

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Aljoša Rakita

**Prenos slikarskega stila s pomočjo
globokih nevronske mrež**

DIPLOMSKO DELO

UNIVERZITETNI ŠTUDIJSKI PROGRAM
PRVE STOPNJE
RAČUNALNIŠTVO IN INFORMATIKA

MENTOR: prof dr. Franc Solina
SOMENTOR: viš. pred. dr. Borut Batagelj

Ljubljana, 2018

COPYRIGHT. Rezultati diplomske naloge so intelektualna lastnina avtorja in Fakultete za računalništvo in informatiko Univerze v Ljubljani. Za objavo in koriščenje rezultatov diplomske naloge je potrebno pisno privoljenje avtorja, Fakultete za računalništvo in informatiko ter mentorja.

Besedilo je oblikovano z urejevalnikom besedil L^AT_EX.

Fakulteta za računalništvo in informatiko izdaja naslednjo nalogo:

Kandidat: Aljoša Rakita

Naslov: Prenos slikarskega stila s pomočjo globokih nevronske mreže

Vrsta naloge: Diplomaska naloga univerzitetnega programa prve stopnje – študij računalništvo in informatika

Mentor: prof. dr. Franc Solina

Opis:

Raziščite fenomen prenosa stila s pomočjo globokih nevronske mreže. Za preizkus tega fenomena uporabite slike slovenskih impresionistov in na osnovi njihovega stila zgenerirajte umetne slike. S pomočjo spletne ankete ugotovite, ali so naključno izbrani ljudje sposobni ločiti tako zgenerirane slike od pravih slik slovenskih impresionistov.

Title: Painting style transfer with deep neural networks

Description:

Research the phenomenon of style transfer using deep neural networks. For demonstration of this phenomenon use paintings of Slovenian impressionists and based on their style generate “fake” pictures. Using a web survey find out, if accidentally selected people could distinguish such “fake” pictures from the real painting of slovenian impressionists.

*Zahvaljujem se svojim staršem in prijateljem, posebno zahvalo pa si zaslužita
Sebastian in mentor profesor Solina.*

Kazalo

Povzetek

Abstract

1	Uvod	1
1.1	Pregled področja in sorodnih del	3
2	Globoke nevronske mreže	5
2.1	Kratka zgodovina	6
2.2	Uporaba	7
3	Umetnostno ozadje	9
3.1	Definicija stila	9
3.2	Impresionizem	10
3.3	Izbor slik	11
3.4	Različni pristopi h generiranju „lažnih“ slik	12
4	Metodologija	15
4.1	Predstavitev vsebine slike	15
4.2	Predstavitev stila slike	17
4.3	Prenos stila	18
5	Demonstracija delovanja	19
5.1	Implementacija metode	19
5.2	Izdelava slik	20

6	Rezultati ankete o razlikovanju pravih in generiranih slik	29
6.1	Rezultati ankete	30
6.2	Interpretacija rezultatov ankete	61
7	Zaključek	65
	Literatura	67

Seznam uporabljenih kratic

kratica	angleško	slovensko
NN	neural networks	nevronske mreže
DNN	deep neural networks	globoke nevronske mreže
CNN	convolutional neural networks	konvolucijske nevronske mreže
BP	back-propagation	vzratno razširjanje

Povzetek

Naslov: Prenos slikarskega stila s pomočjo globokih nevronske mreže

Avtor: Aljoša Rakita

V tej diplomski nalogi, je najprej razloženo kaj so sploh globoke nevronske mreže in kratka razlaga njihovega delovanja. Nato je nekaj besed nemenjenih temu kako je stil slike definiran in kaj vse predstavlja. Po tem, je natančno razloženo in analizirano delovanje specifične metode za prenos stila izbrane slike na ciljno sliko s pomočjo globokih nevronske mreže. Temu sledi demonstracija delovanja, kjer smo naredili „lažne“ slike s pomočjo stila znanih slovenskih impresionistov. Zaključili pa smo s spletno anketo, ki je preverila kako realne so producirane slike, to je ali so naključno izbrani ljudje sposobni ločiti tako generirane „lažne“ slike od pravih slik slovenskih impresionistov.

Ključne besede: prenos stila, globoke nevronske mreže, analiza.

Abstract

Title: Painting style transfer with deep neural networks

Author: Aljoša Rakita

What are deep neural networks and how they work is explained first in this diploma thesis. Next, we describe what is a painting style and what determines the style. With deep neural networks one can transfer the painting style from a selected source image to another target image. We demonstrate style transfer by making “fake” pictures using paintings of Slovene impressionist painters. At the end we made a web survey to find out, if randomly selected people could distinguish such “fake” pictures from the real painting of slovenian impressionists.

Keywords: style transfer, deep neural network, analysis.

Poglavje 1

Uvod

Za to temo sem se odločil, ker se mi zdi celotno področje umetne inteligence zelo zanimivo in perspektivno. Naloga bo razložila in analizirala sistem za prenos stila slik s pomočjo globokih nevronske mreže. Poleg tega bo služila tudi kot neka kritična ocena, kako sposobne so sodobne metode umetne inteligence ustvariti nekaj zelo človeškega — to je umetniško delo.

Umetna inteligenca v takšni ali drugačni obliki buri človeško domišljijo že od kar poznamo pojem znanost. Pred 20. stoletjem je bila umetna inteligenca večinoma pojav v mitih in zgodbah, s pojavom računalnikov v sredini 20. stoletja pa so ideje umetne inteligence dobile realno možnost uresničitve. S področjem se je začelo ukvarjati vedno več raziskovalcev, kar je pripeljalo do vedno hitrejšega napredka. Umetna inteligenca se je najprej uveljavila na tehničnih in medicinskih področjih, ter igrah, kot je na primer šah, kjer je bilo možno podatke zapisati s simboli. Postopoma pa se je začela širiti tudi na področja, kjer so podatki bolj kompleksni, kot so na primer slike in drugi signali. Umetna inteligenca je računalnikom omogočila stvari, za katere si ljudje niso mogli niti predstavljati, da so mogoče in na številnih področjih je umetna inteligenca začela pri odločitvah nadomeščati človeka, ali pa mu je pri odločitvah vsaj svetovala.

Skozi leta je interes za umetno inteligenco rasel in njene metode so se izkazale kot močno orodje za pregledovanje podatkov in iskanje vzorcev v po-

datkih. Danes si računalništva skoraj ne moremo predstavljati brez področja umetne inteligence, vpliv umetne inteligence pa je očiten tudi na številnih uporabniških področjih. V 21. stoletju je uporaba umetne inteligence presešla ozko tehnično in poslovno orientirano uporabo, saj je zaradi vsesplošne digitalizacije postalo možno eksperimentirati z uporabo računalnikov in umetne inteligence tudi v humanistiki in umetnosti.

