

# Ocenjevanje kakovosti neporavnanih obraznih slik

Žiga Babnik, Vitomir Štruc

Univerza v Ljubljani, Fakulteta za Elektrotehniko, Tržaška cesta 25, 1000 Ljubljana, Slovenija  
{ziga.babnik, vitomir.struc}@fe.uni-lj.si

## Quality Assessment of Unaligned Face Images

*Recent Face Recognition (FR) approaches perform well when some quality guarantee can be made for input samples. In real-world applications, the acquired samples can often be of lower quality due to unknown issues during the acquisition process. As a result, many FR approaches struggle in unconstrained real-world scenarios. Consequently, Face Image Quality Assessment (FIQA) methods attempt to estimate the quality of input samples, in order to reject problematic low-quality samples prior to recognition. Well-performing FIQA methods rely on properly aligned input samples using a specific face detection algorithm. The performance of these methods decreases drastically when improperly aligned or even unaligned image samples are used. In this paper, we propose a novel approach that is able to improve the performance of any given FIQA technique for misaligned samples, while maintaining the overall performance of the technique. The approach uses Knowledge Distillation (KD) to train an alignment invariant quality regressor using a pre-trained FR model and a given FIQA technique. Evaluation of the proposed approach on the XQFW benchmark, using five state-of-the-art FIQA techniques and four state-of-the-art FR models, shows that our method improves performance on misaligned samples and maintains performance on properly aligned samples.*

## 1 Uvod

Sistemi za razpoznavanje obrazov (ang. Face Recognition – FR systems) delujejo izvrstno v situacijah, kjer je lahko natančno nadzorujemo pogoje zajema. V primerih mobilnih, ter raznih nadzornih in varnostnih sistemov, kjer se pogoji zajema lahko drastično spreminjajo imajo razpoznavalni sistemi pogosto težave. Nepredvidene težave pri zajemu vodijo do slikovnih (obraznih) vzorcev nizke kakovosti, ki vodijo do slabšega delovanja in napačnih napovedi sistemov za razpoznavanje.

Slabo delovanje razpoznavalnih sistemov na nizko kakovostnih vzorcih je pripeljalo do razvoja področje ocenjevanja kakovosti obraznih slik (ang. Face Image Quality Assessment – FIQA) ter kasneje do kakovostno-informiranega razpoznavanja obrazov (ang. Quality-Aware Face Recognition). Na področju razpoznavanja obrazov je pojem kakovosti definiran s tako imenovano biometrično

Podprto s strani ARRS programa mladih raziskovalcev.

uporabnostjo vzorca, ki meri uporabnost vzorca za nadaljnje razpoznavanje. Vključuje vizualno kakovost vzorca, ki jo določajo lastnosti kot so resolucija, osvetlitev ter zamegljenost, obrazne lastnosti, kot sta okluzija las ter očal, ter obrazna poza in pristranskosti obraznega razpoznavalnika na lastnosti kot so spol, rasa ter starost osebe.

Za pravilno delovanje metod za ocenjevanje kakovosti obraznih slik je potrebno obrazne vzorce pravilno poravnati. Poravnave se med pristopi razlikujejo, uporabljajo lahko različne obrazne detektorje, kot tudi postopke poravnave. Ocenjena kakovost je tako močno odvisna od pravilne poravnave vhodnega obraznega vzorca. Prav tako se v primeru nizko kakovostnih vzorcev poveča verjetnost napačne zaznave obrazov prisotnih na vhodnem vzorcu. Z razvojem metod za oceno kakovosti obraznih slik, ki so neodvisne od začetne poravnave vzorcev, bi povečali odpornost metod na variabilnost detektorjev ter zmanjšali število korakov potrebnih za zavrnitev neprimernih (nizko kakovostnih) vzorcev. V članku predstavimo preprost pristop nadgradnje obstoječih metod za oceno kakovosti obraznih slik, ki omogoča bolj robustno delovanje za neporavnane vhodne vzorce in hkrati ne kviri zmogljivosti pristopov za poravnane vzorce.

