



Rekonštrukcia obrázkov tvárí

Matúš Bako*



Abstrakt

Pri práci s obrázkami tváre sa môžeme dostať do situácie, kedy rozlíšenie bude jednoducho nepostačujúce a algoritmické metódy na zväčšovanie obrázkov nepresné. V takomto prípade sa ponúka možnosť použiť konvolučnú neurónovú sieť, ktorá sa snaží zväčšiť vstupný obrázok a odstrániť prípadné defekty ako šum a rozmazanie. Experimenty ukázali, že mnou navrhnutá architektúra sa na dátovej sade FFHQ dokáže vyrovnať existujúcim architektúram konvolučných neurónových sietí kvalitou, a taktiež zachovaním identity. Takto natrénované modely je možné použiť v praxi na miestach, kde je zväčšovanie tvári potrebné, napríklad pre rozpoznanie identity.

Kľúčové slová: Počítačové videnie — Neurónové siete — Rekonštrukcia obrazu

Priložené materiály: Zdrojový kód

*xbakom01@stud.fit.vutbr.cz, Fakulta informačných technológií, Vysokého učení technického v Brne

1 1. Úvod

Zväčšovanie obrázkov, alebo superrezolúcia, je oblasť 2 počítačového videnia, ktorá stále napreduje. Nachádza 3 využitie pri všeobecnej práci s obrazom, prípadne 4 ako súčasť spracovania špecifických obrazových dát. 5 Medzi takéto uplatnenia patrí zväčšovanie obrázkov 6 tváre pri zachovaní identity [1], prípadne zväčšovanie 7 rôznych biologických snímkov [2] pre ď alšie spraco-8 vanie. 9 Cieľom pri superrezolúcii pomocou konvolučných 10 neurónových sietí je nájsť vhodnú architektúru pre do-11 siahnutie čo najkvalitnejšieho zväčšenia tváre z jedného 12 13 obrázku. Mimo samotného zväčšovania je nutné sa zaoberať faktormi, ktoré môžu degradovať kvalitu obrazu. 14

Medzi tieto patrí rozmazanie spôsobené pohybom kamery, nesprávne zaostrenie, kompresné artefakty, šum
a rôzne iné. Pri rozpoznávaní identity je nutné, aby
bola v zväčšenom obrázku zachovaná identita tváre.

19 Väčšina existujúcich riešení je založená na istej

variácii konvolučnej neurónovej siete alebo genera-20 tívnych adversariálnych sietí [3]. Medzi prvé archi-21 tektúry, ktoré pozostávali iba z jednej konvolučnej 22 siete, patrí Super-resolution Convolutional Neural Ne-23 twork (SRCNN) [4] s tromi konvolučnými vrstvami. 24 Nevýhodou tejto architektúry je, že vstupný obrázok 25 musí byť zväčšený bikubickou interpoláciou a samotná 26 neurónová sieť preto vykonáva iba rekonštrukciu ob-27 razu. Toto vylepšuje architektúra *Efficient Sub-pixel* 28 Convolutional Network (ESPCN) [5]. Jej hlavným 29 prínosom bola tzv. Pixel Shuffle konvolučná vrstva, 30 ktorá obsahuje trénovateľné parametre pre lepší vý-31 sledok pri zväčšovaní. V nasledujúcich architektúrach 32 sa začínajú objavovať reziduálne vrstvy [6], ktoré sú 33 používané aj v iných úlohách nie len v oblasti počí-34 tačového videnia. Vzniklo viacero variácií reziduál-35 nych blokov, ku ktorým patrí aj kaskádový blok v 36 architektúre Cascading Residual Network (CARN) [7]. 37 Tieto typy architektúr však majú svoje obmedzenia a 38

39 nie sú schopné zachovávať na obrázkoch detaily, ako

40 sú napr. vlasy. Preto medzi ď alšie používané archi-

41 tektúry patrili generatívne adversariálne siete (GAN),

42 ktoré sú podrobnejšie popísané v nasledujúcej kapitole.

43 Medzi tento typ architektúr sa radia Super-Resolution

44 Generative Adversarial Network (SRGAN) [8], En-

45 hanced Super-Resolution Generative Adversarial Ne-

46 *tworks* (ESRGAN) [9] a mnoho ď alších.

