

Delno nadzorovano ocenjevanje kakovosti 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

Semi-supervised face image quality assessment

Important security and surveillance applications often depend on reliable predictions from the underlying face recognition (FR) models. Due to the nature of such applications FR models have to perform well in various unconstrained conditions. While state-of-the-art FR models achieve excellent results on large and varied closed-set benchmarks, their performance depends heavily on the quality of the input face samples. Low-quality samples can cause critical false-match errors, lowering the trustworthiness of FR models, and furthermore lead to monetary or privacy issues. Face Image Quality Assessment (FIQA) techniques offer the FR model an estimate of the sample's quality, allowing the system to reject samples of poor quality. Supervised state-of-the-art FIQA techniques rely on extensive training to accurately assess the sample quality. Alternatively, unsupervised techniques extract the quality directly from the input sample, achieving higher runtime complexity and worse performance. In this paper, we present a technique for quality estimation, combining desired characteristics of both supervised and unsupervised methods. Our technique is able to quickly estimate the quality using a single forward pass of the sample through the model needed also for recognition, without any prior supervised training. Comprehensive experiments on a varied set of benchmark datasets and face recognition models show that our method outperforms all existing unsupervised techniques and performs similarly to current state-of-the-art supervised techniques, while achieving excellent runtime.

1 Uvod

Razpoznavanje obrazov (*ang. face recognition*) je razširjeno raziskovalno področje uporabno za varnostne in nadzorne sisteme, kontrolne sisteme (na mejnih prehodih in letališčih), v spletnem bančništvu ter raznih mobilnih aplikacijah. Zanesljivost razpoznavalnikov je v primeru mnogih aplikacij, kot so nadzorni in varnostni sistemi kritična. Na zanesljivost razpoznavalnikov močno vpliva kakovost vhodnih vzorcev, saj lahko nizkokakovostni vzorci sistem vodijo v napačno odločitev, kar ima lahko katastrofalne posledice. Metode za oceno kakovosti obraznih vzorcev (*ang. face image quality assessment techniques*) za obrazne vzorce ocenijo biometrično kakovost. Na podlagi ocene kakovosti lahko razpoznavalni


sistemi vzorce, ki ne dosegajo dovoljše kakovosti, zavrnejo in s tem izboljšajo svoje delovanje in zanesljivost.

Standard ISO/IEC 29794-1 določa pojem poenotene ocene kakovosti (*ang. unified quality score*), ki je definirana kot uporabnost obrazne slike (vzorca) za potrebe razpoznavanja. Povedano drugače je poenotena ocena kakovosti obratno sorazmerna z verjetnostjo, da podani vzorec sistem pripelje do napačne odločitve. Pristope s področja ocenjevanja kakovosti obraznih slik lahko razdelimo v dve skupini: (i) nadzorovane in (ii) nenadzorovane pristope. Nadzorovani pristopi [3, 4, 15, 17, 20] naučijo regresijsko mrežo na podlagi psevdo oznak kakovosti, pridobljenih iz primerjav slik v učni bazi. Nenadzorovani pristopi [1, 12, 19] ocene pridobijo neposredno iz vzorca oziroma iz odziva sistema na podani vzorec, vendar za to potrebujejo več prehodov ali celo več vzratnih širjenj vzorca skozi razpoznavalnik. Prednost nenadzorovanih metod je v njihovi prenosljivosti med različnimi razpoznavalniki. Za razliko od nadzorovanih metod ne potrebujejo nadzorovanega učenja regresijske mreže, vendar je njihova časovna zahtevnost ocenjevanja kakovosti v splošnem višja od nadzorovanih pristopov.

