


# Rekonštrukcia poškodených častí odtlačkov prstov s využitím neurónových sietí

Michael Halinár



## Abstract

Táto práca sa zaoberá problematikou rekonštrukcie poškodených odtlačkov prstov s využitím neurónových sietí. Rekonštruované odtlačky sú syntetické, ako aj poškodenia, ktoré sú do odtlačkov vkladané. Sieť sa snaží z poškodeného odtlačku dostať pôvodný, pri zachovaní všetkých dôležitých aspektov odtlačku prsta. Táto práca rieši dva problémy a to výber vhodnej architektúry neurónovej siete a vytvorenie databázy syntetických odtlačkov. Keďže voľne dostupné databázy reálnych odtlačkoch sú nedostatočne veľké. Špecifická architektúra neurónovej siete je schopná rekonštruovať poškodené obrázky. Takáto architektúra sa nazýva *autoencoder*. Je to druh neurónovej siete, ktorá využíva konvolučné vrstvy. Po naučení dokáže veľmi dobre redukovať šum a rekonštruovať vstupy. V práci je použitý tento typ architektúry na rekonštrukciu poškodených častí odtlačku. Pre simuláciu poškodenia je vložená do odtlačku prstu bradavica. Sieť dokáže rekonštruovať poškodené časti pri zachovaní pôvodných vlastností prsta vo väčšine prípadov. Rekonštrukcia bradavice je závislá od miesta a veľkosti bradavice. Kvalita rekonštrukcie je meraná pomocou programu Verifinger. Táto práca ukazuje, že s použitím vhodnej neurónovej siete, ktorá bude naučená na dostatočne veľkej databáze, je možné dosiahnuť rekonštrukciu poškodeného odtlačku prsta. Odtlačky prstov sa počas života môžu meniť rôznymi spôsobmi. Vytvorená aplikácia dokáže eliminovať tento faktor, zrekonštruovať pôvodný odtlačok a umožniť lepšiu identifikáciu vlastníka odtlačku.

**Kľúčové slová:** neurónová sieť — odtlačok prsta — rekonštrukcia

**Priložené materiály:** [Demonštračné video](#) — [Stiahnuteľný kód](#)

[xhalin01@stud.fit.vutbr.cz](mailto:xhalin01@stud.fit.vutbr.cz), Faculty of Information Technology, Brno University of Technology

## 1. Úvod

Odtlačky prstov sa počas života menia, avšak ich individuálne znaky zostávajú nemenné. To je jeden z dôvodov, kvôli ktorým sú odtlačky prsta výhodnou cestou pre identifikáciu osôb. Uvažujme teda systém, ktorý je určený na identifikáciu osôb podľa odtlačkov prstov a obsahuje odtlačky konkrétnej osoby. Medzičasom sa však danej osobe poškodí pokožka a nie je možné už viac identifikovať túto osobu na základe

pôvodných odtlačkov. S využitím neurónovej siete sme schopný rekonštruovať pôvodný odtlačok a identifikovať tak danú osobu.

Existuje mnoho druhov neurónových sietí, ktoré majú rôzne využitia. Použitie vhodnej architektúry je jedným z problémov ktoré rieši táto práca. Ďalším problémom je nedostatočná veľkosť voľne dostupných databáz, na tento fakt poukazuje aj práca [1]. Kde je malá databáza jedným z faktorom, ktoré ovplyvnili