47 Súčasťou môjho riešenia je návrh vlastnej archi48 tekúry konvolučnej neurónovej siete na zväčšovanie
49 obrázkov, pričom som navrhol aj vlastný reziduálny
50 blok. V rámci experimentov som natrénoval a vyhod-

51 notil úspešnosť viacerích architektúr na dátovej sade

52 FFHQ a CelebA.

53 2. Architektúry

54 V tejto kapitole sú najprv popísané architektúry neu-

55 rónových sietí, ktoré už boli navrhnuté v existujúcich

56 článkoch. Nasledovne je popísaná mnou navrhnutá

57 architektúra, ktorá si z niektorých už existujúcich ar-

58 chitektúr berie inšpiráciu, a pridáva isté inovácie.

59 2.1 Existujúce architektúry

Jednou z prvých architektúr, ktoré boli určené na su-60 perrezolúciu obrázkov, bola SRCNN [4]. Táto archi-61 tektúra mala iba tri vrstvy. Jej úlohou bolo extrahovať 62 jednotlivé dlaždice zo vstupného obrázku, nelineárne 63 ich premapovať a následne zrekonštruovať. Táto idea 64 zostáva vo všetkých architektúrach, avšak tie nasle-65 dujúce už majú viacero vrstiev. Medzi pokroky v ar-66 chitektúrach sa zaraď uje tzv. podpixelová konvolúcia 67 z architektúry ESPCN [5], ktorá pixely z viacerých 68 kanálov nakombinuje do jedného kanálu, čím vzniká 69 zväčšený obrázok. Princíp tejto operácie je presnejšie 70 ukázaný na obrázku 1. Túto metódu zväčšovania pou-71 72 žíva veľa ďalších neurónových sietí, ktoré v tomto

73 článku budú popísané. V architektúre sa táto operácia

74 používa ako tzv. *Pixel Shuffle* vrstva.

Medzi rozšírené architektúry patria tie, ktoré ob-sahujú tzv. reziduálne prepojenia [6]. Sem patria napr.

77 Very Deep Super-Resolution (VDSR) [11], Enhanced



Obrázok 1. Princíp operácie *Pixel Shuffle* vrstvy z architektúry ESPCN [5].



Obrázok 2. Použitie reziduálnych blokov a *Pixel Shuffle* vrstiev v architektúre EDSR. V ľavej spodnej časti je vidieť pridaný škálovací parameter reziduálneho bloku označený ako vrstva *Mult*. (zdroj: [10])

Deep Super-Resolution (EDSR) [10], a Super-Reso-78 lution Residual Network (SRResNet) [8]. Z týchto je 79 najjednoduchšia práve VDSR. Tá obsahuje jediné re-80 ziduálne prepojenie, ktoré smeruje od vstupnej vrstvy 81 až za všetky konvolučné vrstvy, ktoré prevádzajú ma-82 povanie. To znamená, že výstup konvolučných vrs-83 tiev je pripočítaný ku vstupu neurónovej siete. Kon-84 volučné vrstvy teda počítajú iba zmenu nad vstupným 85 obrázkom a tým je odstránená nutnosť odvodzovať 86 celý obrázok. Nevýhodou tejto architektúry však je, 87 že samotný obrázok nezväčšuje, ale dostáva na vstup 88 obrázok zväčšený bikubickou interpoláciou. Tento prís-89 tup vylepšuje architektúra Super-Resolution Residual 90 Network (SRResNet), ktorá už obsahuje Pixel Shuffle 91



Obrázok 3. Architektúra neurónovej siete CARN [7] (vľavo) a zloženie kaskádoveho bloku (vpravo), ktorý je stavebným prvkom tejto architektúry.



Obrázok 4. Architektúra mnou navrhnutej neurónovej siete a použitý reziduálny blok (vpravo dole). Podrobný popis architektúry sa nachádza v podkapitole 2.2.

vrstvy určené na zväčšovanie obrázku. Ďalším vylepše-92 ním je nahradenie konvolučných vrstiev reziduálnymi 93 blokmi. V architektúre Enhanced Deep Super-Reso-94 lution (EDSR) je vylepšený samotný reziduálny blok 95 pridaním škálovacieho parametru, ako je ukázané v 96 obrázku 2. Škálovací parameter sa môže trénovať a 97 určuje, ako veľmi daný reziduálny blok vplýva na 98 celkový výstup. S ď alšou inováciou prichádza archi-99 tektúra CARN, ktorá reziduálne bloky nahrádza kaská-100 dovými blokmi. Kaskádový blok sa od reziduálneho 101 odlišuje tým, že výstup každej konvolučnej vrstvy je 102 vstupom každej nasledujúcej vrstvy v rámci daného 103 bloku, ako je ilustrované v obrázku 3. Ďalší známy 104 105 prístup použiva architektúra Deep Back-Projection Network (DBPN) [12], ktorá vstupný obrázok iteratívne 106 zväčšuje a zmenšuje. Takýmto spôsobom sa vytvorí 107 viacero zväčšených vstupných obrázkov, ktoré sa na-108 koniec skonkatenujú a ďalšou rekonštrukciou vznikne 109 110 výsledný obrázok.