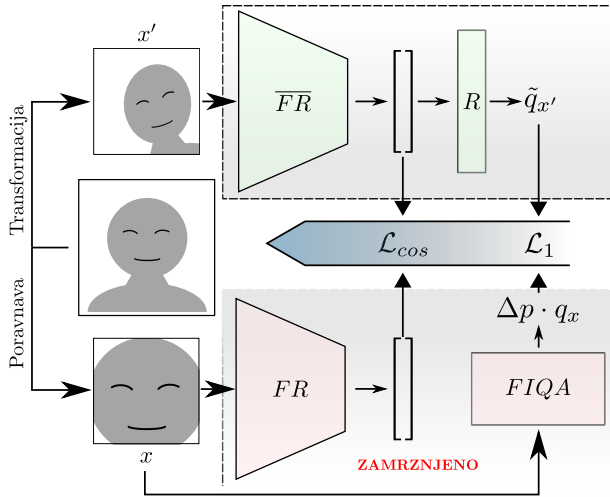
## 2 Pregled področja

V nadaljevanju predstavimo raziskovalno področje ocenjevanja kakovosti obraznih slik, ki ga sestavljajo *posredni pristopi* ocenjevanja kakovosti obraznih slik, ter *neposredni pristopi* kakovostno-informiranega razpoznavanja obrazov. Podrobnejši pregled omenjenega področja je predstavljen v preglednem članku [18].

### 2.1 Posredni pristopi

Posredni pristopi ocenjevanja kakovosti obraznih slik napovedo oceno kakovosti podanega obraznega vzorca. Napovedana kakovost je uporabna v času inferenc razpoznavalnih sistemov, vzorce, ki imajo ocenjeno kakovost pod kakovostnim pragom sistem zavrne oziroma, če je možno jih ponovno zajame. Področje posrednih metod lahko razdelimo v skupini: *analitičnih (nenadzorovanih)* ter *regresijskih (nadzorovanih)* pristopov.

**Analitični pristopi** ocenijo kakovost na podlagi informacije prisotne v obraznem vzorcu. Starejši pristopi se osredotočajo le na vizualno kakovost vzorcev in ne dosegajo vrhunskih rezultatov [10, 17, 15]. Novejši pristopi ovrednotijo kakovost na podlagi robustnosti predstavitve



Slika 1: **Pregled pristopa.** Na podlagi prednaučenega razpoznavalnika ( $FR$ ), podanega pristopa za oceno kakovosti obraznih slik ( $FIQA$ ) in podatkovne baze nepravilnih obraznih vzorcev, uporabimo postopek destilacije znanja za učenje robustnega regresorja kakovosti.

vzorcev v latentnem prostoru poljubnega obraznega razpoznavalnika. Pristop avtorjev Terhörst *et al.* [20] oceni robustnost s pomočjo izpusnih slojev, FaceQAN [1] s pomočjo nasprotniškega šuma ter DiffIQA [2] s pomočjo verjetnostnih difuzijskih modelov za razšumljanje.

**Regresijski pristopi** učijo regresijske modele za napovedovanje kakovosti na podlagi ustvarjenih psevdoreferenčnih oznak. Referenčne oznake največkrat ocenijo s pomočjo primerjave podobnosti vložitev parov obraznih slik. Zgodnji pristop Ortega *et al.* [11] primerja podobnosti vložitev najkakovostnejši sliki posameznika, pri čemer je ta določena z zunanjim orodjem. Naprednejši pristop SDD-FIQA [9] vključuje primerjavo večje količine pravih in prevarantskih parov. Chen *et al.* [6] predstavijo pristop, ki na podlagi nove funkcije izgube minimizira kompleksnost učenega regresorja.

## 2.2 Neposredni pristopi

Neposredni pristopi kakovostno-informiranega razpoznavanja obrazov vpeljejo informacijo o kakovosti vzorcev v učni postopek razpoznavalnih sistemov. Naučeni modeli so zmožni napovedovanja identitete kot tudi kakovosti obraznega vzorca, ter zagotavljajo bolj robustno delovanje za vzorce nižje kakovosti. Zgodnji primer avtorjev Shi in Jain [19] predstavi koncept obraznih predstavitev informiranih o lastni negotovosti (*ang. uncertainty-aware face representation*). Novejši pristop MagFace [16] vključi informacijo o kakovosti vzorcev v magnitudo predstavitev preko razširitve funkcije izgube. Podoben pristop predstavijo Minchul *et al.* [13], ki za oceno kakovosti uporabijo magnitudo vmesnih predstavitev vzorcev. Pristop CR-FIQA [4] oceni kakovost kot razmerje razdalj posameznega učnega vzorca, med pravim in najbližjim prevarantskim centrom.

