH PODMIENKACH	14
5.4	SYSTÉM NA ROZPOZNÁVANIE ĽUDSKÝCH TVÁRÍ.....	14
6	ZHODNOTENIE	15
7	ÚČASŤ AUTORA V PROJEKTOCH.....	15
8	PUBLIKÁCIE AUTORA	16
9	ZOZNAM POUŽITEJ LITERATÚRY	17

1 Úvod

Vedné odbory zaoberajúce sa biometriou a biometrickými systémami majú už historický charakter. V minulosti sa biometria využívala prevažne v kriminalistike na identifikáciu zločincov, či už spočiatku iba vyvesením obrazu tváre hľadanej osoby alebo neskôr napr. pomocou odtlačkov prstov. Vďaka dlhoročnému výskumu v tejto oblasti a taktiež pokročilým výpočtovým technológiám dnes vieme spracovávať biometriky ako hlas, ľudskú tvár, geometriu ruky, očné dúhovku alebo napríklad DNA. Vhodná aplikácia najmodernejších algoritmov v kombinácii s ľudskými biometrikami prináša nový rozmer na poli informačných technológií. Prítomnosť rôznych spôsobov identifikácie a verifikácie sa stáva súčasťou každodenného života. Čoraz viac sa môžeme stretávať s ich využitím či už na hraničných prechodoch, pri ochrane počítačov, sietí, budov, majetku, bankových transakcií, alebo tiež napr. v stravovacích systémoch. Biometrické systémy v praxi však stále nedosahujú výsledky aké by sme od nich očakávali alebo aké dosahujú v ideálnom prostredí.

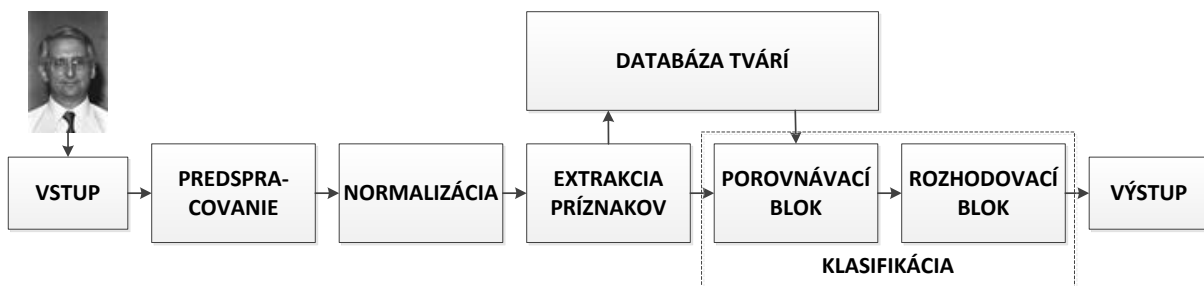
Prvé štúdie problematiky rozpoznávania ľudských tvárí siahajú do 60-tych rokov minulého storočia. V roku 1991 bol navrhnutý prvý systém pre spoľahlivú identifikáciu osôb v reálnom čase. Postupne výskum a vývoj v tejto oblasti zaznamenal veľký záujem. Avšak aj napriek dlhoročnému výskumu systémy určené na rozpoznávanie ľudských tvárí stále nedosahujú takú úspešnosť, s akou dokáže rozpoznávať tváre človek.

Problematika rozpoznávania tvárí so sebou prináša množstvo úloh a problémov, ktorým sa treba postupne venovať. Vo svojej podstate predstavuje rozpoznávanie ľudských tvárí veľkú výpočtovú a časovú náročnosť. Systém musí byť najprv vhodne natrénovaný, aby bol následne schopný pomocou zložitých výpočtov rozpoznať daného jedinca. Pokročilejšie rozpoznávacie prístupy extrahujú iba vybrané príznaky (s najvyššou informačnou hodnotou) a zjednodušujú tak celkovú výpočtovú a časovú náročnosť. Veľký potenciál pri extrakcii príznakov, pre rozpoznávanie tvárí, predstavujú Gáborove filtre. V poslednej dobe sa tiež čoraz viac používa rozpoznávanie na základe jednej trénovacej vzorky na osobu. Takýto prístup výrazne zjednodušuje trénovací proces a celkovú náročnosť, na druhej strane však nedosahuje úspešnosť ako pri používaní viacerých vzoriek na osobu. Všeobecne sa o tejto problematike hovorí ako o probléme jednej vzorky na osobu - One sample per person problem (Tan a kol., 2006). Jednou z možností, ako pristupovať k tomuto problému, je zvyšovanie úspešnosti rozpoznávania generovaním nových vzoriek.

Výraznou problematickou oblasťou je rozpoznávanie tvárí v neriadených podmienkach. Ide o reálne prostredie, kde sa menia všetky faktory vplývajúce na rozpoznávanie. Nevieme dopredu presne odhadnúť aké bude osvetlenie, výraz tváre, pozadie či uhol natočenia tváre pri snímaní.

2 Prehľad súčasného stavu problematiky

Rozpoznávanie tvárí (Jafri a Arabnia, 2009) zahrňuje viacero za sebou idúcich a na seba nadväzujúcich procesov, ktoré môžeme charakterizovať vo viacerých blokoch. Z týchto blokov dokážeme zovšeobecniť model rozpoznávania tvárí. Schematické znázornenie zovšeobecného modelu s jednotlivými blokmi je na Obr. 1.



Obr. 1 Schematické znázornenie zovšeobecného modelu rozpoznávania tvárí.

Opis jednotlivých, za sebou idúcich, blokov zovšeobecneného modelu rozpoznávania tváří a ich jednotlivé výstupy:

- **Vstup** – vstupný blok, zosnímanie tváre, napr. pomocou kamery
 - *Výstup* – nasnímaný obraz.
- **Predspracovanie** – využíva sa, ak je potrebné vstupné dáta špeciálne upraviť pre rozpoznávací systém, napr. detekcia tváre v obraze, odstránenie šumu alebo vrátenie vstupných dát a žiadosť o opätovné zosnímanie.
 - *Výstup* – upravený obraz s detegovanou tvárou.
- **Normalizácia** – Normalizácia (úprava) tváre, napr. pozícia a natočenie tváre alebo škálovanie veľkosti.
 - *Výstup* – obraz s normalizovanou tvárou pre daný systém.
- **Extrakcia príznakov** – extrahuje charakteristiky s najvyššou informačnou hodnotou; výstupom je vektor príznakov. Pri tréovaní systému sa tieto vektory ukladajú do databázy, pri rozpoznávaní postupuje vektor do ďalšieho - porovnávacieho bloku.
 - *Výstup* – vektor príznakov (pri procese tréovania – databáza).
- **Porovnávací blok** – porovnáva vstupný vektor príznakov s vektormi uloženými v databáze, na základe určenej klasifikačnej metódy.
 - *Výstup* – výsledok porovnania.
- **Rozhodovací blok** – na základe predošlých výpočtov určí (alebo overí) identitu vstupnej osoby, prípadne zamietne vstupnú osobu, ak sa v danom systéme nenachádza.
 - *Výstup* – identita, rozhodnutie, zamietnutie.
- **Výstup** – výstupné zariadenie, napr. displej, zobrazí výsledok rozpoznávania - identita alebo záznam vstupnej osoby, prípadne zamietnutie.

Vo väčšine odborných článkov a literatúre zameranej na rozpoznávanie ľudských tváří sa autori venujú hlavne extrakcii príznakov a ich následnému porovnávaniu. Detekciu tváre, predspracovanie, či normalizáciu obrazov opisujú len v prípade, že sa líšia od bežne používaných metód a teda sú charakteristické pre daný prístup. Samotnej detekcii tváří, prípadne očí či iných objektov, sa autori venujú v odbornej literatúre zameranej priamo na túto problematiku. Ide o samostatný vedný odbor, ktorý ma v dnešnej dobe uplatnenie aj v iných oblastiach, ako napr. fotoaparáty a videokamery – automatické zaostrovanie na tvár, sledovanie pohybu tváre. Tiež častým využitím sú webové portály, aplikácie či sociálne siete, zaoberajúce sa zväčša fotografiami. V prípade rozpoznávaní tváří sú veľmi spoľahlivé a rozšírené prístupy Viola-Jones detektor (Viola a Jones, 2001), ktorý využíva Haarové príznaky a Aktívne modely tvaru (z angl. Active Shape Model – ASM; Cootes a kol., 1995) a aktívne modely vzhľadu (z angl. Active Appearance Model AAM; Cootes a kol., 2005).

Systémy rozpoznávania tváří, založené na metódach strojového učenia, spravidla pracujú v dvoch módoch. Prvým módom je tréovanie (učenie). Systém extrahuje postupne zo vstupných údajov príznaky a z nich si vytvára vlastnú databázu užívateľov. Extrahované vektory tak nepokračujú ďalej do nasledujúcich blokov, ale ukladajú sa do spomínanej databázy tváří a priradujú sa k jednotlivým užívateľom. Druhým módom je samotné rozpoznávanie. Vektor extrahovaných príznakov zo vstupného obrazu pokračuje do nasledujúcich blokov, kde je porovnaný s dátami uloženými v databáze užívateľov a následne vyhodnotený (klasifikácia). Celé rozpoznávanie je teda priamo závislé od tréovania metód strojového učenia. Preto sa pri tréovaní procese treba zamyslieť nad viacerými faktormi, napr. koľko vzoriek na jeden subjekt pre tréovanie použijeme. Z hľadiska dosiahnutia čo najúspešnejšieho rozpoznania je vhodné použiť čo najviac vzoriek, avšak tým enormne zvyšujeme výpočtovú a časovú náročnosť celého procesu. V posledných rokoch je čoraz viac diskutovanou oblasťou rozpoznávania tváří problematika dostupnosti jedinej vzorky, tzv. problém jednej vzorky. Ďalším významným faktorom je aj výber vzoriek, ktoré pre tréovanie použijeme. Keďže pri systéme, ktorý by mal byť nasadený v reálnej prevádzke nevieme dopredu určiť presné podmienky pri rozpoznávaní, tak snahou je systému poskytnúť čo najviac informácií o subjekte, čiže rôzne výrazy tváre, natočenia či osvetlenie.