111 Všetky doteraz spomenuté architektúry používajú
112 ako chybovú funkciu istú sumu vzdialeností medzi
113 pixelmi, prevažne priemernú štvorcovú chybu. Nevý114 hodou tohto prístupu je, že tákáto chybová funkcia
115 neberie dostatočne do úvahy detaily. Zväčšené fotky
116 sú preto často mierne rozmazané a oblasti ako vlasy
117 nie sú príliš detailné.

Ďalší typ architektúr, ktoré sa používajú na superrezolúciu, sú generatívne adversariálne siete (GAN)
[3]. Hlavným rozdielom je, že architektúra sa skladá z
dvoch neurónových sietí. Generátor je časť, ktorá produkuje dáta s istým pravdepodobnostným rozložením.
Všeobecne to nemusí platiť, ale generované dáta môžu
byť závislé na vstupe, čo využívame v architektúrach

určených na superrezolúciu. Úlohou diskriminátora 125 je zistiť, či dáta ktoré dostal na vstup pochádzajú z 126 generátora alebo trénovacej dátovej sady. Princíp ar-127 chitektúry generátoru je zhodný s architektúrami po-128 pisovanými doteraz. Väčšinou to je jedna konvolučná 129 neurónová sieť, ktorej výstupom je zväčšený obrázok. 130 Diskriminátor je konvolučná neurónová sieť, ktorej 131 výstupom je pravdepodobnosť, že vstupný obrázok 132 pochádza z dátovej sady a nie je vytvorený generáto-133 rom. Aby bol diskriminátor schopný zmenšiť obrázok 134 na veľkosť jedného pixelu, v architektúre za konvoluč-135 nými vrstvami nasledujú plne prepojené vrstvy. Počas 136 trénovania sa obe časti architektúry stále vylepšujú, 137 teoreticky až kým výstup generátoru je nerozlíšiteľný 138 s obsahom dátovej sady. 139

GAN-y ako chybovú funkciu používajú s pixe- 140 lovú chybou zároveň s adversariálnou chybou. Adver- 141 sariálna chyba sleduje, či sa predikcie diskriminátora 142 líšia od reality a následne trénuje generátor aj diskri-143 minátor. Jednou z prvých architektúr tohto typu je SR-144 GAN [8]. Generátor v tejto architektúre je už popiso-145 vaná neurónová sieť SRResNet. Vylepšením tejto siete 146 je architektúra ESRGAN [9]. Generátor si zakladá na 147 architektúre SRResNet, avšak namiesto reziduálneho 148 bloku používa kaskádový blok z architektúry CARN 149 [7] a aktivačnú funkciu *Parametric Rectified Linear* 150 Unit (PReLU) [14]. Diskriminátor zostáva oproti ar-151 chitektúre SRGAN nezmenený. 152

2.2 Navrhnutá architektúra

V rámci tohto článku som taktiež navrhol vlastnú architektúru neurónovej siete, ktorá sa nachádza na obrázku 4. Architektúra kombinuje vylepšenia Z návrhu je viditeľná inšpirácia architektúrami tvaru presýpacích

153







186

Obrázok 5. Rôzne typy artefaktov, ktoré sa nepodarilo odstrániť pri použití feature loss počítanej pomocou predtrénovanej architektúry ResNet[6] a DenseNet[13].