V članku predstavimo novo metodo za ocenjevanje kakovosti obraznih slik, ki združuje lastnosti nenadzorovanih in nadzorovanih pristopov. Metoda za razliko od nadzorovanih pristopov, ne potrebuje potratnega učenja regresijske mreže, hkrati uspe kakovost napovedati hitro, s pomočjo enega samega prehoda vzorca skozi razpoznavalnik. Kombinacijo lastnosti dosežemo s pomočjo preprostega delno nadzorovanega kalibracijskega postopka, ki v dani mreži poišče najuporabnejše sloje za potrebe ocenjevanja kakovosti. Kalibracijski postopek temelji na uporabi agregacijske funkcije ter kalibracijske množice slik. Agregacijska funkcija omogoča strnjevanje vmesnih predstavitev posameznih slojev mreže v oceno kakovosti. Z ocenjevanjem kakovosti celotnega kalibracijskega nabora lahko posamezne sloje mreže ovrednotimo s pomočjo standardnih eksperimentalnih protokolov.

2 Metodologija

Razpoznavalniki obrazov iz vzorcev poleg ključnih informacij glede identitete izločijo tudi attribute, ki za razpoznavanje niso potrebni, kot sta obrazna poza ter mimika [9] in kakovost vzorca [1, 17, 19]. Predlagan pristop prikazan na Sliki 1, temelji na izločanju informacije o kakovosti vzorca neposredno iz danega razpoznavalnika s pomočjo preprostega kalibracijskega postopka. Postopek se zanaša na kalibracijski nabor vzorcev ter agregacijo



Slika 1: **Pregled metode.** Pristop ovrednoti uporabnost vmesne predstavitev danega obraznega razpoznavnika, s pomočjo agregacijske funkcije $A(\cdot)$ ter kalibracijskih vzorcev $\{\hat{x}_i\}_{i=1}^N$. S pomočjo agregacijske funkcije $A(\cdot)$ iz izbrane vmesne predstavitev z_x^s pridobimo oceno kakovosti danega vzorca x . Ocene kakovosti kalibracijske baze uporabimo v postopku EDC analize preko P različnih verifikacijskih protokolov. Končno oceno uporabnosti sloja o^s pridobimo kot povprečno oceno preko vseh P protokolov. Uporabnost predstavlja delna površina pod EDC krivuljo, kjer nižji rezultat namiguje na večjo uporabnost sloja v namene ocenjevanja kakovosti.

cijsko funkcijo. Najprej s pomočjo kalibracijskega podatkovnega nabora določimo najkoristnejše vmesne predstavitve, za potrebe ocenjevanja kakovosti. Za pridobivanje ocen iz posameznih vmesnih predstavitev uporabimo agregacijsko funkcijo, ter EDC analizo za ovrednotenje pridobljenih ocen kakovosti. EDC analiza je standardni pristop za oceno pristopov FIQA, ki prikaže izboljšanje delovanja razpoznavnika s postopnim zavračanjem vzorcev nizke kakovosti, natančneje je opisana v Sekciji 3. Najkoristnejše vmesne predstavitve nato združimo v končno množico predstavitev. S pomočjo agregacijske funkcije in množice koristnih predstavitev lahko ocenimo kakovost poljubnega vzorca, tako da ga pošljemo skozi razpoznavnik, pridobimo vmesne predstavitve iz izbrane množice predstavitev, ter jih združimo s pomočjo agregacijske funkcije v končno oceno kakovosti.

2.1 Pregled pristopa

Za podan razpoznavnik obrazov R parameteriziran s $\{\phi^s\}_{s=1}^S$, sestavljen iz S slojev, je cilj pristopa pridobiti oceno kakovosti q_x poljubnega obraznega vzorca x iz informacije prisotne v mreži R . Pristop temelji na agregacijski funkciji $A(\cdot)$ ter množici vmesnih predstavitev $\mathcal{V}$. Naloga agregacijske funkcije $A(\cdot)$ je preslikava poljubne vmesne predstavitve z_x^s podanega vzorca x v sloju $s \in [1, S]$ v oceno kakovosti $q_x^s \in \mathbb{R}$. Množica $\mathcal{V}$ predstavlja vmesne predstavitve, izbrane za izračun končne ocene kakovosti vzorca q_x . Določimo jo s pomočjo kalibracijskega postopka, ki najprej preveri uporabnost posameznih vmesnih predstavitev, nato pa najboljše vmesne predstavitve združi v končno množico $\mathcal{V}$.