S pomočjo umetne inteligence, predvsem z nevronskimi mrežami, je danes možno ustvarjati slike, ki zelo prepričljivo posnemajo stil drugih izbranih slik oziroma slikarjev. Oktobra letos bo v dražbeni hiši „Christie’s“ v New Yorku organizirana dražba umetniških del, ki so produkt umetne inteligence. To bo prva taka dražba v priznani dražbeni hiši. Navkljub dilemi, ali lahko dela, ki so produkt računalnikov oziroma algoritmov, označimo kot umetnost, veliko ljudi kaže zanimanje za tako umetnost. V diplomski nalogi smo si zato zadali nalogo, da preučimo in uporabimo metodologijo nevronskih mrež za generiranje slik, ki bodo posnemale slike slovenskih impresionistov. Umetniki so sicer računalnike hitro sprejeli kot novo orodje za umetniško izražanje in predvsem generativna umetnost računalniške algoritme učinkovito uporablja za kreacijo likovnih izdelkov, bodisi z matematičnim formalizmom fraktalov ali s formalizmom oblikovnih slovnice [5]. Vendar pa običajno umetniki, ki uporabljajo računalnike, tega dejstva ne skrivajo. Najnovejši trend uporabe nevronskih mrež za kreiranje umetniških del, pa na nek način želi ustvariti videz, kot da so te slike delo človeških rok. Kratek uvod v zgodovino uporabe računalnikov v likovni umetnosti je na voljo v [16].

V 2. poglavju bomo na kratko predstavili kaj so globoke nevronske mreže in kako delujejo. Videli bomo, da so nevronske mreže zelo močno orodje umetne inteligence in tudi zakaj so primerne za problematiko, ki jo obravnavamo v tej diplomski nalogi. Kako je definiran stil slike in kaj sploh stil je, bomo opisali v 3. poglavju, ki pojasni tudi umetniško plat te diplomske naloge. V 4. poglavju bomo predstavili aktualne tehnike, ki predstavljani problem rešujejo s pomočjo globokih nevronskih mrež, njihove prednosti ter slabosti in primernost njihove uporabe. Predstavitev odprtokodnih realizacij

teh metod, prikaz njihovega delovanja in izdelava „fake“ slik bo opisano v 5. poglavju. V diplomu smo se zavestno odločili, da bomo za demonstracijo teh metod uporabili slike slovenskih avtorjev. Poglavje 6 se bo osredotočilo na analizo in interpretacijo rezultatov s pomočjo ankete. V zaključnem, to je 7. poglavju, bo podana kritična ocena uporabljenih metod in končni sklep: ali je umetna inteligenca danes že sposobna samostojno ustvariti umetniške slike, za katero se človek ni sposoben odločiti, ali so delo računalnika ali človeka.

Rezultati te naloge naj bi koristili širši interesirani javnosti za lažje razumevanje tega povsem novega področja, ki metode umetne inteligence povezuje z likovno umetnostjo, kot tudi strokovnjakom za umetno inteligenco kot pomoč pri izbiri ustreznih metod.

1.1 Pregled področja in sorodnih del

Metode uporabljene v diplomu so podrobno opisane v naslednjih delih:

- *Image style transfer using convolutional neural networks* [4]: Predstavi sistem, ki temelji na globokih nevronske mrežah, ki ustvari visokokvalitetne umetniške slike. Članek naredi korak naprej v razumevanju, kako ljudje ustvarjamo in zaznavamo umetnost.
- *Preserving color in neural artistic style transfer* [2]: Nadaljevanje zgornjega članka, ki se loti problemov in pomankljivosti opisanega algoritma. Opiše preproste linearne metode, ki problem rešijo. Implementacijo tega algoritma smo tudi uporabili za sintezo umetnih slik v diplomu.
- *Texture Networks: Feed-forward Synthesis of Textures and Stylized Images* [17]: V tem članku je predstavljen sistem, ki slike zna generirati hitreje, saj je večina obdelave predstavljena v fazo učenja nevronske mreže.
- *Texture Synthesis Using Convolutional Neural Networks* [3]: Članek

demonstrira generiranje tekstur na slikah s pomočjo konvolucijskih nevronske mreže.

Poglavje 2

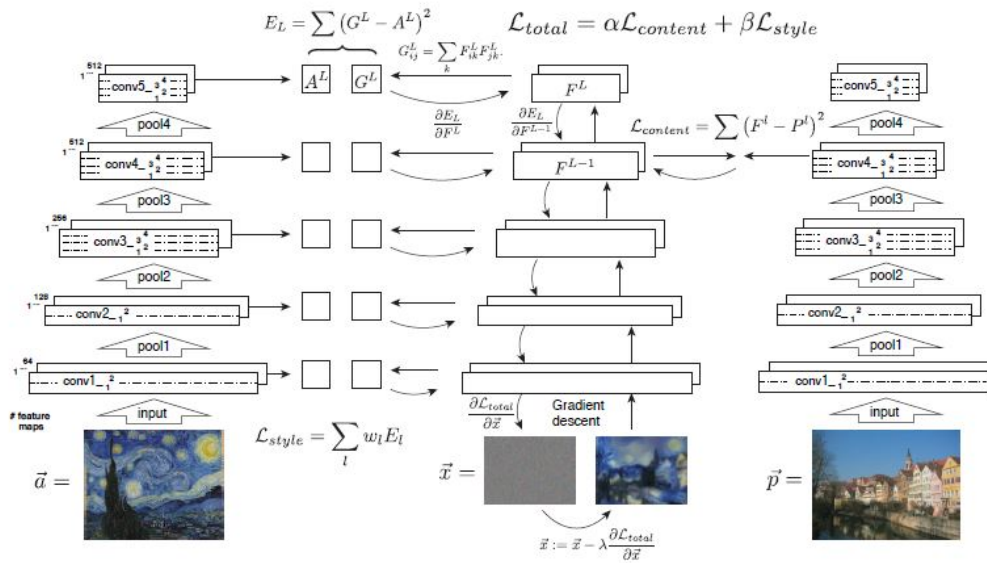
Globoke nevronske mreže

S pojmom nevronskih mrež označujemo množico algoritmov, ki so naučeni razpoznavati določene vzorce v podatkih. Nevronske mreže spadajo na področje umetne inteligence, njihovo poimenovanje pa izvira iz dejstva, da delujejo konceptualno podobno kot človeški možgani.

Nevronske mreže so zgrajene iz velikega števila vozlišč imenovanih nevroni, kjer se izvajajo računske operacije. V vsako vozlišče vodi vhod, ki je ponavadi razdeljen na več delov, kar običajno zapišemo v vektorski obliki. Vhodni nevroni se aktivirajo preko sensorjev, ki zaznavajo okolje ali pa preko drugih vhodnih vrednosti. Ostali nevroni, globlje v nevronske mreži, pa se aktivirajo preko uteženih povezav s predhodnimi „aktiviranimi“ nevroni. Vrednosti vektorja, transformiranega preko uteži, se seštevajo in prenesejo na izhod. Tako dodeljujejo prioriteto vhodnim vektorjem za nalogo, ki se jo nevronska mreža uči.

Proces učenja v nevronskih mrežah (angleško neural network – NN) torej temelji na določanju tistih uteži, ki pripeljejo NN do želenega obnašanja. To obnašanje, odvisno seveda od zastavljenega problema in arhitekture NN (kako so nevroni med seboj povezani), lahko zahteva dolge verige računskih operacij oziroma plasti nevronov, kjer vsaka plast vpliva na aktivacijo naslednjih plasti. Pojem globoko učenje izvira ravno iz velikega števila nevronskih plasti. Izhod ene plasti je vhod v drugo in tako naprej, med njimi pa ponavadi

najdemo tako imenovane aktivacijske funkcije, ki določijo ali in koliko signala se prenese v naslednjo plast nevronov (primer take arhitekture lahko vidimo na sliki 2.1). Pri globokem učenju se vsaka plast vozlišč uči na množici lastnosti, ki temeljijo na prejšnji plasti. Globlje gremo v nevronske mreže, bolj kompleksne lastnosti so mreže sposobne prepoznati, saj se lastnosti seštevajo in kombinirajo z lastnostmi prejšnjih plasti — temu pravimo tudi hierarhija lastnosti [13].