10  
11  
12  
13  
14  
15  
16  
17  
18

19	výsledky.	
20	Existuje pomerne málo výskumov v tejto oblasti.	
21	Podľa práce [2], je táto prvou kde je použitá architektúra	
22	GAN (Generative adversarial network) na generovanie	
23	odtlačkov prstov. GAN vo voľnom preklade znamená	
24	generatívna konfrontačná sieť. Nazýva sa tak preto	
25	lebo obsahuje dve časti a to generátor a diskriminátor.	
26	Pričom diskriminátor hodnotí výstupy vytvorené gene-	
27	rátorom a snaží sa tak vylepšiť jeho schopnosti vytvárania	
28	výstupu. V tejto práci generátor aj diskriminátor	
29	sa skladajú z piatich vrstiev. Použité boli databáze	
30	odtlačkov FVC-2006 a Poly-U. Celkovo obsahovali	
31	zhruba 3000 obrázkov odtlačkov, pričom bol vystrih-	
32	nutý ich stred a zredukovaný na veľkosť 64x64 pixelov.	
33	Treba dodať že odtlačky neboli jedinečné, čiže jeden	
34	prst bol nasnímaný viac krát. Výsledkom práce bolo	
35	generovanie syntetických odtlačkov, ktoré sa podobali	
36	na reálne odtlačky zo spomenutých databáz. V tomto	
37	riešení žiadne testy nepotvrdzovali kvality výstupu.	
38	Ďalšia práca v tejto oblasti má názov Fingerprint	
39	Inpainting with Generative Models [1]. Ktoorej cieľom	
40	bolo dokresľovať časti odtlačku, ktoré boli nahradené	
41	šedým regiónom. Použitá architektúra siete je opäť	
42	GAN kde generátor pozostáva z architektúry <i>autoen-</i>	
43	<i>coder</i> . Databáza odtlačkov pozostávala z obrázkov	
44	s veľkosťou 128x128 pixelov, pričom boli vkladané	
45	šedé oblasti s rozmermi 32x32 pixelov, ktoré boli	
46	následne rekonštruované. Učenie použitej siete bolo	
47	veľmi časovo náročné, autori uviedli že riešenie ne-	
48	muselo konvergovať k správne mu riešeniu. Učenie	
49	trvalo týždeň pri použití grafickej karty nVidia GTX	
50	1060. Testy kvality rekonštrukcie boli urobené na	
51	klasifikátore odtlačkov. Zvýšenie správnej klasifikácie	
52	narástlo zhruba o tretinu po použití rekonštrukcie.	
53	Táto práca sa zaoberá návrhom a implementáciou	
54	architektúry a jej parametrov pre čo najlepšiu rekon-	
55	štrukciu syntetických odtlačkov. Kvôli nedostatočne	
56	veľkým databázam reálnych odtlačkov prstov, sa sieť	
57	učí na syntetických odtlačkoch s ochoreniami do nich	
58	vložených. Príprava databáze odtlačkov je teda ďalším	
59	bodom tejto práce. Výsledky aplikácie sú merané po-	
60	mocou programu Verifinger, ktorý meria zhodu odtlačku	
61	pred a po rekonštrukcii. Nárast hodnoty zhody sa pohy-	
62	buje okolo 10%. Vytvorená sieť je schopná, rýchlo sa	
63	učí a kvalitne rekonštruovať odtlačky. Pomerne malý	
64	počet vrstiev a využitie <i>downsapling</i> vrstiev zabezpečuje	
65	rýchle učenie aj na výpo-četne slabom hardvéri.	
66	Táto neurónová sieť opravuje simulované ochore-	
67	nia kože, na rozdiel od predchádzajúcej práce[1], kde	
68	boli vkladané poškodenia v tvare šedého obdĺžnika.	
69	Rekonštruované odtlačky sa veľmi podobajú odtlačkom	
70	pred poškodením. Zlepšenie porovnávacieho skóre sa	
	zvýšilo po rekonštrukcii o 16%.	71
	<b>2. Odtlačky prstov</b>	<b>72</b>
	Odtlačok prsta vzniká odtlačením papilárnych línií	73
	na určitý povrch. Forma papilárnych línií je určená	74
	hlavne génni jedinca [3]. Ak nepríde k vážnemu me-	75
	chanickému alebo inému poškodeniu, línie zostávajú	76
	rovnaké počas celého života, pokiaľ zanedbáme faktor	77
	starnutia kože, ktorý je prirodzený. Papilárne línie	78
	sú formované v nižšej vrstve kože, čo zabezpečuje	79
	ich obnovu v prípade ľahkého poškodenia [4]. Línie	80
	vytvárajú vzory, vďaka ktorým môžeme odtlačky jed-	81
	noznačne identifikovať.	82
	<b>3. Databáza</b>	<b>83</b>
	Databáza odtlačkov bola vytvorená pomocou nástroja	84
	Anguli <sup>1</sup> . Bolo vytvorených 1000 jedinečných odtlač-	85
	kov prstov. Pred tým ako môžu byť použité, je nutné	86
	upraviť ich rozmery, tak aby konvulučná sieť mohla	87
	robiť <i>downsampling</i> <sup>2</sup> pokiaľ možno, čo najviac krát.	88
	Teda obrázky, ktorých rozmer výšky a šírky je moc-	89
	nina dvojky sú najvhodnejšie vstupy pre konvulučné	90
	siete. Vygenerované obrázky nástrojom Anguli majú	91
	rozmer 400x275 pixelov. Výška 400 pixelov je primer-	92
	ane vhodná, pri takomto rozmere môžeme robiť <i>down-</i>	93
	<i>sampling</i> až 5 krát. Šírka 275 pixelov nie je vhodná	94
	pre <i>downsampling</i> preto bola šírka obrázku zúžená na	95
	256 pixelov. Na náhodné pozície potom boli vložené	96
	syntetické bradavice, vytvorené programom SyFDaS	97
	<sup>3</sup> .	98
	Prvý dataset obsahuje 10 bradavíc s priemerom pri-	99
	bližne 30 pixelov. Každá bradavica bola navyiac 3-krát	100
	otočená za účelom vytvorenia ďalších vzoriek bradavíc.	101
	Spolu teda 40 bradavíc bolo vložených do 1000 syn-	102
	tetických odtlačkov na náhodné miesto. Kombinácia	103
	natočenia bradavice a vloženie na náhodné miesta sa	104
	ukázala ako dostatočná varianta k vytváraniu 1000 ori-	105
	ginálnych bradavíc, nakoľko boli bradavice manuálne	106
	vystrihované z obrázkov generovaných pomocou pro-	107
	gramu SyFDaS <sup>4</sup> .Bradavice majú priemer približne	108
	80 pixelov. Do každého odtlačku bolo vložených 6	109
	bradavíc.	110
	<b>4. Návrh a implementácia</b>	<b>111</b>
	Ako prvé je potrebné vybrať typ neurónovej siete, ktorá	112
	sa bude učiť odtlačky rekonštruovať. Na výber je	113
	niekoľko druhov knižníc a architektúr sietí, ktoré je	114
	<sup>1</sup> <a href="https://dsl.cds.iisc.ac.in/projects/Anguli/">https://dsl.cds.iisc.ac.in/projects/Anguli/</a>	
	<sup>2</sup> <a href="https://en.wikipedia.org/wiki/Downsampling_(signal_processing)">https://en.wikipedia.org/wiki/Downsampling_(signal_processing)</a>	
	<sup>3</sup> <a href="https://www.fit.vut.cz/research/product/600/cs">https://www.fit.vut.cz/research/product/600/cs</a>	
	<sup>4</sup> <a href="https://www.fit.vut.cz/research/product/600/cs">https://www.fit.vut.cz/research/product/600/cs</a>	