## 3 Metodologija

Pristopi s področja ocenjevanja kakovosti obraznih slik, potrebujejo pravilno poravnane obrazne vzorce. Nepravilno poravnani vhodni vzorci znatno znižajo zmo-

gljivost pristopov za ocenjevanje kakovosti. V nadaljevanju predstavimo preprost postopek, ki razširi poljuben že obstoječ postopek ocenjevanja kakovosti obraznih slik. Razširjen pristop je do določene mere invarianten na poravnavo vhodnih vzorcev. Postopek vključuje destilacijo znanja pred naučenega obraznega razpoznavalnika ter metode za oceno kakovosti obraznih slik za učenje regresorja kakovosti na bazi nepravilnih slik, kot to prikazuje Slika 1. V nadaljevanju predstavimo postopek ustvarjanja učnih primerov ter samo destilacijo znanja.

### 3.1 Ustvarjanje učnih primerov

Regresijski model invarianten na poravnano vhodnih vzorcev za ocenjevanje kakovosti vzorcev, potrebuje za učenje naključno transformirane vzorce, ki posnemajo variabilnost vzorcev zajetih v resničnih situacijah. Za ustvarjanje naključno transformiranih učnih vzorcev imamo podan nepravilni vzorec  $x$ , njegovo kakovost  $q_x$  pridobljeno s pomočjo pristopa FIQA ter podatke o začetni točki (zgornji levi rob)  $(x_x, y_x)$ , višini  $h_x$  ter širini  $w_x$  očitanega okvirja (*ang. bounding box*) vzorca  $x$ . Obrazni vzorcev transformiramo, prvič s pomočjo rotacije okoli središča slike  $r(\cdot)$  za naključni kot  $\in [-\alpha, \alpha]$  stopinj, ter s pomočjo sredinskega obreza  $c(\cdot)$  z naključnim faktorjem  $\in [\beta_l, \beta_h]$ . V zadnjem koraku izvedemo še horizontalno zrcaljenje  $f(\cdot)$  vzorca z verjetnostjo  $p_f$ .

Naključno transformiran učni vzorec dobimo z zaporedno izvedbo predstavljenih funkcij  $x' = (f \circ c \circ r)(x)$ . Končni učni vzorec  $x'$  lahko vsebuje le del obraza prisotnega na začetnem vzorcu  $x$ , kar posledično vpliva na kakovost vzorca. Kakovost učnega vzorca  $x'$  izračunamo s pomočjo razmerja površin  $\Delta p$  očitanega okvirja vhodnega vzorca  $x$  ter učnega vzorca  $x'$

$$\Delta p = \frac{p'_{oo}}{p_{oo}}, \quad (1)$$

kjer je  $p_{oo} = h_x \cdot w_x$  površina očitanega okvirja vzorca  $x$  ter  $p'_{oo}$  površina očitanega okvirja prisotnega v vzorcu  $x'$ . Končna kakovost učnega vzorca je tako  $q_{x'} = \Delta p \cdot q_x$ . V primeru, da vzorec  $x'$  vsebuje celoten očitani okvir in posledično celoten obraz je njegova kakovost, kar enaka kakovosti vhodnega vzorca  $q_{x'} = q_x$ . V nasprotnem primeru je njegova kakovost sorazmerno manjša z deležem razmerja površin  $\Delta p$ .

### 3.2 Destilacija znanja

Postopek destilacije ustvari učno  $\bar{F}$  in zamrznjeno kopijo  $F$  danega obraznega razpoznavalnika. Zamrznjeno kopijo nato skupaj s podano metodo ocenjevanja kakovosti  $Q$  uporabimo za usmerjanje učenja učne kopije razpoznavalnika, ki jo razširimo z regresijsko glavo  $R$ .