2.1 Extrakcia príznakov

Extrakcia vhodných príznakov je jedna zo základných úloh rozpoznávania tváří. Pre zjednodušenie celého procesu, ale aj výpočtovej a časovej náročnosti, je snahou vybrať (extrahovať) iba najvýznamnejšie charakteristiky, resp. dáta s najvyššou informačnou hodnotou – tzv. príznaky. Existuje veľké množstvo prístupov a metód extrakcie, ktoré môžeme vo všeobecnosti rozdeliť do troch základných kategórií (Tan a kol., 2006):

- *Holistické metódy* – tieto metódy extrahujú príznaky z celého vstupného obrazu. Každý obraz je reprezentovaný jedným viacrozmerným vektorom príznakov. Výhodou takýchto metód je, že vo vektore sú obsiahnuté všetky potrebné informácie o rozložení a textúre danej tváre. Ich nevýhodou je, že pracujú s veľkým množstvom dát, a teda celé rozpoznávanie je výpočtovo a pamäťovo náročné. Medzi takéto metódy patrí napr. PCA (Turk a Pentland, 1991).
- *Lokálne metódy* – tieto metódy najprv rozdelia tvár na oblasti a následne extrahujú lokálne príznaky z týchto oblastí (napr. oči, nos, uši či ústa). Každý obraz je reprezentovaný viacerými vektormi príznakov, ktoré charakterizujú lokálne oblasti tváre. Výhodou týchto metód je, že aj pri zakrytí časti tváre sa môžu na rozpoznávanie použiť iba niektoré vybrané vektory lokálnych príznakov (napr. pri zakrytí úst sa porovnávajú iba oči a nos). Nevýhodou je nutnosť predspracovania, ktoré pozostáva z rozdelenia obrazu do oblastí, prípadne aj detekcia jednotlivých častí tváre. Medzi takéto metódy patrí napr. EBGM (Wiskott a kol., 1997).
- *Hybridné metódy* – tieto metódy využívajú kombináciu holistických a lokálnych príznakov na rozpoznávanie tváří. Použitie takýchto metód má väčšiu perspektívu dosiahnuť lepšie výsledky ako použitím len holistickej alebo lokálnej metódy, nakoľko sú schopné obsiahnuť viac rôznych typov informácií.

2.2 Rozpoznávanie na základe jednej vzorky

Veľa úsilia v oblasti výskumu rozpoznávania ľudských tváří sa zameriava na to, ako zvyšovať presnosť rozpoznávacích systémov. Vo väčšine prípadov však ignorujú potenciálny problém dostupnej databázy tváří. Problém nastáva, keď rozpoznávací systém je alebo môže byť natrénovaný len s jednou vzorkou na osobu, v dôsledku napr. pamäťových kapacít alebo dostupnosti jednotlivých vzoriek (problém pri zhromažďovaní vzoriek). V takýchto prípadoch väčšine klasických metód, ako sú eigenface (Brunelli a kol., 1993) a fisherface (Belhumeur a kol., 1997), výrazne poklesne úspešnosť rozpoznávania, či dokonca nebudú vôbec fungovať, vzhľadom na absenciu dostatočného počtu vzoriek pre spoľahlivý odhad kovariancie. Takémuto problému sa hovorí problém jednej vzorky na osobu (angl. *one sample per person problem*) a je definovaný nasledovne (Tan a kol., 2006): Majme databázu tváří obsahujúcu iba jeden obraz na osobu. Cieľom je identifikovať osobu z databázy v rozličných nepredvídateľných pózach a svetelných podmienkach na základe jediného obrazu. Ak by rozpoznávací systém dokázal úspešne rozpoznávať aj na základe len jednej vzorky na osobu, zjednodušil by sa tréningový proces a aj celková náročnosť, či už výpočtová alebo časová. Vzhľadom na jeho význam v oblasti rozpoznávania tváří a tiež použitia pre reálne aplikácie, bolo navrhnutých viacero prístupov, ako riešiť daný problém. Prístupy v rôznych publikáciách zahŕňajú napr. generovanie syntetických virtuálnych vzoriek (Chen a kol., 2004; Martinez, 2002), pravdepodobnostnú príslušnosť (Martinez, 2002; 2003), špecifický podpriestor pre jednotlivé triedy (Shan a kol., 2003; Tao a kol., 2013), metódy s využitím neurónových sietí (Tan a kol., 2005) a podobne. V prehľadových publikáciách (Tan a kol., 2006; Oravec a kol., 2011) autori uvádzajú prehľady prístupov vyvinutých za účelom riešiť problém jednej vzorky.

V rámci holistických prístupov bolo pre problematiku jednej vzorky vyvinutých viacero rozšírení klasických metód ako napr. 2D-PCA (Yang a kol., 2004), MW(2D)2PCA -Modular Weighted (2D)2PCA (Que a kol., 2008), GW+DKPCA – Gabor based kernel PCA (Xie a kol., 2006). Jednou z ďalších možností je, ako už bolo spomenuté, generovanie nových syntetických vzoriek. Medzi lokálne metódy zaoberajúce sa problémom jednej vzorky patria napr. metódy založené na porovnávaní grafov (Wiskott a kol., 1997; Kepenecki a kol., 2002), metóda skrytých Markovových modelov (Le a kol., 2004), či metódy založené na SOM - Self-Organizing Maps (Tan a kol., 2005; Tan, Liu, a Chen, 2006).

V publikácií (Martinez, 2002) je popísaná hybridná metóda lokálnych pravdepodobnostných podpriestorov využívajúca virtuálne vzorky a lokálne príznaky.

2.3 Rozpoznávanie tvári v neriadených podmienkach

Vo väčšine prístupoch rozpoznávania ľudských tvári sa autori snažia, za každú cenu, dosiahnuť úspešnosť blížiacu sa k 100%. Na to, aby ich navrhnuté algoritmy fungovali takmer bezchybne často používajú tzv. riadené podmienky (Zhao a kol., 2003). Riadenými podmienkami myslíme prostredie, v ktorom sú umelo a striktné vytvárané situácie snímania tváre. V takomto prostredí je presne dané natočenie hlavy, výraz tváre, nemeniace sa pozadie (napr. biela stena) či osvetlenie. Avšak pri použití v reálnych podmienkach, takéto prístupy často zlyhávajú. Z tohto dôvodu je nevyhnutné vyvíjať algoritmy a prístupy určené do reálnych - neriadených podmienok, kde nevieme dopredu určiť aké bude natočenie hlavy, osvetlenie a iné faktory vplývajúce na celkové rozpoznávanie tvári (Meher a Maben 2014; Singh a Om, 2013; Hua a kol, 2001; Zhou a kol, 2006; Howell a Buxton, 1996). Slabé osvetlenie (prípadne výrazná zmena osvetlenia) býva najčastejším problémom, na ktorom systémy rozpoznávania tvári zlyhávajú.

2.4 Prekrytia a poškodenia vzoriek

Ďalšou problematikou, ktorá z časti zapadá do rozpoznávania v neriadených podmienkach, je prekrytie a poškodenie vzoriek (Bajla a kol., 2011; Nikan a Ahmadi, 2012). Prekrytie môže vznikáť napr. už pri samotnom tvorení snímky (predmet medzi snímacím zariadením a tvárou subjektu – napr. slnečné okuliare či ústa zakryté rukou; zlé nastavenie snímacieho zariadenia – rozmazaná časť tváre). V špecifických prípadoch môžeme tiež vynechať niektoré bloky úmyselne (porovnanie, ktoré prekrytie viac znehodnotí vzorku; prekrytie častí obrazu, ktoré nám nemajú pridanú hodnotu pri rozpoznávaní).

Poškodenie vzoriek môže mať rôzny charakter (chýbajúce pixely, bloky či celé časti obrazu). Takéto poškodenie bežne vniká napr. pri prenose komunikačným kanálom alebo komprimáciou dát s využitím štandardov JPEG a MPEG, ktoré používajú blokovo založené techniky pre dosiahnutie kompresie. Bežne sa pre tento prípad poškodenia vzoriek používajú metódy obnovy stratených informácií z obrazu (angl. error concealment techniques; Pavlovičová a kol., 2006). Chýbajúce pixely sa dopočítavajú na základe informácie z ich okolia.

Samotnou kapitolou poškodenia vzoriek (obrazov) tvorí šum (Buciu a Gacsadi, 2011; Le An a kol., 2013). Šum môže vznikáť ako vedľajší produkt prenosu, kopírovania, modifikovania, samotného snímania alebo iných aktivít. Znižuje informačnú hodnotu užitočných dát a tým aj ovplyvňuje celkovú úspešnosť rozpoznávania. V špecifických prípadoch sa šum môže považovať za informáciu.

2.5 Systém na rozpoznávanie ľudských tvári

Z hľadiska praktického využitia rozpoznávania ľudských tvarí, je potrebný komplexný systém, ktorý by pre spoľahlivú identifikáciu dokázal (aspoň čiastočne) riešiť vyššie uvedené úlohy ale aj mnohé ďalšie. Návrhom takýchto systémov sa venujú viaceré vedecké projekty, ako: MOBIO (Mobile Biometry, 2008), TABULA RASA (Trusted Biometrics under Spoofing Attacks, 2010) či HBB-Next (Hybrid Broadcast Broadband Next Generation, 2011) ale aj vedecké publikácie, napr. (Baykara a Das, 2013; Dobra a kol., 2013; Sang-Heon a kol., 2013; Anith a kol., 2013).

Aby takýto systém dokázal konkurovať iným identifikačným prístupom (napr. heslo), resp. mal voči nim pridanú hodnotu, musí spĺňať základné požiadavky. Najdôležitejšou požiadavkou je samozrejme presná identifikácia či verifikácia jedinca. Avšak nemenej dôležitou požiadavkou je rozpoznávanie v reálnom čase, alebo aspoň blízke reálnemu času (near to real-time). Medzi ďalšie požiadavky pre takýto systém patrí schopnosť rozpoznávania aj v zhoršených svetelných podmienkach, benevolentnosť systému voči jemným zmenám na tvári (napr. fúzy, brada či make-up), ale aj odolnosť voči útokom (napr. oklamanie systému nasnímaním 2D fotografie niekoho iného). Nakoľko aj v súčasnosti je

realizácia týchto požiadaviek stále v štádiu vývoja a predstavuje veľké problémy, používajú sa systémy, ktoré sú stavané len na verifikáciu (overenie identity, napr. rozpoznanie tváří na notebookoch a počítačoch). Azda najväčším problémom je počet užívateľov. Je takmer nespĺniteľnou úlohou navrhnúť systém, ktorý by korektne identifikoval stovky až tisíce užívateľov. Schodnou cestou je prístup pre maximálne desiatky užívateľov, a teda systémy pre malé firmy či rodiny. Z hľadiska bezpečnosti, aby identifikácia bola čo najpresnejšia, sa v poslednom čase stále viac začína využívať spájanie viacerých modalít. Ide o tzv. multimodálne rozhranie (multimodal interface). Z bezpečnostného hľadiska ide o viacnásobnú autentifikáciu (príp. verifikáciu) a teda dalo by sa použiť aj pre prístup k najcitlivejším údajom (napr. pre bankové operácie).