hodín a taktiež použitie reziduálneho prepojenia zo 158 vstupnej vrstvy. Reziduálne prepojenie ktoré smeruje 159 zo vstupu až do výstupu zabezpečuje, že zvyšok neuró-160 novej siete počíta iba diferenciu nad vstupným obráz-161 kom, ktorá sa k nemu pričíta. Tým je práca neurónovej 162 siete zjednodušená. Idea za neurónovými sieťami tvaru 163 presýpacích hodín je, že ich vstup sa postupne zmenšuje 164 a následne zväčšuje po rovnakých krokoch na pôvodnú 165 veľkosť. Platí ale, že vždy sa sčítajú tenzory rovnakej 166 veľkosti. Pre menší tenzor vždy platí, že už prešiel via-167 cerými konvolúciami, a preto má informáciu o väčšej 168 ploche. Pôvodný väčší obrázok po konvolúcii však 169 obsahuje detailnejšie informácie. Sčítaním tenzoru 170 pôvodnej veľkosti a menšieho tenzoru následne zväč-171 šeného na pôvodnú veľkosť kombinujeme globálnu 172 informáciu s detailami obrázku. Medzi každým zmen-173 šením, prípadne zväčšením, sa nachádzajú štyri re-174 ziduálne bloky, ktoré som taktiež navrhol sám. Tie ne-175 176 obsahujú žiadnu normalizáciu vzorky (batch normalization), pretože vo viacerých článkoch [9, 15, 10] bolo 177 uvedené, že pri superrezolúcii nie je prospešná. Týmto 178 taktiež znížime nároky na grafickú pamäť. Použitie 179 Leaky Rectified Linear Unit (LReLU) [14] bolo pre-180 vzaté z architektúry ESRGAN. Za konvolúciami je 181 škálovacia vrstva, ktorá obsahuje jeden trénovateľný 182 parameter. Ten určuje, do akej miery výstup daného 183 bloku ovplyvní celkový výsledok. Túto vrstvu väčšina 184 architektúr neobsahovala. 185

3. Experimenty

Vyhodnocovanie úspešností zvolených architektúr bolo 187 naprogramované v programovacom jazyku Python s 188 použitím knižnice pytorch¹. Pre trénovanie a vyhodno- 189 covanie boli použité dátové sady CelebA² a FFHQ³. 190 Dataset FFHQ bol vytvorený v rámci článku, ktorý 191 popisuje architektúru StyleGAN [16]. Oba datasety ob-192 sahujú obrázky tvárí s rôznym natočením, emóciami, 193 pričom postavy na obrázkoch majú rôzny vek, farbu 194 pleti, prípadne nosia okuliare a rôzne iné doplnky. 195 Pretože žiadna z architektúr neobsahovala v článku 196 úspešnosť na datasete FFHQ a iba niektoré na data-197 sete CelebA, bolo nutné všetky modely natrénovať a 198 vyhodnotiť. 199

Stiahnuté obrázky mali rozdielne veľkosti, a preto 200 boli zmenšené na veľkosť 208x176 a 256x256 pixe-201 lov kvôli deliteľnosti. Pri trénovaní na obrázky bolo 202 náhodne aplikované rozmazanie pohybom kamery (mo- 203 tion blur), rozmazanie spôsobené zlým zaostrením, pri-204 daný šum a kompresné artefakty. Pri vyhodnocovaní 205 boli obrázky zväčšované na štvornásobnú veľkosť. Pri 206 nižšom zväčšení rozdiely neboli dostatočne viditeľné a 207 pri vyššom zväčšení obrázky nedosahovali dostatočnú 208 kvalitu. Na vyhodnotenie bolo z oboch dátových sád 209 použitých 5000 obrázkov z validačnej dátovej sady. 210 Modely boli trénované s veľkosť ou dávky (batch size) 211 8 obrázkov po 10⁵ iterácii. 212

Celková chyba architektúr generatívnych adver- 213

¹www.pytorch.org

²http://mmlab.ie.cuhk.edu.hk/projects/CelebA.html ³www.github.com/NVlabs/ffhq-dataset

	CARN	DBPN	ESPCN	SRGAN	ESRGAN	SRResNet	článok	
PSNR	28.56	28.45	27.00	27.96	28.44	28.21	28.37	
PSNR+	3.20	3.09	1.65	2.61	3.09	2.86	3.02	FFHQ
Vzdialenosť identít	0.394	0.408	0.655	0.426	0.498	0.412	0.423	
PSNR	28.41	27.95	26.76	27.678	28.12	27.94	28.14	
PSNR+	3.70	3.24	2.05	2.969	3.42	3.232	3.43	CelebA
Vzdialenosť identít	0.153	0.159	0.156	0.151	0.151	0.147	0.145	

Tabuľka 1. Porovnanie úspešností natrénovaných architektúr na testovacej sade dátových sád CelebA a FFHQ. Riadok PSNR+ popisuje zlepšenie v peak signal to noise ratio (PSNR) oprori bikubickej interpolácii. Použité metriky sú podrobne popísané v kapitole 3.