Za posamezen učni primer podamo zamrznjenemu modelu  $F$  ter metodi  $Q$  pravilno poravnani vzorec  $x$  in tako pridobimo referenčno vložitev vzorca  $v_x = F(x)$  ter oceno kakovosti vzorca  $q_x = Q(x)$ . Za učni model  $\bar{F}$  ustvarimo s pomočjo postopka predstavljenega v poglavju 3.1 naključno transformiran vzorec  $x'$  ter njegovo referenčno oceno kakovosti  $q_{x'}$ . Za vzorec  $x'$  pridobimo vložitev  $v_{x'} = \bar{F}(x')$  ter napoved kakovosti  $\tilde{q}_{x'} = R(v_{x'})$  in ju uporabimo za izračun izgube. Uporabljeno funkcijo izgube sestavljata dve komponenti: izguba identitete ter iz-

guba kakovosti. Izguba identitete meri skladnost napovedane in dejanske identitete s pomočjo kosinusne razdalje  $\mathcal{L}_{cos}$  med referenčno  $v_x$  in napovedano  $v_{x'}$  vložitvijo, izguba kakovosti meri ujemanje napovedane in referenčne kakovosti s pomočjo absolutne razdalje  $\mathcal{L}_1$ . Končna funkcija izgube

$$L(x') = \frac{1}{2} \cdot \mathcal{L}_{cos}(v_x, v_{x'}) + \frac{1}{2} \cdot \mathcal{L}_1(q_{x'}, \tilde{q}_{x'}), \quad (2)$$

je povprečje obeh predstavljanih komponent.

Tabela 1: Primerjava pAUC vrednosti osnovnih pristopov (*Osnovna*) ter predlagane razširitve (*Razš.*) EDC krivulj na podatkovni bazi XQLFW. Boljši izmed primerjanih rezultatov je obarvan, najboljši rezultat posamezne metode je odebeljen.

FR	Metoda	$pAUC(\%) \uparrow \downarrow$ – Stopnja zavrnitev = 20%						XQLFW [14]			
		Dlib [12]		MTCNN [22]		RFaces [7]			XQLFW [14]		
		Osnovna	Razš.	Osnovna	Razš.	Osnovna	Razš.				
AdaFace [13]	CR-FIQA [4]	82.92	78.38	80.10	76.59	83.54	77.54	83.49	75.97	86.87	80.78
	DiffIQa(R) [2]	79.83	77.79	76.13	76.05	76.24	75.93	76.20	76.33	81.38	79.85
	FaceQAN [1]	91.95	78.26	78.58	76.82	80.73	77.83	76.74	78.70	96.15	78.40
	MagFace [16]	93.89	86.98	95.14	83.32	91.02	80.02	96.16	79.29	92.78	83.32
	SDD-FIQA [9]	88.51	88.60	91.59	84.10	89.45	81.51	91.11	80.93	92.15	82.44
ArcFace [8]	CR-FIQA [4]	83.48	<b>78.54</b>	78.67	79.07	79.97	79.79	79.93	78.84	84.98	81.02
	DiffIQa(R) [2]	82.84	80.06	77.91	81.38	77.55	79.25	77.57	79.41	80.85	82.75
	FaceQAN [1]	89.83	85.63	76.95	84.78	77.39	82.87	78.83	83.22	97.28	80.39
	MagFace [16]	95.38	84.36	90.50	82.07	88.99	80.04	96.13	79.82	99.33	85.01
	SDD-FIQA [9]	94.92	85.01	88.34	82.54	84.31	82.14	93.95	82.00	98.67	83.31
ElasticFace [3]	CR-FIQA [4]	90.03	90.16	89.57	89.64	90.17	93.29	88.46	<b>86.32</b>	93.88	93.61
	DiffIQa(R) [2]	90.06	85.55	89.38	<b>82.66</b>	93.42	83.86	93.20	86.23	87.68	86.60
	FaceQAN [1]	95.43	86.49	86.06	89.38	<b>79.04</b>	86.28	80.20	84.09	98.44	85.44
	MagFace [16]	97.70	88.14	95.61	90.06	96.94	<b>87.16</b>	97.60	90.02	99.53	87.92
	SDD-FIQA [9]	95.86	94.90	91.99	<b>84.26</b>	90.89	90.12	97.29	87.02	97.80	86.99
CosFace [21]	CR-FIQA [4]	77.34	72.67	72.92	71.40	77.47	71.02	77.31	<b>69.63</b>	82.10	74.50
	DiffIQa(R) [2]	73.69	70.60	71.36	71.60	70.60	<b>69.79</b>	70.73	70.56	79.60	71.12
	FaceQAN [1]	85.13	72.00	<b>71.23</b>	73.57	72.28	73.62	73.59	72.45	96.66	71.68
	MagFace [16]	95.00	74.66	92.55	76.95	90.86	<b>70.67</b>	96.25	70.78	98.90	75.80
	SDD-FIQA [9]	80.37	78.52	83.50	74.42	84.44	<b>72.06</b>	87.17	74.88	91.80	73.90