3 Ciele práce

Na základe doterajšieho štúdia odbornej a vedeckej literatúry a poznatkov získaných v problematike strojového rozpoznávania ľudských tváří sme si stanovili nasledovné ciele dizertačnej práce:

3.1 Extrakcia príznakov a klasifikácia

Použitím vhodnej metódy extrakcie príznakov dokážeme zjednodušiť rozpoznávací proces a zároveň zvýšiť úspešnosť klasifikácie. Z tohto dôvodu sme zdefinovali nasledujúci cieľ dizertačnej práce:

Návrh a realizácia algoritmu extrakcie príznakov tak, aby boli splnené nasledovné požiadavky:

- Zvýšenie presnosti rozpoznávania, v porovnaní s použitím priamej klasifikácie.
- Zníženie výpočtovej a časovej náročnosti celého rozpoznávacieho procesu.
- Overenie funkčnosti a porovnanie s inými prístupmi.

3.2 Problém jednej vzorky

Na základe analýzy v danej problematike sa generovanie nových syntetických vzoriek javí ako vhodný prístup riešenia problému jednej vzorky, z ktorého sme si stanovili ďalší cieľ:

- Návrh viacerých postupov generovania nových vzoriek.
- Nájdenie postupov na generovanie syntetických vzoriek, ktoré povedie k zvýšeniu úspešnosti rozpoznávania.
- Využitie rôznych modifikácií obrazov tváří, napr. použitím šumu, waveletovej transformácie.
- Overenie účinnosti rozpoznávania tváří s použitím navrhnutých syntetických vzorov

3.3 Rozpoznávanie tváří v neriadených podmienkach

Väčšina prístupov rozpoznávania tváří je navrhnutá tak, aby dosahovala, čo najvyššiu úspešnosť aj za cenu vytvárania riadených podmienok. Na základe potreby vývoja algoritmov a prístupov rozpoznávania v neriadených podmienkach sme si zvolili nasledovný cieľ:

- Analýza a vyhodnotenie rôznych vplyvov na úspešnosť rozpoznávania.
- Porovnanie vybraných prístupov a metód na dátach získaných v reálnom prostredí (neriadené podmienky).
- Použitie vzoriek s rôznym osvetlením, natočením tváre, výrazom tváre, prekrytím rôznych častí tváre.
- Poškodenie vzoriek rôznymi vplyvmi ako šum alebo chýbajúce časti obrazu vplyvom prenosu chybovým komunikačným kanálom.
- Návrh vhodného postupu pre zvýšenie účinnosti rozpoznávania tváří v neriadených podmienkach.

3.4 Systém na rozpoznávanie ľudských tváří

So všetkých nadobudnutých poznatkov doterajšieho štúdia, nášho výskumu v oblasti rozpoznávania ľudských tváří a na základe našej participácie na vedeckom projekte 7. Rámcového programu HBB-


Next (Hybrid Broadcast Broadband Next Generation, <http://www.hbb-next.eu/>), sme si stanovili posledný cieľ dizertačnej práce:

- Podieľanie sa na návrhu a realizácii systému na rozpoznávanie ľudských tvárí v rámci projektu HBB-Next. Ide o súčasť multimodálneho rozhrania na ovládanie SMART-TV. Rozpoznávanie tvárí slúži na identifikáciu užívateľa a následné sprístupnenie vybraných funkcií podľa jeho profilu, príp. ponuku služieb podľa jeho preferencií.
- Návrh a realizácia systému na rozpoznávanie ľudských tvárí.
- Optimalizácia algoritmov pre jednotlivé úlohy rozpoznávania: detekcia tváre, predspracovanie, extrakcia príznakov a klasifikácia.

4 Vykonané experimenty a výsledky dizertačnej práce

4.1 Extrakcia príznakov a klasifikácia

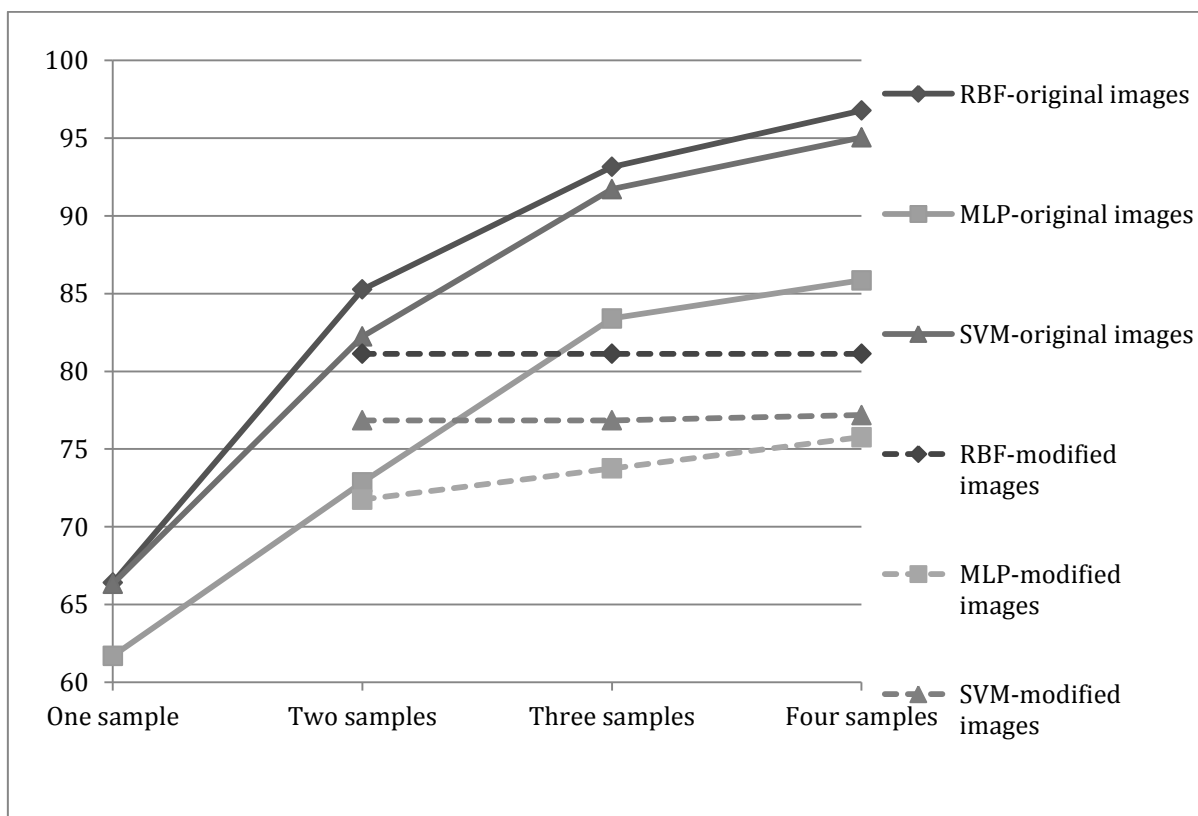
V práci (Ban, Féder, Oravec a Pavlovičová, 2011/a) sme navrhli dva postupy zlepšenia úspešnosti rozpoznávania tvárí využitím extrakcie príznakov s tzv. HLO (angl. Hidden layer outputs) a INDEX obrazmi na databáze tvárí MIT. Naším hlavným cieľom bolo dosiahnutie vyššej úspešnosti rozpoznávania použitím extrahovaných príznakov z obrazov tvárí v porovnaní s použitím priamej klasifikácie obrazov tvárí vybranými metódami, pričom zároveň redukuje množstvo dát. V prípade HLO obrazov sme vychádzali z predpokladu, že neurónová sieť v auto-asociačnom móde vo svojej skrytej vrstve obsahuje dôležité charakteristické príznaky umožňujúce klasifikáciu. Preto sme sa rozhodli modifikované výstupy skrytej vrstvy neurónovej siete použiť ako príznaky ľudských tvárí – vstupy do systému rozpoznávania tvárí. Príznaky nazvané INDEX obrazy sú založené na vektorovej kvantizácii, ako metóde, ktorá významným spôsobom redukuje dáta a zároveň zachováva podstatné vlastnosti obrazu. Tieto prístupy sme testovali na databáze tvárí MIT. Na klasifikáciu extrahovaných príznakov získaných pomocou HLO a INDEX obrazov sme navrhli použitie metód MLP, RBF a SVM. Výsledky, ktoré sme navrhnutými postupmi dosiahli, sme porovnali s priamou klasifikáciou obrazov veľkosti 64x60 pomocou spomenutých metód MLP, RBF a SVM. Pre objektivitu dosiahnutých výsledkov sme použili 5-násobnú krížovú validáciu. Na Obr. 2 je znázornené grafické porovnanie dosiahnutých výsledkov úspešnosti pre použité metódy a postupy. Číselne sú vyznačené najlepšie dosiahnuté úspešnosti rozpoznávania.



Obr. 2 Porovnanie výsledkov použitých metód priamej klasifikácie (obrazy s rozmermi 64x60) a navrhnutých prístupov využívajúcich extrakciu príznakov - HLO a INDEX obrazy.