2.2 Inicializacija pristopa

Za pravilno delovanje potrebuje pristop agregacijsko funkcijo $A(\cdot)$ ter množico izbranih predstavitev $\mathcal{V}$.

Možnih funkcij, ki preslikajo poljubno vmesno predstavitev v oceno kakovosti je neskončno, zato jo določimo na podlagi znanja iz preteklih raziskav [10, 13, 15]. Izkaže se, da je norma predstavitev tesno povezana s kakovostjo vhodnih vzorcev. Dejstvo izhaja iz učnega postopka, kjer nastopa več vzorcev visoke kakovosti, posledično se naučeni filtri mreže odzovejo močneje pri vzorcih visoke kakovosti. Na podlagi predstavljenega dejstva za agregacijsko funkcijo uporabimo normo vmesnih predstavitev:

$$A(z_x^s) = \|f_{spl}(z_x^s)\|_F^2, \quad (1)$$

kjer $f_{spl} : \mathbb{R}^{d_1 \times \dots \times d_d} \rightarrow \mathbb{R}^{d_1 \times \dots \times d_d}$, splošči vmesno predstavitev v enodimenzionalen prostor, $\|\cdot\|_F^2$ predstavlja Frobeniusovo normo.

Množico vmesnih predstavitev $\mathcal{V}$ določimo s preprostim kalibracijskim postopkom, ki vključuje analizo uporabnosti vseh slojev (vmesni predstavitve) razpoznavnika. Podano imamo kalibracijsko množico obraznih vzorcev $\{\hat{x}_i\}_{i=1}^N$, s pomočjo katere najprej zgradimo P verifikacijskih protokolov $\{VP_p\}_{p=1}^P$. Množice pozitivnih (pravih) parov slik so med posameznimi protokoli disjunktne. Analiza posameznih slojev poteka tako, da za izbran sloj s zabeležimo vmesne predstavitve celotne kalibracijske baze $\{z_{\hat{x}_i}^s\}_{i=1}^N$. Nato s pomočjo agregacijske funkcije $A(\cdot)$ iz vmesnih predstavitev določimo ocene kakovosti sloja $\{q_{\hat{x}_i}^s\}_{i=1}^N = \{A(z_{\hat{x}_i}^s)\}_{i=1}^N$. Izračunane kakovosti sloja s uporabimo v EDC analizi preko vseh P verifikacijskih protokolov, in pridobimo P različnih ocen $\{o_p^s\}_{p=1}^P$. Ocena o_p^s predstavlja delno površino pod EDC krivuljo za verifikacijski protokol VP_p , kjer nižja vrednost namiguje na boljšo oceno. Končno oceno, ki ponazarja uporabnost sloja s za potrebe ocenjevanja kakovosti, pridobimo kot povprečje preko vseh P protokolov:

$$o^s = \frac{1}{P} \sum_{i=1}^P o_i^s. \quad (2)$$

Z analizo vseh slojev mreže R , pridobimo množico ocen posameznih vmesnih predstavitev $\{o^s\}_{s=1}^S$. Končno množico $\mathcal{V}$ sestavlja kombinacija vmesnih predstavitev, ki minimizira skupno oceno $o^{\mathcal{V}}$. Skupno oceno kakovosti določimo, tako da v EDC analizi uporabimo povprečno kakovost preko vseh vmesnih predstavitev vsebovanih v množici $\mathcal{V}$. Množico $\mathcal{V}$ gradimo s pomočjo požrešnega algoritma, ki izbira med m najboljšimi posameznimi sloji glede na ocene slojev o^s . Množico tako inicializiramo s slojem z najboljšo oceno, nato pa v vsakem koraku dodamo izmed prostalih m slojev, sloj s za katerega velja:

$$\argmin_{s \in S^m} (o^{\mathcal{V} \cup \{s\}}), \quad (3)$$

da minimizira oceno množice, kjer je S^m množica m najboljših slojev in $o^{\mathcal{V} \cup \{s\}}$ skupna ocena množice $\mathcal{V}$ z dodatnim elementom s . Množici $\mathcal{V}$ dodajamo nove vmesne predstavitve dokler se skupna ocena $o^{\mathcal{V}}$ izboljšuje.