FR	Metoda	$pAUC(\%) \uparrow \downarrow$ – Stopnja zavrnitev = 30%						XQLFW [14]			
		Dlib [12]		MTCNN [22]		RFaces [7]			XQLFW [14]		
		Osnovna	Razš.	Osnovna	Razš.	Osnovna	Razš.				
AdaFace [13]	CR-FIQA [4]	73.04	66.85	<i>64.65</i>	65.20	69.73	65.56	68.67	<b>63.36</b>	79.48	68.72
	DiffIQa(R) [2]	69.88	65.11	<i>61.79</i>	62.32	<b>60.36</b>	64.35	61.98	62.99	72.79	68.12
	FaceQAN [1]	84.66	65.57	66.90	<b>64.37</b>	66.83	65.18	<i>64.46</i>	65.98	95.24	66.03
	MagFace [16]	88.62	84.48	88.92	79.28	87.98	<i>74.02</i>	91.82	<b>72.54</b>	91.29	78.77
	SDD-FIQA [9]	83.51	84.03	86.54	75.53	82.46	<b>71.12</b>	84.19	71.32	88.84	72.97
ArcFace [8]	CR-FIQA [4]	74.47	67.28	<i>67.15</i>	68.46	68.30	68.88	68.09	<b>67.04</b>	79.88	69.71
	DiffIQa(R) [2]	73.04	69.24	<i>64.99</i>	69.59	<b>64.55</b>	68.81	65.94	68.58	71.00	72.02
	FaceQAN [1]	82.10	72.81	<i>66.77</i>	71.15	<b>66.10</b>	70.15	68.02	70.73	94.24	68.80
	MagFace [16]	86.69	80.83	85.17	77.70	84.69	<i>71.24</i>	89.78	<b>73.50</b>	98.83	78.87
	SDD-FIQA [9]	91.07	78.95	81.45	73.01	76.07	<i>72.08</i>	83.17	<b>71.19</b>	97.62	72.47
ElasticFace [3]	CR-FIQA [4]	83.67	77.08	78.43	81.88	77.60	81.88	76.00	<b>69.97</b>	88.50	82.29
	DiffIQa(R) [2]	83.34	<b>71.24</b>	73.92	<i>71.61</i>	76.73	72.49	76.64	72.58	77.34	74.46
	FaceQAN [1]	92.49	73.96	76.02	75.30	<b>67.82</b>	72.57	72.30	<i>71.92</i>	97.11	76.26
	MagFace [16]	91.14	81.26	93.08	84.86	94.20	<b>80.22</b>	94.99	80.79	99.39	83.93
	SDD-FIQA [9]	93.26	92.25	84.02	<i>79.99</i>	81.50	83.55	93.87	<b>79.89</b>	96.72	80.84
CosFace [21]	CR-FIQA [4]	64.90	61.88	59.81	57.88	64.71	57.49	64.74	<b>56.33</b>	73.20	60.90
	DiffIQa(R) [2]	61.61	57.29	<i>56.01</i>	57.52	<b>55.04</b>	56.65	56.92	56.69	67.42	57.80
	FaceQAN [1]	74.94	57.88	58.48	58.84	57.74	59.02	61.05	58.43	92.81	<b>57.56</b>
	MagFace [16]	87.03	70.45	85.29	68.94	83.21	62.79	94.58	<b>61.96</b>	98.13	69.85
	SDD-FIQA [9]	73.14	71.93	73.22	64.34	74.23	<b>61.12</b>	76.97	63.20	88.47	62.10

<sup>1</sup> RFaces – detektor RetinaFace z MobileNet arhitekturo.

<sup>2</sup> RFaces – detektor RetinaFace z ResNet-50 arhitekturo.

Tabela 2: Primerjava povprečnih pAUC vrednosti preko vseh obraznih razpoznavalnikov in poravnanih obrazov osnovnih pristopov (*Osnova*) ter predlagane razširitve (*Razš.*) EDC krivulj pri stopnji zavrnitve 20% ter 30% na podatkovni bazi XQLFW. Boljši izmed primerjanih rezultatov je obarvan.