Slika 2.1: Arhitektura sistema globokih nevronske mreže, kot ga bomo uporabili v diplomski nalogi. Slika je povzeta po [4].

2.1 Kratka zgodovina

Začetki nevronske mreže segajo v štirideseta leta 20. stoletja, ko sta McCulloch in Pitts predstavila NN arhitekturo, ki pa se še ni bila sposobna učiti [10]. Naslednja desetletja so prinesla preproste NN trenirane s pomočjo nadzorovanega in nenadzorovanega učenja. V nekem smislu pa zametki NN segajo že v začetek 19. stoletja, ko so bile NN v bistvu različice metod linearne regresije [13].

Prve globoke nevronske mreže (angleško deep neural network – DNN) so bile natrenirane s pomočjo metode GMDH (Group Method of Data Handling) leta 1966 [7]. Imele so polinomske aktivacijske funkcije, število plasti pa so določili s postopnim povečevanjem na testnih podatkih, nato pa z zmanjševanjem preko „obrezovanja“ in preverjanja na validacijski množici.

Leta 1979 Fukushima [1] predstavi konvolucijske NN (angleško convolutional neural network – CNN), ki so po arhitekturi zelo podobne današnjim NN in vsebujejo izmenjujoče se konvolucijske plasti ter plasti za podvzorčenje. Seveda pa tudi ta način ni bil popoln, Fukushima je uteži določil z lokalnimi funkcijami oziroma ročno in ne preko vzvratnega razširjanja (angleško backpropagation – BP), to je z dinamičnim nastavljanjem uteži, kar omogoči, da se stopnja napake prenese po mreži in upošteva pri določanju vrednosti uteži. Ta koncept je bil znan že od začetka šestdesetih let prejšnjega stoletja, ko so v sistemih izvajali BP s pomočjo gradientnega sestopa. BP, namenjen specifično NN, je bil predstavljen v [18] leta 1982 in je bil populariziran do konca osemdesetih preko različnih člankov in ostalih znanstvenih del.

Skozi devedeseta so raziskovalci mrežam dodajali plasti ter eksperimentirali z različnimi načini BP. NN so postajale vse globlje in uporabljati so jih začeli na zelo raznolikih področjih. V tem obdobju so NN sistemi začeli zmagovati na različnih tekmovanjih v iskanju vzorcev v podatkih.

V naslednjem desetletju so se NN razširile na vsa možna področja uporabe in na nekaterih tudi dominirale. Postavile so vrsto rekordov in stopile tudi v komercialno uporabo. V zadnjih letih so se še bolj izpopolnile in njihova uporaba se je še bolj razširila, predvsem na področju računalniškega vida si ne moremo predstavljati napredka brez nevronske mreže [9].

2.2 Uporaba

Konvolucijske nevronske mreže se uporabljajo za reševanje raznovrstnih problemov; lahko klasificirajo ali pa gručijo. Trenutno je njihov vpliv najbolj opazen na naslednjih področjih uporabe:

- avtomatska prepoznavna govora,
- prepoznavna slik/objektov na slikah,
- procesiranje naravnega jezika,
- toksikologija,
- robotika,
- organiziranje odnosa s strankami,
- priporočilni sistemi,
- bioinformatika,
- procesiranje vizualne umetnosti (npr. za avtomatsko prepoznavo slikarja iz digitalne slike [6]),
- generiranje vizualne umetnosti,
- itd.

V diplomu smo CNN uporabili tako, da smo na vhod postavili dve sliki, se iz prve naučili njen stil in nato ta stil prenesli na drugo sliko. Podroben opis delovanja take CNN sledi v 4. poglavju Metodologija. Najprej pa bomo razložili, kaj je stil neke slike.

Poglavje 3

Umetnostno ozadje

Za demonstracijo in razlago digitalnega prenosa sloga bomo uporabili dela slovenskih impresionistov. Dela slikarjev slovenskega impresionizma nam ponujajo sklenjene slogovne sklope, ki so v svojih formalnih karakteristikah za učinkovitost računskih operacij še posebej primerni. Kljub temu, da je opus slovenskih impresionistov heterogen, tako v celoti, kot v primerih posameznih ustvarjalcev, pa vključuje segmente s formalnimi vzorci, ki so za prenos stila zelo primerni. Ker računalniški program računa na čim bolj slikovito in likovno regularno površino, se zaradi specifičnosti svojega načina slikanja, izmed vseh likovnih paradigem za prenos stila najboljše obnese prav impresionizem. Posebnost površine impresionističnega dela je odvisna od specifičnega postopka njenega nastanka. Da bi bolje razumeli likovno kvaliteto impresionistične slike, bomo najprej povedali nekaj besed o stilu/slogu, impresionizmu kot takemu, o izvoru impresionističnega gibanja in njegovi likovni logiki ter nato namenili nekaj besed nacionalnim specifikam slovenskih ustvarjalcev in njihovih slikarskih opusov.

3.1 Definicija stila

V umetnosti se pojem stil slike definira kot lastnost, ki nam pomaga razvrščati umetniška dela v raznolike kategorije oziroma katerikoli prepoznavni način

ali metoda, ki se uporablja za izdelavo oziroma izvedbo dela. Nanaša se na vizualni izgled umetniškega dela, ki je prisoten v vseh delih istega avtorja ali nekoga iz istega obdobja, urjenja, lokacije, „šole“, umetniškega gibanja oziroma kulture [19].

Stil običajno delimo glede na časovno obdobje, državo, kulturno skupino, skupino umetnikov oziroma umetniško gibanje ter stil posameznika znotraj teh skupin. V tej diplomski nalogi se bomo srečali s slovenskim impresionizmom, katerega bomo uporabili za učenje globokih nevronske mreže in za izdelavo lažnih (angleško fake) slik. Besedo „fake“ smo si izposodili iz konteksta „fake“ ali lažnih novic, saj pri umetno generiranih slikah tudi želimo ustvariti vtis, da gre za pravo oziroma originalno sliko, ki jo je naslikal določen umetnik.

3.2 Impresionizem

Impresionizem je umetniški stil iz druge polovice 19. stoletja, za katerega je značilno, da so umetniki dajali poudarek natančnemu prikazu svetlobe, na slikah pa so bile majhne, tanke, a vendar vidne poteze čopiča. Motivi so bili vsakdanji, „običajni“ dogodki, s vključevanjem gibanja kot ključnega elementa človeškega zaznavanja in občutenja.

Impresionizem je bil začet v Parizu s strani skupine umetnikov, ki so bili opaženi preko samostojnih razstav. Ime pa je dobil po sliki Clauda Moneta: *Impression, soleil levant* (Impresija, vzhajajoče sonce) [11].

Impresionizem ni in že tedaj ni bil le francoski fenomen. Kmalu potem, ko je impresionizem takorekoč škandalozno eksplodiral v francosko javnost, se je stil razširil po večjih evropskih deželah in nastale so posamezne nacionalne šole, ki so njegove postopke in tehnike sprejele, pri čemer je bila recepcija pogosto nacionalno pogojena in je vodila do specifičnih impresionističnih stilov.