2.3 Uporaba pristopa

S pomočjo agregacijske funkcije $A(\cdot)$ ter množice izbranih vmesnih predstavitev $\mathcal{V}$, pristop za poljubni vhodni obrazni vzorec x , določi kakovost s pomočjo:

$$q_x = \frac{1}{K} \sum_{s \in \mathcal{V}} A(z_x^s), \quad (4)$$

kot povprečje ocen posameznih slojev, ki jih vsebuje množica $\mathcal{V}$, kjer K predstavlja moč množice $\mathcal{V}$.

3 Eksperimenti in Rezultati

Modeli in podatki. Predstavljen pristop primerjamo z desetimi vrhunskimi metodami za oceno kakovosti obraznih vzorcev: nenadzorovanimi SER-FIQ [19], FaceQAN [1] ter GraFIQs [12] metodami, in (ii) nadzorovanimi PCNet [20], SDD-FIQA [17], LightQnet [4], eDiffIQA [2], CLIB-FIQA [18], MagFace [15] ter CR-FIQA [3] metodami. Eksperimente izvedemo s pomočjo treh razširjenih konvolucijskih obraznih razpoznavalnikov: AdaFace [10], ArcFace [5] ter CurricularFace [8], ter na šestih raznolikih podatkovnih naborih: Adience [6], LFW [7], CPLFW [21], AgeDB [16], XQFW [11] ter IJB-C [14]. **Zasnova eksperimentov.** Za ovrednotenje pristopov uporabimo splošno uporabljene [2, 3, 15, 17] karakteristične (EDC) krivulje napak-zoper-zavrnitve. Krivulje prikažejo izboljšanje delovanje razpoznavalnega sistema, ko iz podatkovnega nabora izločimo določen delež najslabše ocenjenih obraznih vzorcev. Delovanje razpoznavalnika merimo s pomočjo mere FNMR@FMR, kjer je FMR = 10^{-3} . Nadaljnjo izračunamo delno površino (pAUC) pod EDC krivuljo, ki opisuje učinkovitost FIQA pristopa do meje zavrnitve, ki je pogosto enaka 20% ali 30%. Nižja vrednost pAUC predstavlja boljše delovanje FIQA pristopa. **Podrobnosti implementacije.** Kalibracijski podatkovni nabor je sestavljen iz 30.000 slik podatkovnega nabora Glint360k. Iz kalibracijskega nabora sestavimo 5 verifikacijskih protokolov. Znotraj EDC analize izračunamo mero pAUC pri stopnji zavrnitve 20%. Za m , ki določa število najboljših slojev iz katerih sestavljamo množico $\mathcal{V}$ določimo 10, tako uravnesimo število možnih kombinacij končne množice in časovno kompleksnost analize.

3.1 Primerjava s sorodnimi metodami

V sledečem odseku predstavimo primerjavo izbranih vrhunskih sorodnih metod s predstavljenim pristopom na podlagi: (i) uspešnosti (ii) ter časovne zahtevnosti.

Uspešnost pristopov. Rezultati analize uspešnosti pristopov so prikazani v Tabeli 1. Za posamezne pristope prikažemo rezultate analize v obliki pAUC vrednosti, pri stopnji zavrnitve 20% izračunanih preko posameznih podatkovnih naborov ter preko vseh vključenih razpoznavalnikov. Predstavljen pristop presega rezultate vseh vključenih nenadzorovanih pristopov: SER-FIQ, FaceQAN in GraFIQs ter večine nadzorovanih pristopov z izjemo treh najboljših pristopov, eDiffIQA, CLIB-FIQA ter CR-FIQA. Za razliko od predstavljenega pristopa potrebujejo omejeni trije nadzorovani pristopi kompleksen postopek učenja končne regresijske mreže, zato jih je težje prilagoditi poljubnemu vhodnemu razpoznavalnemu. Za razpoznavalnik AdaFace ter CurricularFace, predstavljen pristop dosega tretji najboljši povprečen rezultat preko vseh naborov, v primeru razpoznavalnika ArcFace pa četrti najboljši rezultat. Analiza preko različnih naborov kaže, da prestavljen rezultat dosega odlične rezultate na XQFW, ki vsebuje slike nizke kakovosti, ter IJB-C, ki je daleč največji nabor. Malce slabše rezultate pristop dosega na