115 možné použiť. Architektúra GAN je veľmi vhodná pre  
 116 generovanie nových výstupov, ktoré sa nenachádzajú  
 117 medzi trénovacou množinou. Z tohoto dôvodu bude  
 118 použitá architektúra *autoencoder*. Po naučení siete na  
 119 vytvorenej databáze bude treba overiť kvalitu rekon-  
 120 štrukcie, naskytá sa tu niekoľko možností. Jednou  
 121 z nich je meranie kvality samotného odtlačku podľa  
 122 NFIQ<sup>5</sup>. Ďalšou možnosťou je meranie hodnoty zhody  
 123 odtlačkov pred a po rekonštrukcii, napríklad pomocou  
 124 programu Verifinger<sup>6</sup>. Po vyhodnotení výsledkov bude  
 125 nasledovať ich analýza.

## 126 5. Architektúra siete

127 Ako východzia architektúra bola použitá sieť *autoen-*  
 128 *coder*[5]. Počet konvolučných vrstiev bol navýšený.  
 129 Aktivačné funkcie a veľkosti filtrov boli zachované.  
 130 Dôležitou zmenou je počet filtrov, ten bol navýšený  
 131 vzhľadom na skutočnosť že pôvodná sieť pracovala s  
 132 obrázkami s veľmi nízkymi rozmermi - 28x28 pixelov,  
 133 oproti syntetickým odtlačkom s rozmermi - 400x256  
 134 pixelov. Výsledná schéma architektúry je znázornená  
 135 na obrázku 1. Kde zelené vrstvy predstavujú *down-*  
 136 *sampling*, modré *upsampling* a žlté predstavujú kon-  
 137 volučné vrstvy. Aktivačné funkcie sú typu ReLu<sup>7</sup>.




Figure 1. Architektúra siete.

## 138 6. Experimenty

139 Učenie prebiehalo na procesore Intel i5-8250 v niekoľ-  
 140 kých iteráciách. Prvá iterácia pracovala nad poškodo-  
 141 nými odtlačkami a pôvodnými odtlačkami bez poško-  
 142 denia 4. V druhej iterácii sa vytvorili nové váhy, v tejto  
 143 iterácii už sa sieť učila na výstupoch z prvej iterácie  
 144 a originálnych obrázkoch. Týmto spôsobom prebehli  
 145 tri iterácie a vznikli tri rôzne skupiny váh pre sieť.  
 146 Poškodený obrázok je teda rekonštruovaný pomocou  
 147 týchto rôznych troch váh, kde prvé váhy sa snažia  
 148 rekonštruovať línie a posledné váhy sú naučené aby už  
 149 iba vyhladzovali výsledok s predchádzajúcej iterácie.  
 150 Pričom počty epoch boli: 200 pre prvú iteráciu, 80  
 151 pre druhú a tretiu iteráciu. Po ďalších iteráciách už  
 152 nastával *overfitting*<sup>8</sup>. Týmto spôsobom dostávame