Impresionizem je na slovensko področje prišel pozno, tj. približno pol stoletja po svojem izvoru [12]. Zaradi velike časovne razlike je prišlo do

marsikatero spremembo, ki tedanji impresionizem loči od prvotnega tako na ravni forme kot na ravni vsebine. Impresionizem je v kontekstu ustvarjanja slovenskih slikarjev označeval širše pomensko polje, kot ga je označeval na Francoskem. Slovenski impresionizem je bil v osnovi eklektično slikarstvo, ki je črpalo iz različnih slikarskih vplivov in posredovalo raznorodna načela slikanja. Slogovne prvine so bile osebno izbrane in proste od zahtev močnih optičnih načel. Na institucionalni ravni je bilo za razliko od močnega organiziranega gibanja, ki zaznamuje francoski impresionizem, povezovanje slovenskih slikarjev šibkejše. Zgodnja razstava na Dunaju je uspela, medtem ko je bilo padanje uspeha čutiti že v prvih dveh slovenskih razstavah, kar je bilo pogojeno s slovenskim trgom in slovensko javnostjo, ki novosti ne podpira. Kljub temu, da se je slovenski impresionizem konstituiral kot izrazito narodno-tvorna funkcija v času iskanja elementov narodne-identifikacije, finančno ni bil uspešen.

3.3 Izbor slik

Pri celotnem umetnostnem vidiku te diplome, sploh pa pri izboru slik slovenskih impresionistov, mi je pomagal Sebastian Korenič Tratnik, ki je tudi avtor vseh novo posnetih fotografij, uporabljenih za vsebinsko podlago prenosa stila.

V obravnavo smo vzeli popularnejša dela naslavnejših slikarjev slovenske moderne. Pri vsakem slikarju smo skušali najti tako slogovno kot motivno reprezentativna dela, ki skupaj tvorijo celoto. Ker je opus impresionistov raznolik, je bilo potrebno izbrati dela, ki si delijo nekaj osnovnih stilističnih parametrov. V opusih smo skušali najti serije slik, ki so bile narejene v podobni maniri in izhajajoč iz istih formalnih izhodišč. Ni naključno, da smo prišli do slogovnih obdobij, v katerih so slikarji ustvarili svoje največje mojstrovine. Raziskovanje določenega sloga je dolgotrajen proces, ki postopno vzpostavlja notranje zakonitosti likovne logike, ki konstituirajo stilistično matrico. Delanje variant znotraj istih formalnih določil vodi do tega, da se

slog postopoma izčiščuje, kar pogosto za sabo potegne tudi porast likovne kvalitete.

- Pri Groharju smo se osredotočili na slog, po katerem je najbolj poznan in v katerem so narejena njegova najbolj slavna dela (Sejalec, Pomlad, Breze). Osnovna barvna paleta: zeleno-roza. Motivi: Krajine, žanr.
- Pri Sternenu smo se osredotočili na njegove akte, natančneje na rdeče-zeleno barvno izhodišče. Osnovna barvna paleta: rdečo-zelena. Motivi: ležeči ženski akt.
- Pri Jami smo se osredotočili na njegove žanre. Osnovna barvna paleta: zeleno-rjava-bela. Motivi: Žanrski prizori.
- Pri Jakopiču smo se osredotočili na njegove barvno zlahtne bogate interiere in njegov motiv Križank. Pri Križankah, ki jih je obdelal z različnimi stili, smo skušali nadaljevati slogovno permutacijo, pomešati stile ipd.

Nadalje smo se pri vseh slikarjih lotili tudi slik z motivom krajinske vedute, ki so jih delali v različnih obdobjih svojega življenja in ki imajo le redko ob sebi niz stilno podobnih del. Več o umetnostno zgodovinskem vidiku teh eksperimentov smo napisali v članku, ki ga pripravljamo [8].

3.4 Različni pristopi h generiranju „lažnih“ slik

Postopek procesiranja je v osnovi temeljil na izbiri slikarske predloge iz katere smo sintetizirali slikarski stil, produkciji ali izbiri fotografske osnove ter aplikacije sintetiziranega stila na to osnovo. Gre za vzvraten proces samega dela impresionistov, ki kot vemo, večino dela niso naredili na prostem, temveč v ateljeju, izhajajoč iz fotografij. Medtem, ko so elemente posameznih fotografij pogosto kombinirali, ter jih niso upoštevali popolnoma (vendar bolj za

navdih), pa obstajajo primeri s skoraj povsem homolognim odnosom. Kontrast med starimi analognimi fotografijami, ki deloma izhajajo iz zapuščine slovenskih impresionistov in ki smo jih poiskali v arhivu Narodne galerije v Ljubljani, in po njih narejenimi oljnimi slikami ter novejšimi digitalnimi fotografijami in po njih zmodeliranimi lažnimi slikami nam podaja zanimive nastavke za tematizacijo samega procesa stilotvorja.

Nismo se omejili le na enosmerni proces prenosa, temveč smo izhajali iz nekaj temeljnih operacij, preko katerih smo prišli do močnejših ramifikacij, ki presegajo področje tehnologije in vstopajo v umetnostno teorijo. Operacije, ki smo jih izvajali, so sledeče:

- Prenos stila iz slike na fotografijo, pri čemer je slikarska predloga kompozicijsko podobna fotografski osnovi.
- Prenos stila iz slike na fotografijo, pri čemer slikarska predloga ni kompozicijsko podobna fotografski osnovi.
- Prenos stila iz fragmenta slike na fotografijo, ki je kompozicijsko podobna ali različna fotografski kompoziciji.
- Prenos stila iz kombinacije slikarskih predlog, ki tvorijo novo kompozicijsko celoto, na fotografijo, ki je strukturalno podobna ali različna fotografski kompoziciji.
- Prenos kombinacije različnih slikarskih predlog, ki tvorijo novo stilistično celoto, na fotografijo, ki je strukturalno podobna ali različna fotografski kompoziciji.
- Prenos stila na podlagi vseh zgoraj navedenih principov med kompozicijskimi in stilističnimi celotami in fragmenti med deli vseh impresionistov in njim strukturalno podobnimi in različnimi fotografskimi predlogami.

Poglavje 4

Metodologija

Algoritem, ki smo ga uporabili, temelji na globokih nevronske mrežah VGG [4], ki so bile naučene za zaznavo in lokalizacijo objektov na slikah. Arhitektura mrež je sestavljena iz zelo majhnih (3×3) konvolucijskih filtrov in ima globino 16–19 plasti. Mreže so bolj obširno opisane v [14].

Omenjene mreže so v uporabljenem algoritmu normalizirane, kar pomeni, da so uteži nastavljene tako, da je povprečna vrednost aktivacije vsakega konvolucijskega filtra čez vse slike in pozicije enaka ena. Druga sprememba pa je sprememba načina združevanja. V originalnih mrežah je uporabljen postopek, ki iz določene regije obdrži samo največjo vrednost, to je „max-pooling“, v naših mrežah pa je uporabljen postopek, ki obdrži povprečno vrednost oziroma „average-pooling“, kar privede do nekoliko boljših rezultatov.

4.1 Predstavitev vsebine slike

V DNN vsaka plast predstavlja nelinearno shrambo za rezultate filtrov, katere kompleksnost narašča glede na pozicijo v mreži. Tako je vhodna slika \vec{x} v vsaki plasti zakodirana glede na odzive filtrov na to sliko. Plast z N_l različnimi filtri proizvede N_l „aktivacijskih map“ (mapa, kjer so shranjeni odzivi filtrov), ki imajo velikost M_l , kjer je M_l višina krat širina aktivacijske

mape. Odzive plasti l torej lahko shranimo v matriko

$$F^l \in R^{N_l \times M_l}$$

kjer je F^l_{ij} aktivacija i -tega filtra na poziciji j v plasti l .