Tabela 1: **Primerjava uspešnosti.** Tabela prikazuje vrednosti pAUC pri deležu zavrnitve 20% in FMR vrednosti 10^{-3} . Rezultati so razdeljeni med nabori in razpoznavalniki, zadnji stolp prikazuje povprečen rezultat preko vseh naborov. Najboljši rezultat je označen z **ZELENO**, drugi z **MODRO** ter tretji najboljši z **RDEČO**. Nenadzorovane metode so označene z **MODRIMI**, in nadzorovane z **ZELENI** poševnimi črtami.

AdaFace [10] - pAUC(FMR = $1e^{-3}$) [4]							
Metode	Adience	LFW	CPLFW	AgeDB	XQFW	IJB-C	pAUC
SER-FIQ [19]	0.871	0.982	0.775	0.809	0.809	0.812	0.843
FaceQAN [1]	0.919	0.797	0.808	0.833	0.924	0.800	0.847
GraFIQs [12]	0.932	0.863	0.791	0.950	0.801	0.846	0.864
PCNet [20]	1.003	0.730	0.914	0.969	0.826	0.843	0.881
SDD-FIQA [17]	0.884	0.857	0.819	0.796	0.907	0.854	0.853
LightQnet [4]	0.890	0.837	0.854	0.792	0.835	0.846	0.842
eDiffIQA(L) [2]	0.889	0.751	0.736	0.756	0.759	0.791	0.780
CLIB-FIQA [18]	0.893	0.762	0.746	0.770	0.770	0.807	0.791
MagFace [15]	0.890	0.735	0.805	0.760	0.958	0.915	0.844
CR-FIQA [3]	0.890	0.755	0.699	0.763	0.833	0.796	0.790
ERK25	0.869	0.754	0.749	0.823	0.742	0.787	0.787
ArcFace [5] - pAUC(FMR = $1e^{-3}$) [4]							
Metode	Adience	LFW	CPLFW	AgeDB	XQFW	IJB-C	pAUC
SER-FIQ [19]	0.840	0.982	0.797	0.790	0.828	0.732	0.828
FaceQAN [1]	0.864	0.775	0.826	0.835	0.883	0.731	0.819
GraFIQs [12]	0.872	0.863	0.814	0.946	0.818	0.786	0.850
PCNet [20]	1.012	0.697	0.810	0.965	0.860	0.770	0.852
SDD-FIQA [17]	0.841	0.857	0.829	0.801	0.935	0.806	0.845
LightQnet [4]	0.840	0.814	0.862	0.797	0.824	0.788	0.821
eDiffIQA(L) [2]	0.842	0.751	0.771	0.757	0.810	0.729	0.777
CLIB-FIQA [18]	0.846	0.762	0.778	0.762	0.789	0.730	0.778
MagFace [15]	0.852	0.712	0.809	0.771	0.960	0.867	0.828
CR-FIQA [3]	0.861	0.732	0.791	0.764	0.814	0.724	0.781
ERK25	0.834	0.786	0.809	0.858	0.794	0.744	0.804
CurricularFace [8] - pAUC(FMR = $1e^{-3}$) [4]							
Metode	Adience	LFW	CPLFW	AgeDB	XQFW	IJB-C	pAUC
SER-FIQ [19]	0.832	0.986	0.764	0.794	0.840	0.725	0.823
FaceQAN [1]	0.855	0.786	0.804	0.830	0.931	0.730	0.823
GraFIQs [12]	0.857	0.882	0.785	0.950	0.887	0.780	0.857
PCNet [20]	1.000	0.732	0.902	0.969	0.855	0.776	0.872
SDD-FIQA [17]	0.838	0.865	0.812	0.793	0.867	0.806	0.830
LightQnet [4]	0.827	0.834	0.852	0.783	0.855	0.787	0.823
eDiffIQA(L) [2]	0.831	0.763	0.751	0.740	0.883	0.721	0.781
CLIB-FIQA [18]	0.834	0.774	0.756	0.749	0.910	0.733	0.793
MagFace [15]	0.841	0.736	0.792	0.757	0.901	0.875	0.817
CR-FIQA [3]	0.859	0.746	0.765	0.751	0.901	0.734	0.792
ERK25	0.830	0.797	0.781	0.766	0.834	0.730	0.790

