

Usporedba različitih modela dubokih neuronskih mreža za detekciju rana

Grčić, Nives

Undergraduate thesis / Završni rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:200:383409>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-12-27**

Repository / Repozitorij:

[Faculty of Electrical Engineering, Computer Science and Information Technology Osijek](#)



SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Preddiplomski Sveučilišni Studij Računarstva

USPOREDBA RAZLIČITIH MODELA DUBOKIH
NEURONSKIH MREŽA ZA DETEKCIJU RANA

Završni rad

Nives Grčić

Osijek, 2023.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK****Obrazac Z1P - Obrazac za ocjenu završnog rada na preddiplomskom sveučilišnom studiju**

Osijek, 11.07.2023.

Odboru za završne i diplomske ispite

**Prijedlog ocjene završnog rada na
preddiplomskom sveučilišnom studiju**

Ime i prezime Pristupnika:	Nives Grčić
Studij, smjer:	Programsko inženjerstvo
Mat. br. Pristupnika, godina upisa:	R4489, 27.07.2020.
OIB Pristupnika:	04566858857
Mentor:	izv. prof. dr. sc. Emmanuel Karlo Nyarko
Sumentor:	,
Sumentor iz tvrtke:	
Naslov završnog rada:	Usporedba različitih modela dubokih neuronskih mreža za detekciju rana
Znanstvena grana rada:	Umjetna inteligencija (zn. polje računarstvo)
Zadatak završnog rad:	Potrebno je usporediti, tj. analizirati i vrednovati, najmanje dva različita modela dubokih neuronskih mreža za detekciju rana na fotografijama. (Tema rezervirana za: Nives Grčić)
Prijedlog ocjene završnog rada:	Izvrstan (5)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 2 bod/boda Jasnoća pismenog izražavanja: 2 bod/boda Razina samostalnosti: 3 razina
Datum prijedloga ocjene od strane mentora:	11.07.2023.
Datum potvrde ocjene od strane Odbora:	08.09.2023.
Potvrda mentora o predaji konačne verzije rada:	Mentor elektronički potpisao predaju konačne verzije.
	Datum:

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK****IZJAVA O ORIGINALNOSTI RADA**

Osijek, 11.09.2023.

Ime i prezime studenta:

Nives Grčić

Studij:

Programsko inženjerstvo

Mat. br. studenta, godina upisa:

R4489, 27.07.2020.

Turnitin podudaranje [%]:

3

Ovom izjavom izjavljujem da je rad pod nazivom: **Usporedba različitih modela dubokih neuronskih mreža za detekciju rana**

izrađen pod vodstvom mentora izv. prof. dr. sc. Emmanuel Karlo Nyarko

i sumentora ,

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija. Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

Sadržaj

1.	Uvod	2
1.1.	Zadatak završnog rada	2
2.	Pregled područja teme	3
3.	Duboko učenje	4
3.1.	Arhitektura neuronske mreže	4
3.2.	Slojevi neuronske mreže	5
3.2.1.	Tipovi slojeva	5
3.3.	Aktivacijske funkcije.	6
3.3.1.	ReLU	6
3.4.	Učenje neuronskih mreža.	6
3.4.1.	Osnovni tipovi učenja	7
3.4.2.	Gradijentni spust	7
3.4.3.	Funkcija gubitka	8
3.4.4.	Povratna propagacija	8
3.4.5.	Problemi učenja mreže	9
3.5.	Konvolucijske neuronske mreže	11
3.5.1.	Arhitektura konvolucijskih neuronskih mreža	11
3.5.2.	Konvolucijski slojevi	11
3.5.3.	Slojevi sažimanja	12
4.	UNet i podtipovi	13
4.1.	Izvorni U-Net model.	13
4.2.	Attention U-Net	14
5.	Usporedba modela	15
5.1.	Baza podataka	15
5.2.	Učenje modela	16
5.3.	Evaluacija modela.	16
5.4.	Rezultati	16
6.	Zaključak.	18
	Sažetak	21
	Abstract	22
	Životopis	23

1. UVOD

Ozljede kože su često medicinsko stanje do kojeg dolazi iz brojnih razloga. Točna dijagnoza i liječenje su ključni za sprječavanje daljnjih komplikacija i brz oporavak. Segmentacija slika postaje sve važniji dio medicinske analize slika koji uključuje podjelu slike na različite regije ili segmente radi identificiranja specifičnih značajki ili struktura. U posljednjih nekoliko godina, metode temeljene na dubokom učenju su se pojavile kao snažan alat za segmentaciju slika, postizujući izrazito napredne performanse u različitim medicinskim primjenama.