SZ	CR-FIQA		DiffIQa(R)		FaceQAN		MagFace		SDD-FIQA		
	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	
20%	Osnova	84.13 ± 6.25	81.27 ± 8.70	84.99 ± 9.68	94.50 ± 3.23	89.30 ± 4.88	80.66 ± 8.60	78.87 ± 7.95	78.76 ± 5.49	81.92 ± 6.89	81.69 ± 6.65
	Razš.	80.66 ± 8.60	78.87 ± 7.95	78.76 ± 5.49	81.92 ± 6.89	81.69 ± 6.65					
30%	Osnova	73.10 ± 8.36	68.37 ± 9.89	75.89 ± 13.70	90.35 ± 4.72	82.98 ± 7.14	68.18 ± 9.21	65.56 ± 8.28	65.72 ± 6.71	75.95 ± 7.74	73.43 ± 8.88
	Razš.	68.18 ± 9.21	65.56 ± 8.28	65.72 ± 6.71	75.95 ± 7.74	73.43 ± 8.88					

<sup>1</sup> SZ – Stopnja zavrnitev

## 4 Eksperimenti in rezultati

**Izbrane metode.** Za analizo vpliva poravnanih vzorcev smo izbrali tri raznolike postopke za detekcijo obrazov: dlib [12], MTCNN [22] ter RetinaFace [7], v primeru metode RetinaFace uporabimo dve različni implementaciji, ki temeljita na arhitekturah MobileNet ter ResNet50. Ovrednotili smo štiri vrhunske pristope ocenjevanja kakovosti obraznih slik: CR-FIQA [4], DiffIQa(R) [2], FaceQAN [1], MagFace [16] ter SDD-FIQA [9]. Za potrebe učenja predstavljenega pristopa smo uporabili podatkovni nabor VGGFace2 [5], za samo ovrednotenje nabor XQLFW [14]. Rezultate smo ovrednotili s pomočjo

štiri vrhunskih ciljnih obraznih razpoznavalnikov: AdaFace [13], ArcFace [8], CosFace [21], ElasticFace [3].

**Ovrednotenje zmogljivosti.** Predstavljen pristop ovrednotimo s pomočjo delne površine pod krivuljo (pAUC) napak-proti-zavrnitvam (*ang. Error-versus-Discard Characteristic curves*). Omenjene krivulje prikažejo izboljšanje delovanja razpoznavalnega sistema, pri različnih deležih zavrnitev vzorcev najnižje kakovosti. V resničnih situacijah ne želimo zavrniti prevelike količine vhodnih podatkov, saj to negativno vpliva na delovanje sistema. Posledično nas zanima mera pAUC le za manjše deleže zavrnitev, najpogosteje 0.2 ter 0.3. Nižja vrednost pAUC nakazuje na boljše ocene kakovosti.

**Podrobnosti o implementaciji.** Za ustvarjanje ključnih transformacij smo izbrali sledeče vrednosti parametrov: za rotacijo  $\alpha = 40^\circ$ , za izreze  $\beta_l = 0.5$  in  $\beta_h = 1.5$  ter za verjetnost zrcaljenja  $p_f = 0.5$ . Učili smo prednaučen razpoznavalnik CosFace, ki dosega najboljše rezultate med izbranimi razpoznavalniki. Za učenje smo uporabili optimizacijski algoritem SGD s stopnjo učenja 0.1, ter eksponentnim razporedom stopnje učenja s faktorjem 0.999. Eksperimenti so bili izvedeni na namiznem računalniku z Intel i9-10900KF procesorjem, 64GB pomnilnika ter z Nvidia 3090 grafično kartico.

### 4.1 Ovrednotenje rezultatov

Tabela 1 prikazuje pAUC vrednosti za vse metode ocenjevanja kakovosti obraznih slik. Za posamezno metodo prikažemo rezultate osnovnega pristopa – *Osnova*, kot tudi rezultate pridobljene s predstavljenimi razširitvijo – *Razš.* Ovrednotenje smo izvedli za stopnji zavrnitev 20% ter 30%, ter v *navzkrižnem* in *prekrivajočem* scenariju. Navzkrižni scenarij uporablja različne modele za učenje in ovrednotenje, tj. v vseh primerih razen za CosFace model, prekrivajoči scenarij predpostavlja enake sisteme za učenje in ovrednotenje. Rezultati so prikazani za poravnave pridobljene z različnimi detektorji obrazov, kot tudi za same neporavnane slike – *XQLFW*.