4.2 Problém jednej vzorky

Významnú časť nášho vedeckého úsilia sme venovali rozpoznávaniu tvári na základe iba jednej dostupnej vzorky. V prácach (Oravec a kol., 2011; Ban, Féder, Oravec a Pavlovičová, 2011/b) sa tomuto problému podrobne venujeme. Venujeme sa návrhom riešenia problému jednej vzorky a vybraným metódam rozpoznávania tvári, na ktoré sme naše prístupy aplikovali. Ako vstupné dáta sme použili databázu FERET. Pracovali sme s vybranými metódami, ktoré patria k najrozšírenejším v oblasti rozpoznávania tvári, ako PCA, 2D-PCA, SVM, neurónové siete (MLP a RBF) a rôzne varianty metódy LBP. Na generovanie nových vzorov sme použili modifikáciu šumom, waveletovú transformáciu, mean filter a modifikáciu obrazu použitím geometrickej transformácie. Naším cieľom bolo zvýšiť úspešnosť rozpoznania tvári pri dostupnosti iba jednej originálnej vzorky. Tiež sme navrhli rozšírenie tréningových množín založené na najlepšíh dosiahnutých výsledkoch s jednotlivými modifikovanými vzorkami. Na Obr. 3 je znázornené porovnanie úspešností tréningovej množiny s originálnymi vzorkami (plná čiara) a tréningovej množiny s jednou originálnou vzorkou, rozšírenou o generované vzorky (čiarkovaná čiara) pre metódy RBF, MLP a SVM. Ako môžeme vidieť, podarilo sa nám, rozšírením tréningovej množiny o modifikované vzorky, zvýšiť úspešnosť rozpoznávania o 10 až 15% v porovnaní s použitím iba jednej originálnej vzorky. Rozšírenie tréningovej množiny o viac ako jednu generovanú vzorku prinieslo nárast úspešnosti už len pre metódu MLP. Na základe dosiahnutých výsledkov môžeme zhodnotiť, že pri dostupnosti iba jednej vzorky dokážeme pomocou rozšírenia tréningovej množiny o jednu vhodne modifikovanú originálnu vzorku zvýšiť úspešnosť rozpoznávania.



Obr. 3 Porovnanie úspešností rozpoznávania pri použití tréningovej množiny s originálnymi vzorkami (plná čiara) a tréningovej množiny s jednou originálnou vzorkou, rozšírenou o generované vzorky (čiarkovaná čiara)

4.3 Rozpoznávanie tvári v neriadenej podmienkach

Problematike rozpoznávania tvári v neriadenej podmienkach sa venujeme v práci (Ban, Pavlovičová, Féder, Omelina a Oravec, 2012). Hlavným cieľom je výber vhodnej metódy pre systém rozpoznávania ľudských tvári, ktorý by čo najspolahlivejšie pracoval v podmienkach reálneho sveta. Ako vstupné dáta sme použili databázu tvári PIE, ktorá má široké využitie pre výskum v oblasti neriadenej a neštandardných podmienok. V práci sme sa zamerali hlavne na dva významné faktory, a to natočenie tváre subjektu a nerovnomerné osvetlenie. Pre zvýšenie odolnosti rozpoznávania voči rôznym

svetelným podmienkam, sme navrhli postup s aplikáciou ekvalizácie histogramu na jednotlivé použité vzorky. Pre naše experimenty sme použili vybrané metódy rozpoznávania tvárí - PCA, KPCA (Scholkopf a kol., 1999), GDA (Baudt a kol., 2000; Xu a kol., 2010), SVM a RBF.

V ďalších našich prácach (Ban, Féder, Oravec a Pavlovičová, 2012; Ban, Féder, Oravec, Omelina a Pavlovičová, 2013) sa venujeme problematike rôznych zakrytí a poškodení vzoriek. Neúplnosť vzoriek má tiež podstatný vplyv na celkovú úspešnosť rozpoznania, najmä v reálnych podmienkach, kde k týmto situáciám často dochádza.

Prvou témou, ktorou sme sa zaoberali, bolo poškodenie vzoriek, ktoré môže vzniknúť napr. pri prenose chybovým komunikačným kanálom (Ban, Féder, Oravec a Pavlovičová, 2012). Pre takýto prípad poškodenia vzoriek sa bežne používajú metódy obnovy stratených dát z obrazu (angl. error concealment techniques; Pavlovičová a kol., 2006). V našom prístupe analyzujeme úspešnosť vybraných rozpoznávacích metód – SVM, RBF, PCA a KPCA, bez použitia obnovy stratených dát a teda bez ďalšieho zvyšovania výpočtovej a časovej náročnosti rozpoznávania. Ako vstupné dáta sme použili databázu tvárí FERET, konkrétne predspracovanie FERET BIGFace (geometrická normalizácia, ekvalizácia histogramu a orezanie tváre). Aby sme dosiahli simuláciu poškodenia dát, na jednotlivých vzorkách sme generovali náhodný počet chybných (stratených) blokov (5 až 10), s náhodnou veľkosťou (3x3 až 7x7 pixelov) a s náhodným rozmiestnením. Chybné bloky sme vyplnili strednou hodnotou intenzity zodpovedajúcej vzorky (najčastejšie hodnota okolo 128) a nulovou hodnotou intenzity (čierne bloky).

V práci (Ban, Féder, Oravec, Omelina a Pavlovičová, 2013) prezentujeme rozsiahle porovnanie vybraných metód – SVM, RBF, PCA, KPCA a GDA, na vzorkách modifikovaných rôznymi prekrytiami a poškodenými rozličným šumom. Ako vstupné dáta sme opäť použili databázu tvárí FERET s predspracovaním FERET BIGFace. Jedným z našich hlavných cieľov bolo experimentálne overiť ktoré časti tváre v najväčšej miere ovplyvňujú rozpoznávanie. Vzorky sme modifikovali pridávaním prekrytia na rôzne časti tváre.

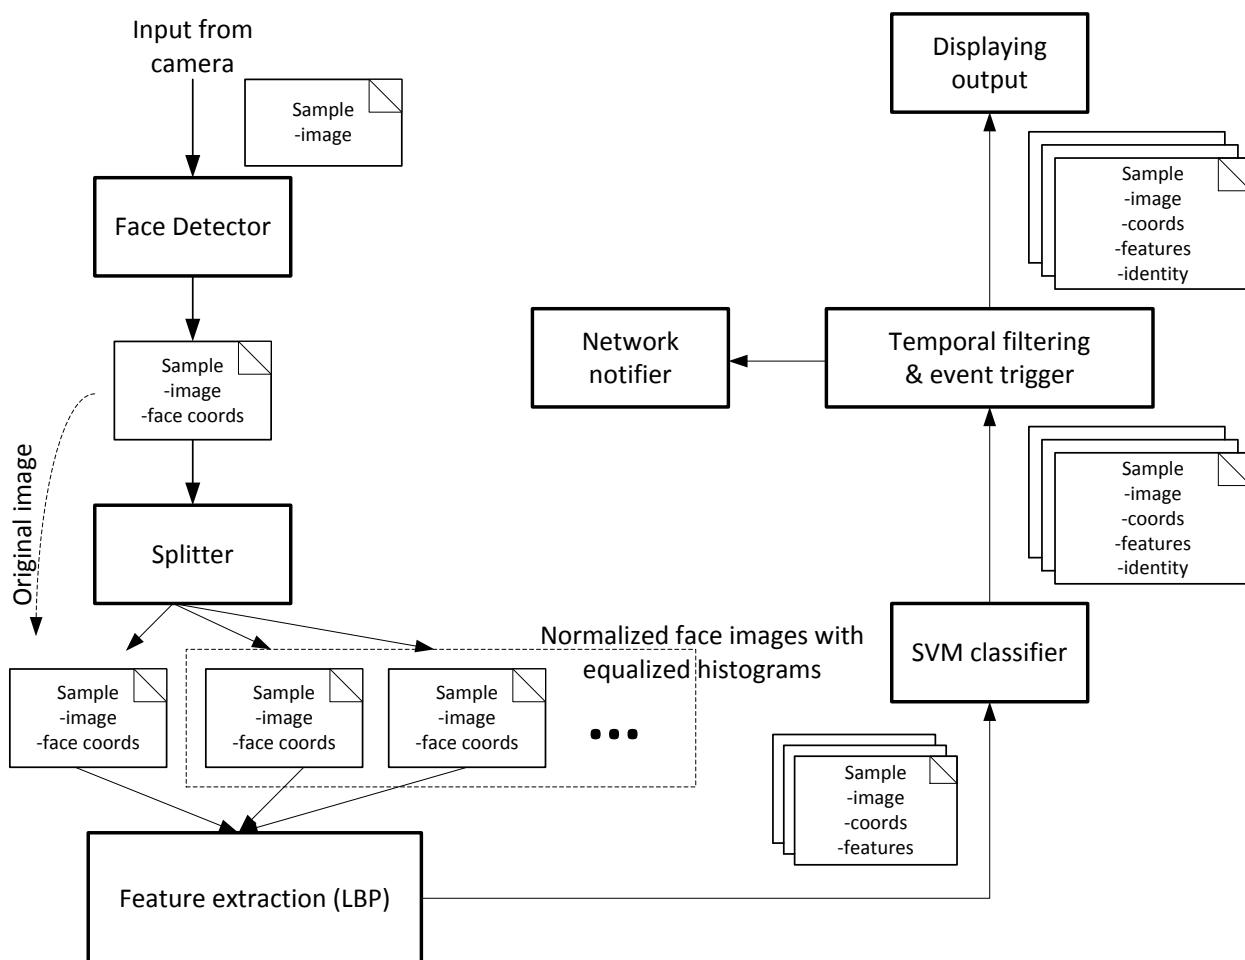
4.4 System na rozpoznávanie ľudských tvárí

Významnú časť nášho vedeckého úsilia venujeme projektu európskeho siedmeho rámcového programu HBB-Next (Hybrid Broadcast Broadband Next Generation, <http://www.hbb-next.eu/>), ktorý sa zaoberá problematikou inteligentnej (smart) televízie novej generácie. V rámci tohto vedeckého projektu participujeme na návrhu a realizácii systému rozpoznávania ľudských tvárí, ktorý je súčasťou modulu multimodálneho rozhrania. Multimodálne rozhranie, v rámci HBB-next systému, má primárne slúžiť na interakciu zariadenia s užívateľom. Obsahuje viacero podsystémov, ktoré na základe využitia rôznych modalít dokážu rozpoznávať identitu používateľa, či ovládať samotný systém. Patria sem aplikácie pre rozpoznávanie reči, rozpoznávanie gest, rozpoznávanie dúhovky a rozpoznávanie tvárí. Jednotlivé aplikácie by mali byť schopné medzi sebou komunikovať. Vďaka zapojeniu viacerých modalít (reč, dúhovka, tvár) do rozpoznávacieho procesu sme schopní docieľiť presnejšiu identifikáciu užívateľa, ktorá by sa dala využiť na prístup k citlivejším údajom. Na interakciu medzi užívateľom a multimodálnym rozhraním používame jednotné zariadenie Kinect (<http://www.microsoft.com/en-us/kinectforwindows/>). Toto multifunkčné zariadenie obsahuje vhodné senzory pre uvedené aplikácie – mikrofón, RGB kamera a hĺbková 3D kamera.