<sup>5</sup><https://github.com/usnistgov/NFIQ2>

<sup>6</sup><https://www.neurotechnology.com/verifinger.html>

<sup>7</sup><https://www.kaggle.com/dansbecker/rectified-linear-units-relu-in-deep-learning>

<sup>8</sup><https://elitedatascience.com/overfitting-in-machine-learning>

rekonštruované odtlačky, ktorých porovnávacie skóre 153  
 je vyššie v niektorých prípadoch až o viac ako 40% 3. 154  
 Väčšie bradavice nie sú vždy rekonštruované správne, 155  
 ak sa poškodenie nachádza napríklad v strede odtlačku 156  
 (delte), sieť má problém korektne dokresliť túto časť 157  
 2. Porovnávanie prebiehalo manuálne na prvých 100 158  
 odtlačkoch, pre výpočet priemerného nárastu zlepšenia. 159  
 Manuálne zmerané porovnávacie skóre sa nachádza v 160  
 priložených súboroch. Celkovo sa zlepšilo porovnáva- 161  
 cie skóre po rekonštrukcii o 16%. 162




Figure 2. Kvalitná rekonštrukcia bradavíc.




Figure 3. Nekvalitná rekonštrukcia bradavíc.





Figure 4. Priebek učenia prvej iterácie.

Jedným z vedľajších produktov tejto práce je aj 163  
 detektor polohy a veľkosti bradavice. Tento detektor 164  
 5, používa rovnakú sieť ako pre rekonštrukciu, avšak 165  
 je naučený iba jednou epochou. Takáto sieť ešte nevie 166  
 čo sa od nej očakáva preto oblasť s bradavicou celú 167  
 zafarbí na šedo. Pomocou filtra teraz môžeme bra- 168  
 davicu zvýrazniť a zistiť tak jej polohu a tvar. Tento 169  
 detektor slúži predovšetkým ako ilustrácia možností 170  
 neurónových sietí a je jedným z možných rozšírení do 171

budúcna.



**Figure 5.** Detektor bradavice. Zľava do prava: poškodený odtlačok, predikcia rekonštrukcie a úprava predikcie filtrom.

[4] Martin Drahanský. *Fingerprint Recognition Technology - Related Topics*. Lambert Academic Publishing, Lambert Academic Publishing, 2011. 207 208 209

[5] Francois Chollet. Building autoencoders in keras. 210 online, 2016. 211

172

## 173 7. Záver

174 Vytvorená neurónová sieť dokáže pomerne dobre rekon-  
175 štruovať syntetické odtlačky s bradavicami. Kvalita  
176 rekonštrukcie bola meraná pomocou programu Verifin-  
177 ger. Učenie siete trvá zhruba 36 hodín. Skóre zhody  
178 pôvodného obrázku a obrázku po rekonštrukcii sa  
179 zvýšilo v priemere o 16%. Rekonštrukcia poškodenia  
180 syntetických odtlačkov je možná, bola ukázaná rekon-  
181 štrukcia bradavíc o priemere zhruba 80 pixelov. Oproti  
182 konvenčným spôsobom táto metóda nevyžaduje nároč-  
183 né matematické výpočty, a je taktiež škálovateľná.  
184 Čiže zväčšením robustnosti siete môžeme získať ešte  
185 lepšie výsledky.

186 Ako možné rozšírenie sa naskytá použitie inej architek-  
187 túry, zväčšenie počtu vrstiev alebo rekonštrukcia reál-  
188 ných odtlačkov prstov. Ďalším možným rozšírením  
189 je naučenie siete rekonštruovať ďalšie ochorenia alebo  
190 poškodenia. Preskúvanie možností detektora poško-  
191 denia alebo generátora je taktiež jedno z možných  
192 rozšírení. Ďalším možným vylepšením je zautomati-  
193 zovanie merania kvality rekonštrukcie.

## 194 Poďakovanie

195 Chcel by som poďakovať môjmu vedúcemu diplomovej  
196 práce, doktorovi Ondřejovi Kanichovi za poskytnuté  
197 materiály a pomoc pri vytváraní práce.

## 198 Literatúra

199 [1] Group 107. Fingerprint inpainting with generative  
200 models. 2018.

201 [2] Shervin Minaee and AmirAli Abdolrashidi.  
202 Finger-gan: Generating realistic fingerprint im-  
203 ages using connectivity imposed GAN. *CoRR*,  
204 abs/1812.10482, 2018.

205 [3] Jain Anil, Flynn Patrick, and Ross Arun. *Hand-  
206 book of Biometrics*. Springer, 1 edition, 2008.