**Navzkrižni scenarij.** Za metodi MagFace ter SDD-FIQA, lahko opazimo, da z uporabo razširitve delujeta mnogo bolje v vseh primerih razen v primeru uporabe detektorja Dlib z metodo SDD-FIQA. Pristop CR-FIQA deluje bolje z razširitvijo, ko uporabimo razpoznavalnika AdaFace ter ArcFace v primeru uporabe modela ElasticFace pripelje uporaba razširitve do slabših rezultatov. Razširjena pristopa FaceQAN ter DiffIQa(R) dosežeta boljše rezultate, ko uporabimo neporavnane slike oziroma detektor Dlib. V nasprotnem primeru so rezultati dobljeni z razširjeno metodo primerljivi v osnovnim pristopom, vendar ne dosegajo boljših rezultatov v vseh situacijah. Najboljše (odebeljene) rezultate doseže za vse ključne metode razen FaceQAN razširjen pristop.

**Prekrivajoči scenarij.** Rezultati razpoznavalnika CosFace se večinoma ne razlikujejo od rezultatov preostalih razpoznavalnih sistemov. Razširjeni pristopi metod SDD-FIQA, MagFace ter CR-FIQA dosežajo boljše rezultate kot osnovni pristopi za vse prikazane poravnave slik. Preostali metodi FaceQAN ter DiffIQa(R) dosežata z razširjenim pristopom slabše rezultate pri uporabi MTCNN detektorja ter izmenično pri uporabi različnih izvedenk RetinaFace detektorja. Podobno kot za preo-



stale obrazne razpoznavalnike doseže najboljše rezultate razširjen pristop vseh metod razen metode FaceQAN, dodatno še pri stopnji zavrnitev 30% za pristop DifFIQA(R).

Tabela 2 prikazuje povprečje ( $\mu$ ) ter standardni odklon ( $\sigma$ ) vrednosti pAUC izračunanih preko vseh uporabljenih obraznih razpoznavalnikov ter detektorjev obrazov, tako za osnovni pristop – *Osnova*, kot tudi za razširjen pristop – *Razš.*. Iz rezultatov je očitno, da razširjen pristop dosega v povprečju preko različnih poravnjav obrazov mnogo boljše rezultate od osnovnih pristopov, tako pri stopnji zavrnitve 20% kot tudi 30%.

## 5 Zaključek

V članku smo predstavili pristop, ki skuša izboljšati delovanje obstoječih metod za ocenjevanje kakovosti obraznih slik na nepravilno poravnanih obraznih vzorcih. Pristop s pomočjo destilacije znanja prednaučenega razpoznavalnika ter metode ocenjevanja kakovosti vzorcev uči regresor kakovosti na podlagi naključno transformiranih vhodnih vzorcev. Rezultati eksperimentov kažejo, da predstavljen pristop izboljša delovanje vseh vključenih metod za ocenjevanje kakovosti na nepravilno poravnanih vzorci ter ne pokvari delovanje metod na pravilno poravnanih podatkih.