CPLFW, ki vsebuje vzorce z različnimi obraznimi pozami ter AgeDB, ki z vzorci pokriva več starostnih skupin. Daleč najboljši metodi sta eDiffIQA(L) in CLIB-FIQA, ki se za oceno kakovosti zanašata na generativne modele, sledita predstavljen metoda ter CR-FIQA. V splošnem predstavljen pristop dosega vrhunske rezultate, ki presegajo vse obstoječe nenadzorovane pristope in so kos tudi najzmoglivejšim nadzorovanim metodam.

Časovna zahtevnost. Rezultati analize časovne zahtevnosti pristopov so prikazani v Tabeli 2. Rezultati prikazujejo povprečen čas ter standardni odklon potreben za oceno kakovosti 1000 slik. Analizo izvedemo ločeno na vsaki sliki, tako se izognemo morebitni pohitritvi, ki bi sledila iz paketne obdelave podatkov. Iz tabele je očitna razlika med časovno zahtevnostjo nenadzorovanih ter nadzorovanih pristopov, daleč najpočasnejši pristop je FaceQAN, sledita pa mu preostala nenadzorovana pristopa SER-FIQ ter GraFIQs in nadzorovani pristop CLIB-FIQA. V povprečju nadzorovani pristopi dosegajo znatno nižjo časovno zahtevnost. Najhitrejši pristop je LightQnet, ki temelji na optimizaciji velikosti učene regresijske mreže, sledita mu SDD-FIQA in MagFace. Predstavljen pristop dosega čas, ki je znatno hitrejši od vseh nenadzorovanih pristopov, vendar med počasnejšimi v skupini nadzorovanih pristopov. Počasneje delujeta le pristopa PCNet ter CLIB-FIQA, le-ta izstopa z najpočasnejšim časom med

Tabela 2: **Časovna zahtevnost metod.** Tabela prikazuje povprečen čas ter standardni odklon potreben za delovanje metod za oceno kakovosti. Čas je izmerjen na podlagi 1000 obraznih vzorcev, kjer vsako izmed slik analiziramo ločeno. Nenadzorovane metode so označene z **MODRIMI**, in nadzorovane z **ZELENI**mi poševnimi črtami.

FIQA	SER-FIQ [19]	FaceQAN [1]	GraFIQs [12]	PCNet [20]	SDD-FIQA [17]	LightQNet [4]	eDifFIQA(L) [2]	CLIB-FIQA [18]	MagFace [15]	CR-FIQA [3]	ERK25
Čas ($\mu \pm \sigma$)	118.376 $\pm$ 29.240	352.12313.515	55.698 $\pm$ 32.328	13.913 $\pm$ 5.542	5.060 $\pm$ 1.300	4.929 $\pm$ 4.615	10.062 $\pm$ 1.342	80.346 $\pm$ 53.122	8.219 $\pm$ 0.228	9.381 $\pm$ 0.309	12.478 $\pm$ 1.483

nadzorovanimi pristopi. Kljub povprečnemu rezultatu v primerjavi z nadzorovanimi metodami, dosega predstavljen pristop znatno hitrejši čas od vseh prikazanih nenadzorovanih pristopov.

4 Zaključek

V članku smo predstavili pristop, ki združuje lastnosti nenadzorovanih in nadzorovanih pristopov za oceno kakovosti obraznih slik. Z uporabo preprostega delno nadzorovanega kalibracijskega postopka, ki uporablja agregacijsko funkcijo in kalibracijski podatkovni nabor vzorcev, uspe pristop doseči vrhunske rezultate. Predstavljen pristop, za razliko od nadzorovanih pristopov ne potrebuje učnega postopka regresijske mreže, hkrati uspe oceno napovedati znatno hitreje kot nenadzorovani pristopi.