Ako sme už spomenuli, našim cieľom je návrh a realizácia modulu pre rozpoznávanie tvárí. Keďže ide o komplexný systém, v ktorom riešime úlohy rozpoznávania vo všetkých úrovniach, vo veľkej miere využívame poznatky nadobudnuté z doterajšieho výskumu v danej oblasti. HBB-Next projekt presne definuje zoznam požiadaviek, ktoré systém musí spĺňať. Dokument (Vanattenhoven a kol., 2012) obsahuje všetky HBB-Next požiadavky týkajúce sa systému, služieb a užívateľa, vrátane prehľadu vhodných technológií a štandardov, ktoré môžu byť využité pri navrhovaní a realizácii HBB-NEXT systému a jeho aplikácii. Základná požiadavka týkajúca sa systému rozpoznávania tvárí je nasledovná: HBB-Next systém musí vedieť identifikovať užívateľa v miestnosti s dobrými svetelnými

podmienkami a mal by dokázať rozpoznať užívateľa aj v zhoršených svetelných podmienkach. Ďalšou požiadavkou, ktorá vyplýva z celého konceptu takéhoto systému, je rozpoznávanie v reálnom čase, resp. blízke reálnemu času. Pri návrhu predpokladáme obmedzený počet užívateľov jedného systému, keďže ide o zariadenie primárne určené do domácností. Aj keď rozpoznávacie algoritmy dokážu pracovať s menším počtom používateľov relatívne dobre, problémom môže byť podobnosť charakteristických čŕt užívateľov, keďže vo väčšine prípadov pôjde o členov rodiny. Rozpoznávanie by malo prebiehať opakovane, v krátkych časových intervaloch, pokiaľ sa daný užívateľ bude vyskytovať na scéne pred snímacím zariadením. Výstup systému, resp. rozpoznaná identita má byť posielaná vo forme XML súboru na HBB-Next server, kde bude táto identita použitá napr. na spúšťanie rôznych udalostí. Na základe uvedených požiadaviek sme doteraz navrhli a zrealizovali nosnú časť systému pre rozpoznávanie tvárí. Architektúru súčasnej implementácie nášho systému môžeme rozdeliť do nasledujúcich blokov: Vstupný blok, Lokalizácia tváre, Predspracovanie, Extrakcia príznakov, Rozhodovací blok (klasifikácia), Sledovanie tváre, Temporálne filtrovanie a Výstupný blok.

Spustením rozpoznávacieho systému sa aktivuje kamera a spustia sa algoritmy pre detekciu tvárí. Po úspešnej lokalizácii tváre sa spustí celý rozpoznávací proces. Ten sa opakuje v cykle, v krátkych časových intervaloch, v závislosti od diania na scéne pred snímacím zariadením. V prípade, že užívateľ opustí scénu, systém odošle túto informáciu na HBB-Next server a opäť spustí algoritmy na detekciu tvárí. Celý navrhnutý proces rozpoznávania tvárí pre HBB-Next projekt je znázornený na Obr. 4. V súčasnej implementácii dokážeme v reálnom čase rozpoznávať dvoch užívateľov, ktorí sa súčasne nachádzajú pred snímacím zariadením. Na Obr. 5 je znázornený príklad obrazového výstupu našej súčasnej implementácie s dvoma rozpoznávanými užívateľmi s aktívnym sledovaním tváre.



Obr. 4 Navrhnutý proces rozpoznávania tvárí v rámci implementácie pre HBB-Next projekt



Obr. 5 Príklad obrazového výstupu našej súčasnej implementácie v rámci HBB-Next projektu

Z vedeckého hľadiska, v rámci HBB-Next projektu jednak aplikujeme a využívame vedecké poznatky nadobudnuté z doterajšieho výskumu, ale aj navrhujeme a implementujeme nové prístupy pre celkovú funkčnosť komplexného systému na rozpoznávanie tvárí.

5 Sumarizácia publikovaných prínosov

5.1 Extrakcia príznakov a klasifikácia

Z dosiahnutých výsledkov v práci (Ban, Féder, Oravec a Pavlovičová, 2011/a) som navrhol a zrealizoval postupy HLO a INDEX obrazov v spojení s klasifikačnými metódami MLP a RBF. Navrhnutým postupom HLO a INDEX obrazov s metódou RBF som dosiahol výrazné zvýšenie presnosti rozpoznávania pre tréningové množiny bez vzoriek modifikovaných šumom, v porovnaní s použitím priamej klasifikácie (v prípade tréningovej množiny $a_{11}+111n$ a použitia INDEX obrazov dokonca zvýšenie presnosti rozpoznávania o viac ako 45%, Obr. 2). Podobne s navrhnutým postupom, ktorý využíva metódou MLP som dosiahol zvýšenie presnosti rozpoznávania pri použití tréningovej množiny $a_{11}+112+113+111n$. Navrhnutým postupom sa tiež podarilo znížiť celkovú výpočtovú a časovú náročnosť celého rozpoznávacieho procesu a to konkrétne z 8 bit/pixel na 0.5 bit/pixel.

5.2 Problém jednej vzorky

V prácach venovaných problému jednej vzorky (Oravec a kol., 2011; Ban, Féder, Oravec a Pavlovičová, 2011/b) som postupne navrhol viacero postupov na generovanie nových syntetických vzoriek, ako možné riešenia tohto problému. Ako prvý a zároveň najjednoduchší spôsob generovania nových vzoriek som navrhol modifikáciu originálnej vzorky pomocou šumu. Použil som Gaussov šum s rôznymi hodnotami variancie (intenzity). Takto generované nové vzorky som pridal do tréningovej množiny k originálnej vzorke. Z dosiahnutých výsledkov môžeme konštatovať, že navrhnutý postup generovania nových vzoriek pomocou modifikácie originálnej vzorky Gaussovým šumom, výrazne zvyšuje úspešnosť rozpoznávania metód MLP, RBF a SVM (v niektorých prípadoch o 10 až 15% v porovnaní s použitím iba jednej originálnej vzorky). Pre ešte výraznejšie zvýšenie úspešnosti rozpoznávania a v snahe viac sa priblížiť úspešnosti s viacerými originálnymi vzorkami som navrhol ďalší postup na generovanie nových vzoriek - modifikáciou originálnej vzorky pomocou waveletovej transformácie. Originálnu vzorku som modifikoval pomocou dvoch druhov waveletov – Haar a

Reverse biorthogonal wavelet tak, aby produkcia nových vzoriek bola s jemnou zmenou výrazu tváre. Takto navrhnutým postupom som dosiahol v niektorých prípadoch zvýšenie úspešnosti o viac ako 10% a dosiahol som výsledky porovnateľné ako pri použití tréningových množín s dvoma originálnymi obrazmi.

5.3 Rozpoznávanie tváří v neriadených podmienkach

V tejto oblasti nášho výskumu som sa zameril na viaceré aspekty rozpoznávania tváří v neriadených (reálnych) podmienkach. V práci (Ban, Pavlovičová, Féder, Omelina a Oravec, 2012) sme sa zamerali hlavne na dva významné aspekty, a to natočenie tváre subjektu a nerovnomerné osvetlenie. Pri takýchto podmienkach som analyzoval využitie metód RBF a SVM. Na základe dosiahnutých výsledkov môžem zhodnotiť, že metóda RBF, pri použití navrhnutého postupu s ekvalizáciou histogramu (pre jednoduchú elimináciu rôznych svetelných podmienok), dosiahla najlepšie výsledky rozpoznávania. Avšak pre použitie v reálnych podmienkach nie je vhodná z hľadiska časovej náročnosti, keďže dosahovala tréningový čas 418,48 sekúnd a čas rozpoznania tváre až 33,72 sekúnd. Ako najvhodnejšia metóda v mojich postupoch, sa pre použitie v neriadených podmienkach ukázala metóda SVM. Tá, pri použití navrhnutého postupu s ekvalizáciou histogramu, dosahovala úspešnosť rozpoznávania okolo 90% a čas rozpoznávania 5,8 sekúnd. Ďalším aspektom reálnych podmienok je zaiste prenos cez chybový komunikačný kanál. Tejto problematike sa venujeme v práci (Ban, Pavlovičová, Féder, Omelina a Oravec, 2012). Ako simuláciu takéhoto prostredia, som navrhol náhodne vkladanie čiernych blokov do jednotlivých vzoriek (obrazov). Dosiahnuté výsledky vybraných metód (SVM, RBF, PCA a KPCA), na takto poškodených vzorkách, som porovnal s výsledkami na originálnych vzorkách. Na základe tohto porovnania som prišiel k záveru, že použité metódy dosahujú na poškodených vzorkách porovnateľné výsledky, ako v prípade s originálnymi, nepoškodenými vzorkami aj bez použitia rôznych techník pre obnovu dát, ktoré by negatívne ovplyvňovali výpočtovú a časovú náročnosť celkového rozpoznávania. Posledným aspektom neriadených podmienok, ktorému sme sa bližšie venovali, bolo prekrytie vzoriek a poškodenie šumom (Ban, Féder, Oravec, Omelina a Pavlovičová, 2013). V práci prezentujeme rozsiahle porovnanie vybraných metód – SVM, RBF, PCA, KPCA a GDA, na vzorkách modifikovaných rôznymi prekrytiami a poškodenými rozličným šumom. V tejto oblasti som sa zameriaval na analýzu vplyvu prekrytia očí, obočia, nosa a tiež poškodenie vzoriek Gaussovým šumom na celkovú úspešnosť rozpoznávania tváří. Na základe dosiahnutých výsledkov a mojich analýz môžem sformulovať viacero záverov: v niektorých prípadoch prítomnosť šumu (s nízkou intenzitou $\sim 0,05$) vo vzorkách dokáže mierne zvýšiť presnosť rozpoznávania v porovnaní s použitím originálnych vzoriek (hlavne pre metódy PCA a KPCA). Ďalšou zaujímavosťou je, že zakrytie obočia spôsobovalo výraznejší pokles úspešnosti použitých metód rozpoznávania ako zakrytie očí. Podobné zistenie prezentujú autori v práci (Sadr a kol., 2003), avšak na základe ľudského vnímania. Môžem teda zhodnotiť, že oblasť obočia má vyššiu informačnú hodnotu, ako samotné oči, aj pre metódy strojového učenia používané na rozpoznávanie tváří.