sariálnych sietí sa v experimentoch líšila od chyby 214 uvedenej v článkoch. Súčasťou celkovej chyby bola 215 tzv. feature loss, ktorá bola vypočítaná ako rozdiel 216 výstupných vektorov neurónovej siete určenej sa ex-217 trakciu rysov. V rámci experimentov boli použité pred-218 trénované architektúry ResNet a DenseNet z balíčku 219 torchvision⁴. Obe architektúry však zapríčiňovali vznik 220 pravidelných artefaktov vo výstupných obrázkoch ako 221 je viditeľné na obrázku 5. 222

V architektúrach SRGAN a ESRGAN namiesto ad-223 versariálnej chyby definovanej v príslušných článkoch 224 bola použitá tzv. binary cross entropy [17], ktorá počíta 225 chybu nad rozhodovaním medzi dvomi triedami. To 226 bolo z dôvodu, že pri použití pôvodnej chybovej fun-227 kcie sa model netrénoval a nepodarilo sa zistiť príčinu. 228 Pre vyhodnotenie kvality rekonštrukcie som použil 229 mieru peak signal-to-noise ratio (PSNR), ktorá vyjad-230 ruje pomer výkonu signálu voči súčtu výkonov šumov. 231 232 Kvalita rekonštrukcie teda rastie s hodnotou PSNR. Výslednú hodnotu PSNR každej architektúry som tak-233 tiež porovnal s hodnotou nameranou pri zväčšovaní 234 bikubickou interpoláciou. Problémom však je, že ne-235 môžeme porovnávať PSNR v prípade, že vyhodnocu-236 jeme kvalitu rekonštrukcie GAN-ov. To je z dôvodu, že 237 GAN-y sa nesnažia obrázok priamo rekonštruovať, ale 238 vygenerovať zo vstupného obrázku nový v istom prav-239 240 depodobnostnom rozložení, ktoré je určené trénovaním. Preto na zväčšených obrázkoch bolo nutné brať do 241 úvahy aj identitu tváre. Pre vyhodnotenie rozdielu me-242 dzi identitou na pôvodnom a zväčšenom obrázku bola 243 použitá miera vzdialenosti identít. Z oboch obrázkov 244 boli najprv extrahované rysy. K tomu bola použitá 245 neurónová sieť architektúry ResNet [6] natrénovaná 246 na extrakciu rysov z tvárí. Výstupom tejto siete je 247 vektor príznakov, ktorý popisuje identitu danej tváre. 248 Pre samotnú extrakciu bola použitá knižnica dlib⁵. Z 249 výstupných vektorov bola následne vypočítaná vzdiale-250 nosť identít podľa vzorca $d = \sum x_i^2 - y_i^2$. Z toho vyplíva, 251 že čím je výsledná vzdialenosť menšia, tým viac sa 252 253 identita vo zväčšenom obrázku zhoduje s pôvodnou identitou. Výsledné vzdialenosti boli následne nor-254 malizované do intervalu (0.1, 1) násobením vhodnou 255 mocninou čísla 10. Z toho dôvodu nie sú vzájomne 256 porovnateľné jednotlivé hodnoty medzi dátovými sa-257 258 dami. Z výsledkov v tabuľke 1 vyplíva, že medzi architektúry, ktoré produkujú najkvalitnejšie obrázky, sa 259 radia CARN, ESRGAN, SRResNet a architektúra na-260 vrhnutá v tomto článku. Z toho môžeme určite vyvodiť, 261 že použitím vhodného reziduálneho bloku je možné 262 263 dosiahnuť kvalitné výsledky. Na výsledkoch je taktiež

> ⁴https://pytorch.org/docs/stable/torchvision/index.html ⁵www.dlib.net

viditeľné, že na datasete FFHQ sa výsledky viac podo-264 bajú očakávaným výsledkom. To zrejme súvisí s tým, 265 že táto dátová sada obsahuje kvalitnejšie obrázky. 266

267

286

290

4. Záver

Tento článok sa zaoberá superrezolúciou obrázkov268tvárí. Uvedených bolo niekoľko typov rôznych archi-269tektúr, nad ktorými boli vykonané experimenty na270dátových sadách CelebA a FFHQ. Taktiež som navrhol271vlastnú architektúru neurónovej siete.272

V experimentoch sa medzi najlepšie architektúry 273 radili CARN, SRResNet, ESRGAN a mnou vytvorená 274 architektúra, pričom všetky na dátovej sade FFHQ 275 dosahovali PSNR o hodnote približne 28.5*dB* a vzdia-276 lenosť identít o hodnote približne 0.4. 277