Da bi vizualizirali podatke o sliki, ki so zakodirani na različnih plasteh, moramo narediti gradientni sestop na sliki belega šuma (angleško „white noise“, glej sliko 2.1), da dobimo novo sliko, ki ustreza odzivom filtrov, ki jih je producirala originalna slika. Naj bosta \vec{p} originalna in \vec{x} generirana slika, P^l ter F^l pa njune predstavitve v plasti l . Nato lahko definiramo funkcijo kvadratne napake med dvema predstavitvama kot:

$$L_{\text{vsebina}}(\vec{p}, \vec{x}, l) = \frac{1}{2} \sum_{i,j} (F^l_{ij} - P^l_{ij})^2$$

Odvod te funkcije izgube glede na aktivacije plasti l je tako:

$$\frac{\partial L_{\text{vsebina}}}{\partial F^l_{ij}} = \begin{cases} (F^l - P^l)_{ij}, & \text{če } F^l_{ij} > 0 \\ 0, & \text{če } F^l_{ij} < 0 \end{cases} \quad (4.1)$$

iz česar lahko s standardno napako BP izračunamo gradient glede na sliko \vec{x} . S tem postopkom lahko spreminjamo naključno začetno sliko \vec{x} , dokler ne generira istega odziva na določeni plasti konvolucijske nevronske mreže (CNN) kot originalna slika \vec{p} .

CNN z učenjem za prepoznavo objektov razvijejo predstavitve slike, ki povzročijo, da so informacije o objektih, višje ko gremo po plasteh, vedno bolj eksplisitne (poudarjene) [3]. Tako se vhodna slika, skozi hierarhijo plasti, pretvori v predstavitve, ki so vedno bolj občutljive na dejansko vsebino slike. V višjih plasteh torej najdemo predstavitve ki zajamejo vsebino (kaj je na sliki in kako je postavljeno) ampak ne omejujejo dejanske vrednosti pikslov, nižje plasti pa vsebujejo predstavitve, ki preprosto vrnejo vrednosti originalne slike.

4.2 Predstavitev stila slike

Da bi dobili predstavitev stila vhodne slike, uporabimo prostor lastnosti, ki je namenjen za zajem informacij o teksturi [3]. Ta prostor lahko zgradimo na katerikoli plasti, iz korelacij odzivov različnih filtrov. Te korelacije pa nam daje Gramova matrika $G^l_{ij} \in R^{N_1 \times N_1}$, kjer je G^l_{ij} notranji produkt vektoriziranih aktivacijskih map i in j v plasti l :

$$G^l_{ij} = \sum_k F^l_{ik} F^l_{jk} .$$

Če združimo korelacije večih plasti, dobimo obsežno predstavitev vhodne slike, ki zajema informacije o teksturi, ne pa kompozicije.

Da bi vizualizirali podatke na različnih plasteh, moramo zopet minimizirati povprečno kvadratno razdaljo (ang. mean-squared distance) med elementi originalne Gramove matrike in pa elementi Gramove matrike slike, ki jo generiramo [3].

Naj bosta \vec{a} originalna in \vec{x} generirana slika, A^l ter G^l pa njune predstavitve v plasti l . Prispevek plasti l k celotni izgubi je torej:

$$E_l = \frac{1}{4N_1^2 M_1^2} \sum_{i,j} (G^l_{ij} - A^l_{ij})^2$$

celotna izguba stila pa je:

$$L_{stil}(\vec{a}, \vec{x}) = \sum_{l=0}^L w_l E_l ,$$

kjer so w_l uteži, ki vplivajo na to, kako pomembna je katera plast. Odvod E_l glede na odzive filtrov v plasti l lahko izračunamo s pomočjo sledeče enačbe:

$$\frac{\partial E_l}{\partial F^l_{ij}} = \begin{cases} \frac{1}{N_1^2 M_1^2} ((F)^T (G^l - A^l))_{ij}, & \text{če } F^l_{ij} > 0 \\ 0, & \text{če } F^l_{ij} < 0 \end{cases} \quad (4.2)$$

Gradiente E_l glede na vrednosti pikslov \vec{x} , pa lahko izračunamo s standardno BP.

4.3 Prenos stila

Da prenesemo stil iz umetniškega dela \vec{a} na fotografijo \vec{p} , generiramo novo sliko, ki se ujema z vsebinsko predstavitvijo slike \vec{p} in predstavitvijo stila slike \vec{a} . Tako moramo hkrati minimizirati razdaljo med odzivi fitrov na sliko belega šuma in vsebinsko predstavitvijo fotografije v eni plasti ter razdaljo med stilsko predstavitvijo, definirano preko večih plasti CNN, ki imajo tako arhitekturo kot prikazuje slika 2.1. Funkcija izgube, ki jo minimiziramo je:

$$L_{\text{total}}(\vec{p}, \vec{a}, \vec{x}) = \alpha L_{\text{vsebina}}(\vec{p}, \vec{x}) + \beta L_{\text{stil}}(\vec{a}, \vec{x}) \quad ,$$

kjer sta α in β uteži za rekonstrukcijo vsebine in stila.

Gradient glede na vrednosti pikslov $\frac{\partial L_{\text{total}}}{\partial \vec{x}}$ lahko uporabimo kot vhodne vrednosti algoritma za numerično optimizacijo. Tu smo uporabili optimizacijski algoritem L-BFGS [20], za katerega so ugotovili, da pri generiranju slik deluje najbolj. Da bi se dalo izluščene informacije o stilu čim bolje prenesti na vsebino, algoritem vedno spremeni velikost sliki stila tako, da ima iste dimenzije kot slika vsebine.

Poglavje 5

Demonstracija delovanja

5.1 Implementacija metode

Za generiranje „umetnih“ slik smo uporabili python aplikacijo *neural-style-tf*, ki temelji na omenjenih VGG nevronskih mrežah za zaznavo in lokalizacijo objektov [14]. Storitve je prosto dostopna na spletnem naslovu <https://github.com/cysmith/neural-style-tf> [15].

Aplikacija podpira napredno uporabo s pomočjo velikega števila argumentov, s katerimi lahko določimo:

- maksimalno velikost izhodne slike (v našem primeru 512×512),
- vpiv stila oziroma vsebine,
- ali naj se obdržijo originalne barve,
- način vzorčenja (max, avg),
- s katero „napravo“ bomo procesirali (algoritem podpira uporabo GPU in CPU),
- kateri algoritem za numerično optimizacijo naj se uporabi (v našem primeru L-BFGS)
- itd.

5.2 Izdelava slik

Sam proces generiranja slik ni bil pretirano zahteven, ampak je bil zato zelo dolgotrajen. Razlog za to dolgotrajnost je, da smo za procesiranje uporabili prenosni računalnik. Računalnik je imel CPU Intel Core i7-5500U @ 2.40GHz s 6GB RAM-a, operacijskim sistemom Windows 10 (64bit) in brez možnosti procesiranja na GPU. Tako je čas prenosa stila na eno fotografijo dimenzije 512×512 v povprečju dosegal dve uri in pol.