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)*, pages 748–754, 2022.
- [2] Ž. Babnik, P. Peer, and V. Štruc. eDifFIQA: Towards Efficient Face Image Quality Assessment Based on Denoising Diffusion Probabilistic Models. *Transactions on Biometrics, Behavior, and Identity Science (TBIOM)*, 2024.
- [3] 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 International Conference on Computer Vision and Pattern Recognition (CVPR)*, 2023.
- [4] K. Chen, T. Yi, and Q. Lv. Lightweight Deep Face Quality Assessment for Risk-Controlled Face Recognition. *Signal Processing Letters*, 28:1878–1882, 2021.
- [5] 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.
- [6] E. Eidinger, R. Enbar, and T. Hassner. Age and Gender Estimation of Unfiltered Faces. *Transactions on Information Forensics and Security (TIFS)*, 9(12):2170–2179, 2014.
- [7] G. B. Huang, M. Ramesh, T. Berg, and E. Learned-Miller. Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments. Technical Report 07-49, University of Massachusetts, Amherst, October 2007.
- [8] Y. Huang, Y. Wang, Y. Tai, X. Liu, P. Shen, S. Li, J. Li, and F. Huang. CurricularFace: Adaptive Curriculum Learning Loss for Deep Face Recognition. In *Proceedings of the CVF/IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 5901–5910, 2020.
- [9] J. Jiang and W. Deng. Disentangling Identity and Pose for Facial Expression Recognition. *IEEE Transactions on Affective Computing (TAC)*, 13(4):1868–1878, 2022.
- [10] M. Kim, A. K. Jain, and X. Liu. AdaFace: Quality Adaptive Margin for Face Recognition. In *Proceedings of the CVF/IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 18750–18759, 2022.
- [11] M. Knoche, S. Hormann, 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.
- [12] J. N. Kolf, N. Damer, and F. Boutros. GraFIQs: Face Image Quality Assessment Using Gradient Magnitudes. In *Proceedings of the CVF/IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, pages 1490–1499, 2024.
- [13] Q. Li, H. He, H. Lai, T. Cai, Q. Wang, and Q. Gao. Enhanced Nuclear Norm Based Matrix Regression for Occluded Face Recognition. *Pattern Recognition*, 126:108585, 2022.
- [14] B. Maze, J. Adams, J. A. Duncan, N. Kalka, T. Miller, C. Otto, A. K. Jain, W. T. Niggel, J. Anderson, J. Cheney, et al. IARPA Janus Benchmark-C: Face Dataset and Protocol. In *Proceedings of the IAPR/IEEE International Conference on Biometrics (ICB)*, pages 158–165, 2018.
- [15] 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 International Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 14225–14234, 2021.
- [16] S. Moschoglou, A. Papaioannou, C. Sagonas, J. Deng, I. Kotsia, and S. Zafeiriou. AgeDB: the First Manually Collected, in-the-Wild Age Database. In *Proceedings of the CVF/IEEE conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, pages 51–59, 2017.
- [17] F.-Z. Ou, X. Chen, R. Zhang, Y. Huang, S. Li, J. Li, Y. Li, L. Cao, and Y.-G. Wang. SDD-FIQA: Unsupervised Face Image Quality Assessment with Similarity Distribution Distance. In *Proceedings of the CVF/IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 7670–7679, 2021.
- [18] F.-Z. Ou, C. Li, S. Wang, and S. Kwong. CLIB-FIQA: Face Image Quality Assessment with Confidence Calibration. In *Proceedings of the CVF/IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 1694–1704, 2024.
- [19] 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 International Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 5651–5660, 2020.
- [20] W. Xie, J. Byrne, and A. Zisserman. Inducing Predictive Uncertainty Estimation for Face Verification. In *Proceedings of the British Machine Vision Conference (BMVC)*, 2020.
- [21] T. Zheng and W. Deng. Cross-Pose LFW: A Database for Studying Cross-Pose Face Recognition in Unconstrained Environments. Technical Report 18-01, Beijing University of Posts and Telecommunications, February 2018.