5.4 Systém na rozpoznávanie ľudských tváří

V rámci participácie na európskom siedmom rámcovom programe HBB-Next, sa venujeme návrhu a realizácii systému rozpoznávania ľudských tváří. V návrhu a realizácii systému pre rozpoznávanie ľudských tváří sme vo veľkej miere využívali poznatky nadobudnuté z doterajšieho výskumu v oblasti rozpoznávania ľudských tváří. V nasledujúcej časti spomeniem hlavné časti výskumu, návrhu a samotnej realizácie, na ktorých som sa vo veľkej miere podieľal. Z pohľadu architektúry ide hlavne o tieto bloky: Vstupný blok – Návrh a realizácia snímania scény pred kamerou pomocou zariadenia Kinect. Načítanie snímok a konverzia do systémového formátu. Predspracovanie – Normalizácia vzoriek s detegovanou tvárou – orezanie tváre, aplikácia ekvalizácie histogramu a uloženie normalizovaných vzoriek do súborového systému.

Extrakcia príznakov – Návrh postupu na rýchlu a presnú extrakciu príznakov. Na základe doterajšieho výskumu v oblasti rozpoznávania tváří sme pre účely HBB-Next projektu navrhli postup extrakcie príznakov s využitím metódy LBP.

Rozhodovací blok (klasifikácia) – Podobne ako pri extrakcii príznakov sme na základe doterajšieho výskumu navrhli postup pre klasifikáciu extrahovaných príznakov s využitím SVM klasifikátora. Hlavnou nevýhodou tejto metódy je časovo náročné trénovanie modelu, keď sa používa veľké množstvo vzoriek. Aby sme minimalizovali časovú náročnosť, používame v trénovanom procese 6 vzoriek na osobu. Výstupom tohto bloku je identita užívateľa s percentuálnou úspešnosťou rozpoznávania.

Ďalšou časťou, na ktorej som sa vo veľkej miere podieľal je trénovací proces. Výsledné rozpoznanie je priamo závislé od vhodného natrénovania systému. Pri návrhu trénovacieho procesu sa snažíme zohľadniť možné vplyvy v neriadených podmienkach. Najdôležitejším a zároveň najzložitejším krokom trénovacieho procesu je výber vhodných vzoriek. V práci (Ban, Féder, Jirka, Loderer, Omelina, Oravec a Pavlovičová, 2013) analyzujeme dopad vybraných zhukovacích algoritmov (K-means, SOM a DBSCAN) pre automatický výber vhodných trénovacích vzoriek. Z dosiahnutých výsledkov môžeme zhodnotiť, že pre našu implementáciu automatického trénovanie a výberu vzoriek sú najvodnejšie prístupy využívajúce zhukovacie algoritmy K-means a SOM.

6 Zhodnotenie

Nosnou časťou práce je prezentácia publikovaných výsledkov, ktoré nadväzujú na analýzu opísaných oblastí problematiky rozpoznávania ľudských tvárí. V časti venovanej extrakcii príznakov predstavujeme dva navrhnuté postupy HLO a INDEX obrazy, ktoré v porovnaní s priamou klasifikáciou dosahujú výrazný pokles časovej a výpočtovej náročnosti pri zachovaní porovnateľných, v niektorých prípadoch až lepšie výsledky. Ďalšou oblasťou nášho vedeckého úsilia je rozpoznávanie na základe jednej vzorky. Tu prezentujeme navrhnuté postupy generovania nových vzorov na základe modifikácie originálnej vzorky pomocou šumu, waveletovej transformácie, geometrickej transformácie a dolnopriepustného filtra. V experimentálnych výsledkoch dokazujeme, že nami navrhnutými postupmi dosahujeme značné zvýšenie úspešností rozpoznávania v porovnaní s použitím jednej vzorky. V práci sa tiež venujeme rozpoznávaniu tvárí v rôznych neriadených podmienkach. Analyzujeme vplyv reálneho prostredia na úspešnosť rozpoznávania. V experimentálnych výsledkoch porovnávame dopad meniaceho sa osvetlenia, rôzneho natočenia a meniaceho sa výrazu tváre, ale aj rozličné poškodenia vzoriek, na vybrané algoritmy rozpoznávania tvárí. Zaujímavým záverom vyplývajúci z dosiahnutých výsledkov je, že obočie ma vyššiu informačnú hodnotu pre metódy strojového učenia ako samotné oči. Veľkú časť nášho vedeckého úsilia venujeme návrhu a realizácii komplexného systému pre rozpoznávanie ľudských tvárí v rámci európskeho siedmeho rámcového programu HBB-Next (Hybrid Broadcast Broadband Next Generation), ktorý sa zaoberá problematikou inteligentnej (smart) televízie novej generácie.

Dosiahnuté výsledky dizertačnej práce sa môžu ďalej uplatniť ako vhodné podklady pre návrh a realizáciu systému rozpoznávania tvárí napr. pre multimediálne zariadenie. Taktiež sa môžu uplatniť pre ďalší výskum a vedeckú prácu. Výskum v tejto oblasti sa stále snaží dosahovať čo najvyššie úspešnosti v rôzne upravených laboratórnych podmienkach. Ako bolo už aj v práci spomenuté, mal by sa ďalej uberať smerom rozpoznávania v reálnych podmienkach tak, aby aj takáto forma autentifikácie mala čoraz viac možností reálneho využitia.

7 Účasť autora v projektoch

HBB-Next: Hybrid Broadcast Broadband Next Generation FP7-ICT-2011-7-287848.

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

VEGA 1/0961/11 Pokročilé algoritmy spracovania obrazov na efektívne vyhľadávanie a kódovanie ľudských tvárí.

VEGA 1/0529/13 Návrh pokročilých metód biometrického rozpoznávania na základe obrazov tváre a dúhovky.

Grant Nadácie Tatra Banky: BioDaT - Biometrické rozpoznávanie na základe obrazov Dúhovky a Tváre, 2013.

8 Publikácie autora

Ban, J., Féder, M., Oravec, M. (2009). Biometrické metódy pre rozpoznávanie obrazov ľudských tvárí. ŠVOČ 2009 : Študentská vedecká a odborná činnosť. Zborník víťazných prác. Bratislava, Slovak Republic, ISBN 978-80-227-3094-5.

Ban, J., Féder, M. a Oravec, M. (2009). Experiments with Selected Machine Learning Methods for Biometric Face Recognition. Proceedings Redžúr 2009: 3rd International Workshop on Speech and Signal Processing. Bratislava, Slovak Republic, pp. 28-33. ISBN 978-80-227-3137-9.

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

Ban, J., Féder, M., Oravec, M. a Pavlovičová, J. (2011/a). 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, pp. 75-90. <http://old.bmf.hu/journal/Ban_Feder_Oravec_Pavlovicova_30.pdf>.

Ban, J., Féder, M., Oravec, M., Pavlovičová, J. (2011/b) 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.

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

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

Ban, J., Pavlovičová, J., Féder, M., Omelina, L., Oravec, M. (2012). Face Recognition Methods for Multimodal Interface, Proc. of 2012 5th Joint IFIP Wireless and Mobile Networking Conference WMNC 2012, ISBN: 978-1-4673-2994-1, 19.-20. sept. 2012, Bratislava, Slovakia, pp.110-113.

Ban, J., Pavlovičová, J., Féder, M., Omelina, L., Oravec, M. (2013). Face Recognition under Partial Occlusion and Noise, Proceedings Eurocon 2013, Zagreb, Croatia.

Oravec, M., Pavlovičová, J., Omelina, L., Féder, M., Ban, J., Mazanec, J., Valčo, M., Zelina, M. (2013). Metódy strojového učenia na extrakciu príznakov a rozpoznávanie vzorov. 2. diel : rozpoznávanie tvárí v biometrii. – vedecká monografia, 1. vyd. - Bratislava : FELIA, s.r.o., 2013. - 179 s. - ISBN 978-80-971512-0-1

Ban, J., Féder, M., Jirka, V., Loderer, M., Omelina, L., Oravec, M., Pavlovičová, J. (2013). An Automatic Training Process Using Clustering Algorithms for Face Recognition System. In:

9 Zoznam použitej literatúry

- Ahonen, T., Hadid, A., Pietikainen, M. (2004). Face recognition with local binary patterns, *Computer Vision-ECCV 2004*, vol. 3021, pp. 469–481.
- Ahonen, T., Hadid, A., Pietikainen, M. (2006). Face Description with Local Binary Patterns: Application to Face Recognition, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 28, No. 12, pp. 2037-2041.
- Anith, S., Vaithyanathan, D., Seshasayanan, R. (2013). Face recognition system based on feature extration, Information Communication and Embedded Systems (ICICES), 2013 International Conference, Chennai, pp. 660 – 664.
- Arlot, S., Celisse, A. (2010). A survey of cross-validation procedures for model selection, Source: *Statist. Surv.* Vol. 4, 40-79.
- Bajla, I., Soukup, D., Štolc, S. (2011). Occluded image object recognition using localized nonnegative matrix factorization methods. Chapter 6: „Object recognition“, Tam Phuong Cao, InTech open Access Publisher, Rijeka, pp. 83-106.
- Baudt, G., Anouar, F. (2000). Generalized Discriminant Analysis Using a Kernel Approach. *Neural Computation*, 2000.
- Baykara, M., Das, R. (2013). Real time face recognition and tracking system, Electronics, Computer and Computation (ICECCO), 2013 International Conference, Ankara, pp. 159 – 163.
- Belhumeur, P., Hespanha, J., Kriegman, D. (1997). Eigenfaces vs. Fisherfaces: recognition using class specific linear projection. *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 19, No. 7, pp. 711-720, 1997.
- Bhuiyan, A., Liu, C.H. (2007). On Face Recognition using Gabor Filters, *World Academy of Science, Engineering and Technology*, pp. 51-56.
- Bishop, C. M. (2007). *Pattern Recognition and Machine Learning*, Springer.
- Black, J., Gargesha, M., Kahol, K., Kuchi, P., Panchanathan, S. (2002). A framework for performance evaluation of face recognition algorithms, ITCOM, Internet Multimedia Systems II, Boston, July 2002.
- Brunelli, R., Poggio, T. (1993). Face recognition: features versus templates. *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 15, No. 10, pp. 1042-1062.
- Buciu, I., Gacsadi, A. (2011). Noise suppression methods for low quality images with application to face recognition, ELMAR, 2011 Proceedings, Zadar, p. 21 – 24.
- Cavalcanti, G. D. C., Filho, E. C. B. C. (2003). Eigenbands fusion for frontal face recognition, *Proceedings 2003 International Conference on Image Processing (Cat. No.03CH37429)*, IEEE, pp. I-665-8.
- Clyde, W. C. Jr. (2002). Human Bar Code: Monitoring Biometric Technologies in a Free Society, *Cato Policy Analysis*, č. 452, Dostupné na internete: <<http://www.cato.org/pubs/pas/pa-452es.html>>.
- Cootes, T. F., Cooper, D., Taylor, C.J., Graham J. (1995). Active Shape Models - Their Training and Application. *Computer Vision and Image Understanding*. Vol. 61, No. 1, pp. 38-59.
- Cootes, T. F., Taylor, C. J., Kang, H., Petrović, V. (2005). Modeling Facial Shape and Appearance. *Imaging Science and Biomedical Engineering*, University of Manchester, England, Handbook of Face recognition, chapter 3, pp.39-63, Springer.
- Dandpat, S.K., Meher, S. (2013). Performance improvement for face recognition using PCA and two-dimensional PCA, Computer Communication and Informatics (ICCCI), 2013 International Conference, pp. 1 – 5.
- Daugman, J. G. (1985). Uncertainty Relation for Resolution in Space, Spatial Frequency, and Orientation Optimized by Two-Dimensional Visual Cortical Filters, *Journal of Optical Society America A*, Vol. 2, No. 7, pp. 1160 - 1169.

- Dobrea, D.-M., Maxim, D., Ceparu, S. (2013). A face recognition system based on a Kinect sensor and Windows Azure cloud technology, *Signals, Circuits and Systems (ISSCS)*, 2013 International Symposium, Iasi, pp. 1 – 4.
- Ester, M., et al. (1996). A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise, In *Second International Conference on Knowledge Discovery and Data Mining*, ISSN 0975-8887, vol. 2, p. 226-231.
- FERET Database (2001). Available from: <<http://www.itl.nist.gov/iad/humanid/feret/>, NIST>.
- Gabor, D. (1946). Theory of communications, *Inst. Elect. Eng.*, Vol. 93, pp. 429–457.
- Gavriloaia, G., Gavriloaia, R. (2011). “Improving Quality of Medical Ultrasound Images by Filtering of Frames Sequences,” *E-Health and Bioengineering Conference (EHB)*, pp. 1-4, 24-26.
- Georghiades, A. S., Belhumeur, P. N., Kriegman, D. J. (2001). From Few to Many: Illumination Cone Models for Face Recognition under Variable Lighting and Pose, *IEEE Trans. Pattern Anal. Mach. Intelligence*, Vol. 23, No. 6, pp. 643-660.
- Gerstner, W., Germond, A., Hasler, M., Nicoud, J. D., Scholkopf, B., Smola, A., Muller, K. R. (1997). Kernel principal component analysis, *International Conference on Artificial Neural Networks — ICANN 97*, Berlin/Heidelberg: Springer-Verlag, pp. 583- 588.
- Guoxia S., Liangliang Z., Huiqiang S., (2011). Face recognition based on symmetrical weighted PCA, *Computer Science and Service System (CSSS)*, 2011 International Conference, ISBN: 978-1-4244-9762-1, pp.2249 – 2252.
- Han, W., Li, J., Sun, N. (2008). A Novel Fast Face Recognition Method of Two-Dimensional Principal Component Analysis Based on BP Neural Networks, *Computational Intelligence and Industrial Application*, Vol. 1, pp. 44-48.
- HBB-Next (Next-Generation Hybrid Broadcast Broadband), <http://www.hbb-next.eu>, project FP7-ICT-2011-7 – 287848.
- Howell, A. J., Buxton, H. (1996). Towards unconstrained face recognition from image sequences, In *Proceedings of the 2nd International Conference on Automatic Face and Gesture Recognition*, pp. 224-229.
- Hua, G., Yang, M., Learned-Miller, E., Ma, Y., Turk, M., Kriegman, D., Huang, T. (2001). Introduction to the Special Section on Real-World Face Recognition, *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol. 33, Nr. 10. p. 1921-1924.
- Chen, S. C., Zhang D. Q., Zhou Z. - H. (2004). Enhanced (PC)2A For Face Recognition With One Training Image Per Person. *Pattern Recognition Letters*, Vol. 25, No.10, pp. 1173-1181, ISSN: 0167-8655.
- Chengliang, W., Libin, L., Yuwei, Z., Minjie, G. (2011). Face Recognition Based on PrincipleComponent Analysis and Support Vector Machine, *Intelligent Systems and Applications (ISA)*, 2011.3rd International Workshop. ISBN: 978-1-4244-9855-0. Pp. 1 – 4.
- Introna, L. D., Nissenbaum, H. F. (2009). *Facial Recognition Technology: A Survey of Policy and Implementation Issues*. Center for Catastrophe Preparedness and Response, New York University. Available at SSRN: <http://ssrn.com/abstract=1437730>.
- Jafri, R., Arabnia H. R. (2009). A Survey of Face Recognition Techniques, *Journal of Information Processing Systems*, Vol.5, No.2, pp. 41-68.
- Jain, A. K., Ross, A., Prabhakar, A. (2004). An Introduction to Biometric Recognition. *IEEE Transactions on Circuits and Systems for Video Technology*, Special Issue on Image- and Video-Based Biometrics, Vol. 14, No. 1, pp. 4-20.
- Jemaa, B. Y., Khanfir, S. (2008). Automatic Gabor Features Extraction for Face Recognition using Neural Networks, *Image Processing Theory, Tools and Applications*, pp. 1-6.
- Jihua, Y., Dan, H., Guomiao, X., Yahui, C. (2013). An advanced BPNN face recognition based on curvelet transform and 2DPCA, *Computer Science & Education (ICCSE)*, 2013 8th International Conference, pp. 1019 - 1022.
- Kalal, Z., Mikolajczyk, K., Matas, J. (2011). *Tracking-Learning-Detection*, *Pattern Analysis and Machine Intelligence*.

- Kanan, H. R., Faez, K., (2010). Recognizing Faces Using Adaptively Weighted Sub-Gabor Array From a Single Sample Image Per Enrolled Subject, *Image and Vision Computing*, Vol. 28, No. 1, Jan. 2010, pp. 438–448, ISSN: 0262-8856.
- Kepenekci, B., Tek, F.B., Bozdagi G.A. (2002). Occluded Face Recognition based on Gabor Wavelets, *ICIP 2002*, Rochester, NY, MP-P3.10.
- Kohonen, T. (1982). Self-organizing formation of topologically correct feature maps, *Biological Cybernetics*, vol. 43, no. 1, pp.59–69.
- Kumar, A. P, Das, S., Kamakoti, V. (2004). Face recognition using weighted modular principle component analysis, in *Neural Information Processing*, Vol.3316, Lecture Notes In Computer Science: Springer Berlin / Heidelberg, pp.362-367.
- Kvasnička, V., Beňušková, Ľ., Pospíchal J., Farkaš, I., Tiňo, P., Kráľ, A. (1997). Úvod do teórie neurónových sietí. IRIS, Dostupné na internete: <<http://www2.fiit.stuba.sk/~cernans/nn/detailes.html>>.
- Le An, Kafai, M., Bhanu, B. (2013) Dynamic Bayesian Network for Unconstrained Face Recognition in Surveillance Camera Networks, *Emerging and Selected Topics in Circuits and Systems*, IEEE Journal, Vol. 3, No. 2, p. 155 – 164.
- Le, H. S., Li, H. (2004). Recognizing frontal face images using Hidden Markov models with one training image per person, *Proceedings of the 17th International Conference on Pattern Recognition(ICPR04)*, pp. 318 – 321.
- Len, B., Dat, T., Xu, H., Chetty, G. (2011). Face recognition based on Gabor features, *Visual Information Processing (EUVIP), 2011 3rd European Workshop*, ISBN: 978-1-4577-0072-9, pp. 264 – 268.
- Li, J., Zhao, B., Zhang, H., Jiao, J. (2009). Face Recognition System Using SVM Classifier and Feature Extraction by PCA and LDA Combination, *International Conference on Computational Intelligence and Software Engineering*, Wuhan: IEEE, pp. 1-4.
- MageshKumar, C., Thiyagarajan, R., Natarajan, S. P., Arulselvi, S., Sainarayanan, G. (2011). Gabor features and LDA based face recognition with ANN classifier, *Emerging Trends in Electrical and Computer Technology (ICETECT), 2011 International Conference*, ISBN: 978-1-4244-7923-8, pp. 831 – 836.
- Mahalanobis, P. (1936). On the generalised distance in statistics, *In Proceedings National Institute of Science*, India, vol. 2, pp. 49 - 55.
- Martinez, A.M. (2002). Recognizing imprecisely localized, partially occluded, and expression variant faces from a single sample per class. *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 25, No. 6, pp. 748-763.
- Meher, S.S., Maben, P. (2014). Face recognition and facial expression identification using PCA, *Advance Computing Conference (IACC), 2014 IEEE International*, pp. 1093 - 1098.
- MOBIO: Mobile Biometry FP7-2007-ICT-1, <http://www.mobioproject.org>, January 2008.
- Nazari, S., Moin, M.-S. (2013). Face recognition using global and local Gabor features, *Electrical Engineering (ICEE), 2013 21st Iranian Conference*, pp. 1 – 4.
- Nazeer, S. A. Omar, N., Khalid, M. (2007). Face Recognition System using Artificial Neural Networks Approach, *Signal Processing, Communications and Networking*, pp. 420-425.
- Nikan, S., Ahmadi, M. (2012). Human face recognition under occlusion using LBP and entropy weighted voting, *Pattern Recognition (ICPR), 2012 21st International Conference on Tsukuba*, p. 1699 – 1702.
- Ojala, T., Pietikainen, M., Maenpaa, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, pp. 971-987.
- Omelina, L., Oravec, M. (2011). Efficient Face Expression Generation for Face Recognition. In: *Proceedings ELMAR: 53rd International Symposium ELMAR-2011, 14-16 September 2011, Zadar, Croatia. - Zadar : Croatian Society Electronics in Marine, 2011. - ISBN 978-953-7044-12-1. - S. 29-32.*
- Oravec, M., Mazanec, J., Pavlovičová, J., Eiben, P., Lehocký, F. (2010). Face Recognition in Ideal and Noisy Conditions Using Support Vector Machines, PCA and LDA, *Face Recognition*, INTECH.