Na fotografije smo prenesli različne stile, da bi dobili najbolj prepričljive rezultate. Eksperimentirali pa smo tudi z nastavljanjem uteži vsebine oziroma stila in uporabo originalnih barv. Ponekod smo tudi združili več stilov in jih prenesli na izbrano fotografijo. Procesiranje vsake slike posebej je bolj podrobno opisano v nadaljevanju.

5.2.1 Generiranje slik

Skupaj smo proizvedli nabor z več kot 50 slikami, iz katerega smo izbrali 16 najbolj prepričljivih (realnih), ki smo jih nato skupaj še s 14 slikami, ki so delo slikarjev, vključili v anketo.


Algoritem ima, če ne uporabimo dodatnih argumentov, nastavljene privzete vrednosti. V nadaljevanju, če ni posebej zapisano drugače, so uporabljene privzete vrednosti naslednje: 512×512 : maksimalna velikost izhodne slike, utež vsebine: 5, utež stila: 10.000, naprava: /cpu:0, optimizacijski algoritem: L-BFGS z maksimalno 1000 iteracijami.

Generirani rezultati s kratkim opisom procesa izdelave je prikazano v slikah od 5.1 do 5.16




(a) Vsebina. (b) Stil: R. Jakopič - Sončni breg. (c) Rezultat.

Slika 5.1: Postopek generiranja slike št. 10.




(a) Vsebina. (b) Stil: R. Jakopič - Sončni breg. (c) Rezultat.

Slika 5.2: Postopek generiranja slike št. 28.



(a) Vsebina. (b) Stil: I. Grohar-Hribček. (c) Rezultat.

Slika 5.3: Postopek generiranja slike št. 27.




(a) Vsebina.

(b) Stil: I. Grohar–
Sejalec.

(c) Rezultat.

Slika 5.4: Postopek generiranja slike št. 49.




(a) Vsebina.

(b) Stil: I. Grohar–
Hribček.

(c) Rezultat.

Slika 5.5: Postopek generiranja slike št. 16, z utežjo stila povečano na 200.000



(a) Vsebina.

(b) Stil: R. Jakopič–
Sončni breg.


(c) Rezultat.

Slika 5.6: Postopek generiranja slike št. 30.




(a) Vsebina. (b) Stil: R. Jakopič– Kamnitnik v snegu. (c) Rezultat.

Slika 5.7: Postopek generiranja slike 39, z utežjo stila povečano na 200.000.




(a) Vsebina. (b) Stil: I. Grohar– Sejalec. (c) Rezultat.

Slika 5.8: Postopek generiranja slike št. 48, z utežjo stila povečano na 200.000.



(a) Vsebina. (b) Stil: R. Jakopič–Križanke. (c) Rezultat.

Slika 5.9: Postopek generiranja slike št. 46.




(a) Vsebina. (b) Stil: R. Jakopič–Križanke. (c) Rezultat.

Slika 5.10: Postopek generiranja slike št. 11.




(a) Vsebina. (b) Stil: I. Grohar – Hribček. (c) Rezultat.

Slika 5.11: Postopek generiranja slike št. 31.




(a) Vsebina. (b) Stil: I. Grohar-Hribček. (c) Rezultat.

Slika 5.12: Postopek generiranja slike št. 23, z utežjo stila zmanjšano na 2000.




(a) Vsebina. (b) Stil 1: R. Jakopič-Sončni breg. (c) Stil 2: I. Grohar-Sejalec.




(d) Rezultat.

Slika 5.13: Postopek generiranja slike št. 14. Tu smo uporabili dva stila, ki na generirano sliko vplivata vsak polovično




(a) Vsebina. (b) Stil: I. Grohar-Sejalec. (c) Rezultat.

Slika 5.14: Postopek generiranja slike št. 6.



(a) Vsebina. (b) Stil: R. Jakopič–Križanke. (c) Rezultat.

Slika 5.15: Postopek generiranja slike št. 43, z utežjo stila povečano na 20.000.



(a) Vsebina. (b) Stil: R. Jakopič–Sončni breg. (c) Rezultat.

Slika 5.16: Postopek generiranja slike št. 13, kjer smo utež stila povečali na 1.000.000!

Izbrane slike smo nato po potrebi še obrezali ali pa jim spremenili dimenzije, saj so bile skoraj vse generirane slike istega formata (ker smo izhajali iz fotografij iz iste naprave in zaradi omejitve izhodne velikosti).

Poglavje 6

Rezultati ankete o razlikovanju pravih in generiranih slik

Da bi preverili, kako prepričljive so slike, ki smo jih zgenerirali in prikazali v prejšnjem poglavju, smo naključno izbrane ljudi vprašali, kakšen je po njihovem mnenju izvor slike: računalniški ali človeški. Da bi to izvedeli, smo izvedli spletno anketo in jo preko različnih družabnih omrežij, spletne pošte in ostalih metod razširili med čim bolj raznolike profile ljudi.


Za izdelavo spletne ankete smo uporabili odprtokodno aplikacijo za spletno anketiranje: En klik anketa oziroma 1KA. Storitve je brezplačno dostopna na spletnem naslovu <http://www.1ka.si> in omogoča oblikovanje, tehnično izdelavo ter izvedbo ankete, nato pa nudi tudi orodja za urejanje in analizo podatkov oziroma parapodatkov.

Anketa je bila sestavljena iz 32 vprašanj. Prvi dve vprašanji sta bili demografske narave, da bi izvedeli kakšen je profil anketirancev — „Kakšen je vaš spol?“ in „V katero starostno skupino spadate?“ Nato je sledilo 30 slik (16 računalniškega in 14 človeškega izvora), kjer so morali anketiranci izbrati med dvema možnostima, ali je sliko naslikal slikar, ali pa je produkt računalniškega algoritma.


6.1 Rezultati ankete

Na anketo je odgovorilo 268 ljudi, od tega 48% moških in 52% žensk. Največ, to je 53% anketirancev, je bilo starih med 21 in 40 let, 37% je bilo starih 41 do 60 let, 5% je bilo starejših od 60 in prav tako 5% jih je bilo mlajših od 21 let.


Rezultati ankete po posameznih slikah so prikazani na slikah od 6.1 do 6.30. Histogrami so obarvani modro za pravilne in rdeče za napačne odgovore.




Slika 6.1: Slika je bila umetno generirana: glej postopek na sliki 5.1.




Slika 6.2: Rihard Jakopič: Svež sneg (1908)




Slika 6.3: Rihard Jakopič: Kamnitnik v snegu (1903), ta slika je zanimivost ankete, saj so jo ljudje napačno označili kot računalniško




Slika 6.4: Slika je bila umetno generirana: glej postopek na sliki 5.2, slika je ena izmed bolj prepričljivih „lažnih“ slik.




Slika 6.5: Slika je bila umetno generirana: glej postopek na sliki 5.3. Je tretja najbolj prepričljiva generirana slika.




Slika 6.6: R. Jakopič: Križanke (1909)




Slika 6.7: Slika je bila umetno generirana: glej postopek na sliki 5.4.





Slika 6.8: Ivan Grohar: Štemarski vrt (1907), najbolj prepričljiva prava slika.




Slika 6.9: Slika je bila umetno generirana: glej postopek na sliki 5.5





Slika 6.10: Matej Sternen: Kozolci (1907)




Slika 6.11: Slika je bila umetno generirana: glej postopek na sliki 5.6, tukaj je zanimiv „sij“ okoli figure.