## Literatura

- [1] Ž. Babnik, P. Peer, and V. Štruc. FaceQAN: Face Image Quality Assessment Through Adversarial Noise Exploration. In *Proceedings of the IAPR International Conference on Pattern Recognition (ICPR)*, 2022.
- [2] Ž. Babnik, P. Peer, and V. Štruc. DifFIQA: Face Image Quality Assessment Using Denoising Diffusion Probabilistic Models. In *Proceedings of the IEEE International Joint Conference on Biometrics (IJCB)*, 2023.
- [3] F. Boutros, N. Damer, F. Kirchbuchner, and A. Kuijper. ElasticFace: Elastic Margin Loss for Deep Face Recognition. In *Proceedings of the CVF/IEEE International Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, 2022.
- [4] F. Boutros, M. Fang, M. Klemm, B. Fu, and N. Damer. CR-FIQA: Face Image Quality Assessment by Learning Sample Relative Classifiability. In *Proceedings of the CVF/IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2023.
- [5] Q. Cao, L. Shen, W. Xie, O. M. Parkhi, and A. Zisserman. VGGFace2: A Dataset for Recognising Faces Across Pose and Age. In *Proceedings of the IEEE International Conference on Automatic Face & Gesture Recognition (FG)*, pages 67–74, 2018.
- [6] K. Chen, T. Yi, and Q. Lv. LightQNet: Lightweight Deep Face Quality Assessment for Risk-Controlled Face Recognition. *IEEE Signal Processing Letters*, 28, 2021.
- [7] J. Deng, J. Guo, E. Ververas, I. Kotsia, and S. Zafeiriou. RetinaFace: Single-Shot Multi-Level Face Localisation in the Wild. In *Proceedings of the CVF/IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 5203–5212, 2020.
- [8] J. Deng, J. Guo, N. Xue, and S. Zafeiriou. ArcFace: Additive Angular Margin Loss for Deep Face Recognition. In *Proceedings of the CVF/IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 4690–4699, 2019.
- [9] O. Fu-Zhao, X. Chen, R. Zhang, Y. Huang, S. Li, J. Li, Y. Li, L. Cao, and W. Yuan-Gen. SDD-FIQA: Unsupervised Face Image Quality Assessment with Similarity Distribution Distance. In *Proceedings of the CVF/IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2021.
- [10] X. Gao, S. Z. Li, R. Liu, and P. Zhang. Standardization of Face Image Sample Quality. In *Proceedings of the IEEE International Conference on Biometrics (ICB)*, pages 242–251. Springer, 2007.
- [11] J. Hernandez-Ortega, J. Galbally, J. Fierrez, R. Haraksim, and L. Beslay. FaceQnet: Quality Assessment for Face Recognition Based on Deep Learning. In *Proceedings of the IEEE International Conference on Biometrics (ICB)*, pages 1–8, 2019.
- [12] V. Kazemi and J. Sullivan. One Millisecond Face Alignment with an Ensemble of Regression Trees. In *Proceedings of the CVF/IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 1867–1874, 2014.
- [13] M. Kim, A. K. Jain, and X. Liu. AdaFace: Quality Adaptive Margin for Face Recognition. In *Proceedings of the CVF/IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 18750–18759, 2022.
- [14] M. Knoche, S. Hoermann, and G. Rigoll. Cross-Quality LFW: A Database for Analyzing Cross-Resolution Image Face Recognition in Unconstrained Environments. In *Proceedings of the IEEE International Conference on Automatic Face and Gesture Recognition (FG)*, pages 1–5, 2021.
- [15] Z. Lijun, S. Xiaohu, Y. Fei, D. Pingling, Z. Xiangdong, and S. Yu. Multi-Branch Face Quality Assessment for Face Recognition. In *Proceedings of the IEEE International Conference on Communication Technology (ICCT)*, pages 1659–1664, 2019.
- [16] Q. Meng, S. Zhao, Z. Huang, and F. Zhou. MagFace: A Universal Representation for Face Recognition and Quality Assessment. In *Proceedings of the CVF/IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 14225–14234, 2021.
- [17] R. Raghavendra, K. B. Raja, B. Yang, and C. Busch. Automatic Face Quality Assessment From Video Using Gray Level Co-Occurrence Matrix: An Empirical Study on Automatic Border Control System. In *Proceedings of the IAPR International Conference on Pattern Recognition (ICPR)*, pages 438–443, 2014.
- [18] T. Schlett, C. Rathgeb, O. Henniger, J. Galbally, J. Fierrez, and C. Busch. Face Image Quality Assessment: A Literature Survey. *ACM Computing Surveys*, 2022.
- [19] Y. Shi and A. K. Jain. Probabilistic Face Embeddings. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, pages 6902–6911, 2019.
- [20] P. Terhorst, J. N. Kolf, N. Damer, F. Kirchbuchner, and A. Kuijper. SER-FIQ: Unsupervised Estimation of Face Image Quality Based on Stochastic Embedding Robustness. In *Proceedings of the CVF/IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 5651–5660, 2020.
- [21] H. Wang, Y. Wang, Z. Zhou, X. Ji, D. Gong, J. Zhou, Z. Li, and W. Liu. CosFace: Large Margin Cosine Loss for Deep Face Recognition. In *Proceedings of the CVF/IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 5265–5274, 2018.
- [22] K. Zhang, Z. Zhang, Z. Li, and Y. Qiao. Joint Face Detection and Alignment using Multitask Cascaded Convolutional Networks. *IEEE Signal Processing Letters*, 23(10):1499–1503, 2016.