Počas trénovania nebol kladený dôraz na optimalizáciu parametrov trénovania, čo by potenciálne mohlo vylepšiť výsledky architektúr. Ďalej by bolo vhodné s generatívnymi adversariálnymi sieťami používať aj *feature loss* a zbaviť sa artefaktov, ktoré doteraz vznikali. Taktiež by bolo vhodné vykonať experimenty s architektúrami, ktoré berú do úvahy aj identitu na obrázkoch, na čo by už ale bola potrebná iná dátová sada. 285

Poďakovanie

Chcel by som poď akovať Ing. Michalovi Hradišovi 287 Ph.D. a Ing. Mariánovi Beszédešovi Ph.D. za pomoc a 288 odborné konzultácie pri tvorbe tohto článku. 289

Literatúra

- Kaipeng Zhang, Zhanpeng Zhang, Chia-Wen 291
 Cheng, Winston H. Hsu, Yu Qiao, Wei Liu, 292
 and Tong Zhang. Super-identity convolutional 293
 neural network for face hallucination. *CoRR*, 294
 abs/1811.02328, 2018. 295
- [2] Thomas Köhler. Multi-frame super-resolution 296 reconstruction with applications to medical imaging. *CoRR*, abs/1812.09375, 2018.
- [3] Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi 299 Mirza, Bing Xu, David Warde-Farley, Sherjil 300 Ozair, Aaron C. Courville, and Yoshua Bengio. 301 Generative adversarial nets. In Advances in Ne- 302 ural Information Processing Systems 27: Annual 303 Conference on Neural Information Processing 304 Systems 2014, December 8-13 2014, Montreal, 305 Quebec, Canada, pages 2672–2680, 2014. 306
- [4] Chao Dong, Chen Change Loy, Kaiming He, and 307 Xiaoou Tang. Image super-resolution using deep 308 convolutional networks. *CoRR*, abs/1501.00092, 309 2015. 310

- [5] Wenzhe Shi, Jose Caballero, Ferenc Huszár, Johannes Totz, Andrew P. Aitken, Rob Bishop, Daniel Rueckert, and Zehan Wang. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network. *CoRR*, abs/1609.05158, 2016.
- [6] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and
 Jian Sun. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages
 770–778, 2016.
- [7] Namhyuk Ahn, Byungkon Kang, and KyungAh Sohn. Fast, accurate, and, lightweight
 super-resolution with cascading residual network. *CoRR*, abs/1803.08664, 2018.
- [8] Christian Ledig, Lucas Theis, Ferenc Huszar,
 Jose Caballero, Andrew P. Aitken, Alykhan Tejani, Johannes Totz, Zehan Wang, and Wenzhe
 Shi. Photo-realistic single image super-resolution
 using a generative adversarial network. *CoRR*,
 abs/1609.04802, 2016.
- [9] Xintao Wang, Ke Yu, Shixiang Wu, Jinjin
 Gu, Yihao Liu, Chao Dong, Chen Change
 Loy, Yu Qiao, and Xiaoou Tang. Enhanced
 super-resolution generative adversarial networks. *CoRR*, abs/1809.00219, 2018.
- [10] Bee Lim, Sanghyun Son, Heewon Kim, Seungjun
 Nah, and Kyoung Mu Lee. Enhanced deep residual networks for single image super-resolution. *CoRR*, abs/1707.02921, 2017.
- [11] Jiwon Kim, Jung Kwon Lee, and Kyoung Mu
 Lee. Accurate image super-resolution using
 very deep convolutional networks. *CoRR*,
 abs/1511.04587, 2015.
- Muhammad Haris, Greg Shakhnarovich, and Norimichi Ukita. Deep back-projection networks for
 super-resolution. *CoRR*, abs/1803.02735, 2018.
- [13] Gao Huang, Zhuang Liu, and Kilian Q. Weinberger. Densely connected convolutional networks. *CoRR*, abs/1608.06993, 2016.
- [14] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and
 Jian Sun. Delving deep into rectifiers: Surpassing
 human-level performance on imagenet classification. *CoRR*, abs/1502.01852, 2015.
- [15] Chao Dong, Chen Change Loy, and Xiaoou Tang.
 Accelerating the super-resolution convolutional neural network. *CoRR*, abs/1608.00367, 2016.
- 358 [16] Tero Karras, Samuli Laine, and Timo Aila. A359 style-based generator architecture for generative

adversarial networks. *CoRR*, abs/1812.04948, 360 2018. 361

[17] Katarzyna Janocha and Wojciech Marian Czar necki. On loss functions for deep neural networks
 in classification. *CoRR*, abs/1702.05659, 2017.
 364