

# 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

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.

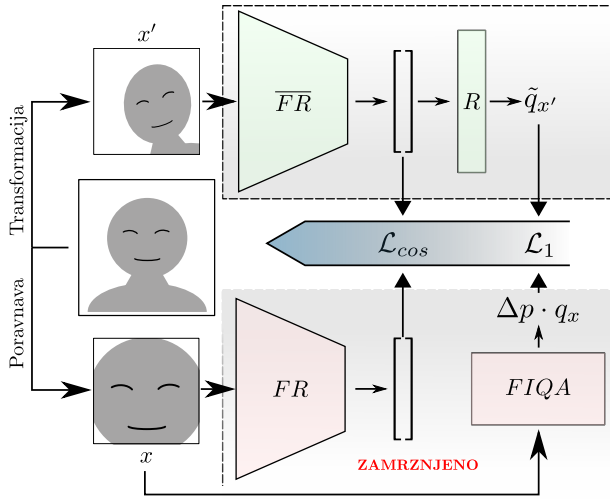
## 2 Pregled področja

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 inference 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 DiffFIQA [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  $w_x$  očiščanega 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  $\Delta p$  očiščanega 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 očiščanega okvirja vzorca  $x$  ter  $p'_{oo}$  površina očiščanega 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 očiščan 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  $\overline{F}$  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  $\overline{F}$  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  $v_{x'} = \overline{F}(x')$  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-



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 poravnanih 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.