Slika 6.12: Ivan Grohar: Sejalec (1907)





Slika 6.13: Slika je bila umetno generirana: glej postopek na sliki 5.7. Najbolj očitno računalniška slika, kar pa ni čudno, saj so anketiranci že njen stil označili kot računalniško generirano sliko.




Slika 6.14: Matej Sternen: V jutro (1908)





Slika 6.15: Ivan Grohar: Hribček (1910)




Slika 6.16: Slika je bila umetno generirana: glej postopek na sliki 5.8




Slika 6.17: Rihard Jakopič: Breze (1903)




Slika 6.18: Slika je bila umetno generirana: glej postopek na sliki 5.9. Tu svoj izvor morda izdaja sama vsebina slike (klasična ljubljanska klop), vendar je 55% ljudi še vedno pretentala.




Slika 6.19: Slika je bila umetno generirana: glej postopek na sliki 5.10




Slika 6.20: Matej Sternen: Dama v modrem (Začetek 20. stoletja)




Slika 6.21: Ivan Grohar: V Gerajtah (1908)





Slika 6.22: Slika je bila umetno generirana: glej postopek na sliki 5.11




Slika 6.23: Matija Jama: Naslov ni znan (Začetek 20. stoletja)




Slika 6.24: Rihard Jakopič: Križanke (1924)




Slika 6.25: Slika je bila umetno generirana: glej postopek na sliki 5.12. Je druga najmanj prepričljiva računalniško generirana slika





Slika 6.26: Slika je bila umetno generirana: glej postopek na sliki 5.13




Slika 6.27: Matija Jama: Tri breze (okoli 1901)



Slika 6.28: Slika je bila umetno generirana: glej postopek na sliki 5.14



Slika 6.29: Slika je bila umetno generirana: glej postopek na sliki 5.15. Slika je najbolj prepričljiva slika v anketi.



Slika 6.30: Slika je bila umetno generirana: glej postopek na sliki 5.16

6.2 Interpretacija rezultatov ankete

Pri reševanju ankete so bili anketiranci 80% natančni, saj so pravilno razvrstili 24 od 30 slik. Ko je bila slika umetniškega izvora je to v povprečju ugotovilo 77% anketirancev, in s podobno gotovostjo 75% so pravilno ugotovili računalniški izvor slik.

Malo manj kot tretjina (32%) računalniško generiranih slik je anketirance „pretentala“, saj so jih pet napačno označili kot da jih je naslikal slikar. Kot lahko razberemo na sliki 6.31 sta bili najbolj prepričljivi računalniško generirani sliki 6.4 in 6.29, saj jih je kar 62% anketirancev označilo kot delo slikarja.

Presenetljivo pa je, da je ljudi pretentala tudi ena prava umetniška slika. Sliko 6.3 je skoraj dve tretjini anketirancev, oziroma 65% populacije, klasificiralo kot računalniško generirano.

Kot je razvidno iz slike 6.31 in 6.32 so največjo natančnost anketiranci dosegli pri klasificiranju računalniško generiranih slik 6.13 in 6.25 (natančnost: 91% in 89%) in umetniških slik 6.6 in 6.8 (natančnost: 90% in 96%).

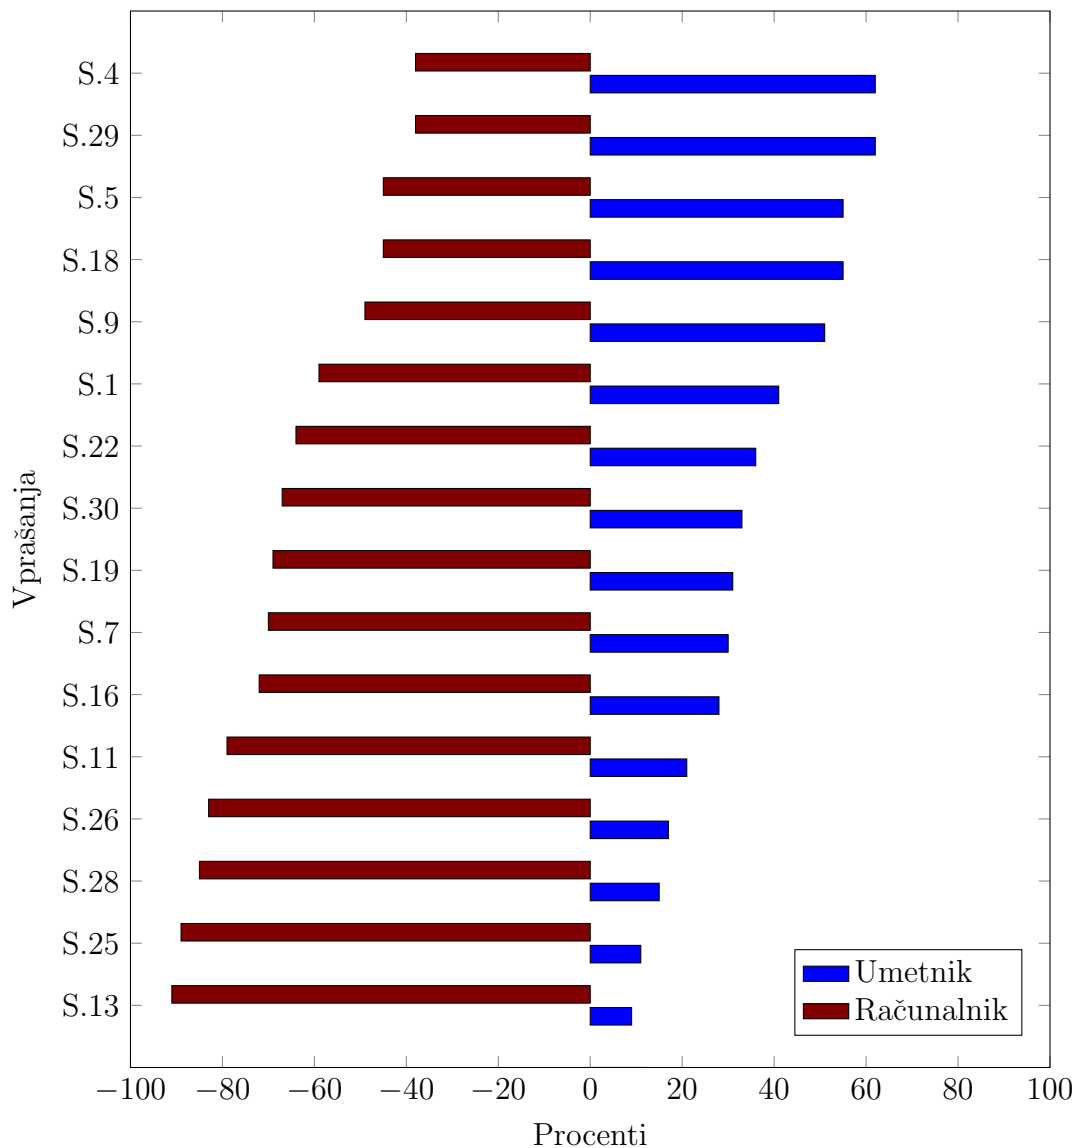
Ena od možnih razlag za tako visoko natančnost pri prepoznavanju umetniških slik je ta, da so določene izbrane slike tako ikonične, da jih je veliko slovencev enostavno prezpoznalo, ker so jih že tolikokrat videli. V anketo smo namreč vključili nekaj zelo znanih slik slovenskih impresionistov. Za visoko natančnost pri klasificiranju določenih računalniško generiranih slik pa morda lahko krivimo (ne)uravnoteženost kompozicije in preveč monotono barvno paleto vhodne slike.