- Oravec, M., Pavlovičová, J., Mazanec, J., Omelina, L., Féder, M., Ban, J. (2011). Efficiency of Recognition Methods for Single Sample per Person Based Face Recognition. chapter in monograph *Reviews, Refinements and New Ideas in Face Recognition*. ISBN 978-953-307-368-2, IN-TECH, Croatia, pp. 181-206.
- Oravec, M., Polec, J., Marchevský, S. (1998). *Neurónové siete pre číslicové spracovanie signálov*, Bratislava.
- Pavlovičová, J., Oravec, M., Polec, J., Keleši, M., Mokoš, M. (2006). Error Concealment using Neural Networks for Block-Based Image Coding, *Radioengineering* ISSN 1210-2512, Vol.: 15, No. 2, Start page: 30.
- Phillips, P. J., Wechsler, H., Huang, J., Rauss, P. (1998). The FERET Database and Evaluation Procedure For Face Recognition Algorithms, *Image and Vision Computing*, Vol. 16, No. 5, pp. 295-306, ISSN: 0262-8856.
- Qiong, Y., Xiaoqing, D.(2002). Symmetrical PCA in face recognition, *International Conference on Image Processing 2002. Proceedings.*, IEEE, p. II-97-II-100.
- Que, D., Chen, B., Hu, J., Ax, Y. (2008). A Novel Single Training Sample Face Recognition Algorithm Based on Modular Weighted (2D)2 PCA, 9th Int. Conf. on Signal Processing, ICSP 2008, pp. 1552-1555, ISBN: 978-1-4244-2178-7.
- Ramanathan, N., Chellappa, R., Chowdhury, A. K. R. (2004). Facial similarity across age disguise illumination and pose. In *ICIP(2004)*, Vol. 3, pp. 1999-2002.
- Rashid, R.D., Jassim, S.A., Sellahewa, H. (2013) LBP based on multi wavelet sub-bands feature extraction used for face recognition, *Machine Learning for Signal Processing (MLSP)*, 2013 IEEE International Workshop, Southampton, pp. 1 – 6.
- Rayat, N., Walia, E. (2008). Face Recognition Using Improved Fast PCA Algorithm. In *2008 Congress on Image and Signal Processing, CISP 2008*, Vol. 1, pp.554 – 558, ISBN: 978-0-7695-3119-9.
- Raymond, H. C., Chung-Wa, H., Nikolova, M. (2005). Salt-and-Pepper Noise Removal by Median-Type Noise Detectors and Detail-Preserving Regularization, *IEEE Transactions on Image Processing*, Vol. 14, No. 10, pp. 1479-1485.
- Sadr, J., Jarudi, I., Sinha, P. (2003) The Role of Eyebrows in Face Recognition, *Perception*, vol. 32, pp. 285–293.
- Samaria, F., Harter, A. (1994). Parameterisation of a Stochastic Model for Human Face Identification. *Proceedings of 2nd IEEE Workshop on Applications of Computer Vision*, Sarasota FL.
- Sang-Heon, L., Myoung-Kyu, S., Dong-Ju, K., Byungmin, K., Hyunduk, K. (2013). Smart TV interaction system using face and hand gesture recognition, *Consumer Electronics (ICCE)*, 2013 IEEE International Conference, Las Vegas, pp. 173 – 174.
- Shan, S., Gao W., Zhao D. (2003). Face Identification Based On Face-Specific Subspace, *International Journal of Image and System Technology*, Vol. 13, No. 1, pp23-32.
- Shirazi, M. N., Noda, H., Sawai, H. (1997). A modular realization of adaptive PCA, *IEEE International Conference on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation*, Orlando, FL , USA : IEEE, , pp. 3053-3056.
- Scholkopf, B., Smola, A., Muller, K. R. (1999). Kernel Principal Component Analysis, *Advances in Kernel Methods – Support Vector Learning*. MIT press Cambridge MA. pp. 327-352.
- Sim T, Baker S, Bsat M (2002). The CMU Pose, Illumination, and Expression (PIE) database. *Automatic Face and Gesture Recognition*. pp. 46-51.
- Sinčák, P., Andrejková, G. (1996). *Neurónové siete Inžiniersky prístup* (1.diel).
- Singh, R., Om, H. (2013). An overview of face recognition in an unconstrained environment, *Image Information Processing (ICIIP)*, 2013 IEEE Second International Conference, Shimla, pp. 672 – 677.
- TABULA RASA: Trusted Biometrics under Spoofing Attacks, <http://www.tabularasa-euproject.org>, November 2010.
- Tan, K. R., Chen, S.(2005). Adaptively weighted sub-pattern PCA for face recognition, *Neurocomputing*, Vol.64, pp.505-511.
- Tan, P. N, Steinbach, M., Kumar, V. (2005). *Introduction to Data Mining*, Addison Wesley.

- Tan, X., Chen, S., Zhou, Z.-H., Zhang, F. (2006). Face recognition from a single image per person: A survey. *Pattern Recognition*, Vol. 39, No.9, pp. 1725-1745. ISSN:0031-3203.
- Tan, X., Liu, J., Chen, S. (2006). Recognition from a Single Sample per Person with Multiple SOM Fusion. In *ISNN (2)*, pp. 128-133.
- Tao, Z., Furao, S., Jinxi, Z. (2013). An incremental learning face recognition system for single sample per person, *Neural Networks (IJCNN)*, The 2013 International Joint Conference, Dallas, pp. 1 – 6.
- Thakur, S., Sing, J. K., Basu, D. K., Nasipuri, M., Kundu, M. (2008). Face Recognition Using Principal Component Analysis and RBF Neural Networks, *Emerging Trends in Engineering and Technology*, pp. 695-700.
- Truax, B. (1999). Gaussian Noise, In: *Handbook for Acoustic Ecology*, http://www.sfu.ca/sonic-studio/handbook/Gaussian_Noise.html Cambridge Street Publishing, 1999.
- Turk, M. (2001). A Random Walk through Eigenspace, *IEICE Transactions on Information and Systems*, Vol. E84-D, No. 12, pp. 1586-1595.
- Turk, M., Pentland, A. (1991). Eigenfaces for recognition, *Journal of Cognitive Neuroscience*, Vol. 3, No. 1, pp 71-86.
- Vanattenhoven, J., Renz, J., Stockleben, B. (2012). HBB-NEXT I D2.2 System-, Service-, and User Requirements, HBB-NEXT Consortium 2012, Available on <<http://www.hbb-next.eu/index.php/documents> >.
- Verschae, R., Ruiz-del-Solar, J., Correa, M. (2008). Face recognition in unconstrained environments: a comparative study, in *Proceedings of the Workshop on Faces in Real-Life Images: Detection, Alignment, and Recognition (ECCV '08)*, pp. 1–12, Marseille, France.
- Viola, P., Jones, M. (2001). *Robust Real-time Object Detection*, 2001, Vancouver, Canada.
- Wang, W. (2008). Face Recognition Based on Radial Basis Function Neural Networks, *Future Information Technology and Management Engineering*, pp. 41-44.
- Wen, G., Shiguang, S., Xiujuan, C., Xiaowei, F. (2003). Virtual face image generation for illumination and pose insensitive face recognition, *IEEE International Conference on Acoustics, Speech, and Signal Processing, 2003. Proceedings. (ICASSP '03)*, IEEE, 2003, pp. IV-776-9.
- Wiskott, L., Fellous, Kruger N., Malsburg C. (1997). Face Recognition by Elastic Bunch Graph Matching, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 19, No. 7, pp. 775-779.
- Xie, X., Lam, K.-M., (2006). Gabor-Based Kernel PCA With Doubly Nonlinear Mapping for Face Recognition With a Single Face Image. *IEEE Trans. on Image Processing*, Vol. 15, No. 9, ISSN: 1057-7149.
- Xu, A. H., Wang, F. L., Cai, Z. (2010). Improved Kernel Fisher nonlinear Discriminant Analysis Used in Face Identification, *Image and Signal Processing (CISP)*, 3rd International Congress, pp. 482-486.
- Xu, J., Yang, J. (2009) Local graph embedding discriminant analysis for face recognition, *Pattern Recognition CCPR 2009*, Chinese Conference on Nanjing, pp. 1 – 5.
- Yang, J., Zhang, D., Frangi, A. F., Yang, J.-yu. (2004). Two-dimensional PCA: a New Approach to Appearance-Based Face Representation And Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 26, No. 1, pp. 131-137, ISSN:0162-8828.
- Zhang, B., Shan, S., Chen, X., Gao, W.(2007). Histogram of Gabor phase patterns: a novel object representation approach for face recognition, *IEEE Trans. Image Process.*, Vol. 16, No. 1, pp. 57-68.
- Zhang, D., Zhou, Z. H., Chen, S.(2006). Diagonal principal component analysis for face recognition, *Pattern Recognition*, Vol.39, pp.140-142.
- Zhang, Y., Xue, Z. (2010). RBF Neural Network Application to Face Recognition, *Challenges in Environmental Science and Computer Engineering (CESCE)*, Vol. 2, pp. 381-384.
- Zhao, W., Chellappa, R., Phillips, P. J., Rosenfeld, A. (2003). Face recognition: A literature survey, *ACM Comput. Surv.* Vol. 35, No. 4, pp. 399-458, ISSN: 0360-0300, 2003.
- Zhou, S. K., Chellappa, R., Zhao, W. (2006). Unconstrained Face Recognition, *International Series on Biometrics*, Vol. 5, 2006.