Verjetno je na rezultate vplivalo samo zaporedje vprašanj. Pri vseh anketirancih so bila namreč vprašanja postavljena v istem vrstnem redu in opazimo lahko, da so anketirance bolj „pretentale“ računalniško generirane slike, ki so bile med v anketi med prvimi na vrsti. Anketiranci so morda opazili ponavljajoče se lastnosti generiranih slik in to znanje uporabili pri kasnejših slikah.


Iz primerov, ki so anketirance najbolj pretentali lahko sklepamo, da algoritem pravilno opravlja svojo nalogo, vendar mora kreator lažnih slik združiti

take slike, ki producirajo najboljši rezultat.

Impresionistični stil se je, kot smo predvideli, za nalogo prenosa stila dobro obnesel. Najboljša primera za sintezo in prenos stila sta se izkazali sliki Križanke in Sončni breg slikarja Riharda Jakopiča.



Slika 6.31: Slike, generirane z računalnikom, razvrščene po „prepričljivosti“ v opravljeni anketi.



Slika 6.32: Prave slike umetnikov, razvrščene po „prepričljivosti“ v opravljeni anketi.

Poglavje 7

Zaključek

Cilj diplomskega dela je bila raziskava fenomena prenosa slikovnega stila s pomočjo globokih nevronske mreže, kar je sedaj vroča tema v računalniško generirani umetnosti. Zato smo najprej razložili, kako se s pomočjo globokih nevronske mreže prenaša stil z ene slike na drugo sliko. To uporabo globokih nevronske mreže smo nato demonstrirali s pomočjo slik slovenskih impresionistov.

Stil, ki smo ga uporabili za generiranje slik, smo sintetizirali iz najpopularnejših del slovenskih impresionistov. Nato smo ta stil prenesli na fotografije, na katerih so bili podobni motivi, ki so jih kot predlogo za svoje slike uporabljali tudi sami impresionisti.

Prepričljivost tako dobljenih rezultatov smo preverili preko spletne ankete, ki smo jo preko socialnih omrežij, spletne pošte in ostalih metod razširili med čimširši krog ljudi. Na anketi je sodelovalo več kot 250 ljudi.

Rezultati spletne ankete kažejo, da vsaj v našem primeru, ljudje še vedno znajo ločiti med pravimi in generiranimi slikami. Vendar je približno tretjina generiranih slik anketirance „prevarala“ in prepričani smo, da bi ta delež z boljšo kompozicijo fotografij, ki smo jih izbrali za osnovo in z bolj raznoliko paleto stilov ter z naključnim zaporedjem slik v anketi še narastel. Sam proces generiranja slik je sicer bil v našem primeru dokaj počasen, vendar to lahko zlahka rešimo z uporabo boljše tehnologije, predvsem z uporabo

grafičnih procesorskih enot (GPU).

Uporaba globokih nevronske mreže na raznolikih področjih uporabe (npr. računalniški vid, učenje, kreativnost itd.) nam pomaga pri razumevanju, kako taki procesi delujejo v realnem življenju. Njihova uporaba v umetnosti pa odpira nov problem: Ali lahko dela, ki jih je generirala umetna inteligenca, smatramo kot prava umetniška dela, in če da, kdo je potem njihov avtor (programer, algoritem ali kombinacija obojega)? Zagotovo pa drži, da računalniško generirana umetnost ostaja med nami.

Uporabe opisanih metod za strokovnjake na področju umetnostne zgodovine odpira povsem nove možnosti analize posameznih umetniških del ali nekaterih zaključenih slikarskih stilskih opusov, saj je možno s ciljno usmerjeno sintezo generiranih slik preizkusiti marsikatero, dosedaj le teoretično zasnovano domnevo ali idejo.

Literatura

- [1] Kunihiro Fukushima. Neural network model for a mechanism of pattern recognition unaffected by shift in position-neocognitron. *IEICE Technical Report, A*, 62(10):658–665, 1979.
- [2] Leon A Gatys, Matthias Bethge, Aaron Hertzmann, and Eli Shechtman. Preserving color in neural artistic style transfer. *arXiv preprint arXiv:1606.05897*, 2016.
- [3] Leon A Gatys, Alexander S Ecker, and Matthias Bethge. Texture synthesis using convolutional neural networks. In *Advances in Neural Information Processing Systems*, pages 262–270, 2015.
- [4] Leon A Gatys, Alexander S Ecker, and Matthias Bethge. Image style transfer using convolutional neural networks. In *Computer Vision and Pattern Recognition (CVPR), 2016 IEEE Conference on*, pages 2414–2423. IEEE, 2016.
- [5] Jerneja Gros and Franc Solina. Describing artworks using shape grammars. *Elektrotehniški vestnik*, 59(5):314–320, 1992.
- [6] Nejc Ilenič. Deep Models of Painting Authorship. Master’s thesis, Fakulteta za računalništvo in informatiko, Ljubljana, 2017.
- [7] Aleksej Ivakhnenko. Cybernetic predicting devices. Technical report.

-
- [8] Sebastian Korenič Tratnik, Aljoša Rakita, and Franc Solina. Prenos stila s pomočjo globokih nevronsih mrež na primeru slovenskih impresionistov. Ljubljana, 2018. V pripravi.
- [9] Yann LeCun, Koray Kavukcuoglu, and Clément Farabet. Convolutional networks and applications in vision. In *Circuits and Systems (ISCAS), Proceedings of 2010 IEEE International Symposium on*, pages 253–256. IEEE, 2010.
- [10] Warren S McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133, 1943.
- [11] Luc Menaše. *Evropski umetnostno zgodovinski leksikon*. Mladinska knjiga, Ljubljana, 1971. Stran 894.
- [12] Jožef Muhovič. *Leksikon likovne teorije*. Celjska mohorjeva družba, Celje-Ljubljana, 2015. Stran 307, geslo: Impresionizem.
- [13] Jürgen Schmidhuber. Deep learning in neural networks: An overview. *Neural networks*, 61:85–117, 2015.
- [14] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [15] Cameron Smith. neural-style-tf. <https://github.com/cysmith/neural-style-tf>, 2016. [Accessed 14-September-2018].
- [16] Franc Solina and Srečo Dragan. Novomedijski umetniški projekti kot most med realnim in virtualnim svetom. In Tadej Bajd and Ivan Bratko, editors, *Robotika in umetna inteligenca*. Slovenska matica, Ljubljana, 2014.

-
- [17] Dmitry Ulyanov, Vadim Lebedev, Andrea Vedaldi, and Victor S Lempit-sky. Texture networks: Feed-forward synthesis of textures and stylized images. In *ICML*, pages 1349–1357, 2016.
- [18] Paul J Werbos. Applications of advances in nonlinear sensitivity analysis. In *System modeling and optimization*, pages 762–770. Springer, 1982.
- [19] Wikipedia contributors. Style (visual arts) — Wikipedia, the free encyclopedia, 2018. [Online; accessed 13-Jun-2018].
- [20] Ciyou Zhu, Richard H Byrd, Peihuang Lu, and Jorge Nocedal. Algorithm 778: L-bfgs-b: Fortran subroutines for large-scale bound-constrained optimization. *ACM Transactions on Mathematical Software (TOMS)*, 23(4):550–560, 1997.