Ovim radom biti će proučena primjena dubokog učenja za segmentaciju slika ozljeda kože te osnovni koncepti dubokog učenja i različite tehnike koje su korištene za segmentaciju slika. Rad će biti posebice fokusiran na dva tipa U-Net modela koji su široko korišteni u segmentaciji biomedicinskih slika.

Rad je započet uvodom u duboko učenje - općenitim pregledom područja strojnog učenja i umjetne inteligencije. Biti će objašnjeni osnovni pojmovi poput neuronskih mreža, konvolucijskih neuronskih mreža i dubokog učenja. Nadalje biti će promotrena arhitektura U-Net modela.

U nastavku, predstavlja se model izveden iz modela U-Neta: Attention U-Net, njegova arhitektura, prednosti i nedostatci. Potom će biti opisan eksperimentalni postupak i skup podataka koji će se koristiti za procjenu performansi modela. Biti će provedena usporedba performansi dva različita U-Net modela za segmentaciju slika ozljeda kože.

1.1. Zadatak završnog rada

Cilj ovog rada je usporediti performanse različitih modela dubokog učenja, posebno U-Net i Attention U-Net, za segmentaciju slika ozljeda kože te procjenom prednosti i nedostataka svakog modela doprinijeti razumijevanju primjene dubokog učenja u medicinskim primjenama.

2. PREGLED PODRUČJA TEME

Zadatak ovog završnog rada je usporedba dva modela dubokog učenja u svrhu segmentacije slike rana na koži. Problem segmentacije slike već je dugo aktualna tematika u području dubokog učenja te vrlo često dolazi do novih ideja i radova na temu konvolucijskih neuronskih mreža. Uz razvitak mogućnosti konvolucijskih neuronskih mreža pojavljuju se i ideje za njihovu upotrebu, a jedna od najpopularnijih je segmentacija biomedicinskih slika. U nastavku opisuje se nekoliko radova s tom ili sličnom tematikom:

U radu [1] autori istražuju mogućnosti segmentacije rana te ulogu umjetne inteligencije u liječenju u svrhu razvitka medicinske pomoći putem telefonske komunikacije. U radu koriste četiri konvolucijske neuronske mreže: SegNet, LinkNet, U-Net i U-Net s VGG16 Enkoderom koji je prije toga učen na ImageNet bazi podataka.

Idejom razvitka medicinske pomoći putem telefonske linije također su se bavili autori rada [2] iz 2020. godine. Rad istražuje mogućnost primjene konvolucijskih neuronskih mreža na segmentaciju i mjerenje površine rane. Autori predlažu ASURA *framework* koji upotrebom U-Net modela segmentira sliku rane kraj koje je postavljeno ravnalo. Osim segmentacije slike rane pomoću postavljenih ravnala ASURA računa ukupnu površinu rane.

Nadalje, u radu [3] autori se bave segmentacijom mamografskih slika u svrhu otkrivanja raka dojke. Autori razvijaju novi model koji je inspiriran U-Net modelom te ga uspoređuju s izvornim U-Net modelom i njegovim inačicama.

Rad [4] predlaže novi način segmentacije slika metodom superpiksela. Rad rješava zadatak identifikacije različitih tkiva unutar dermatoloških rana. Autori su razvili sustav po imenu QTDU koji kombinira modele dubokog učenja s metodama segmentacije koje su bazirane na metodi superpiksela.

U radu [5] autori se bave klasifikacijom i segmentacijom poremećaja vena. Autori predlažu novo rješenje u vidu *framework*-a po imenu VENet koji je baziran na U-Net modelu. arhitektura predložena u ovom radu kao ulaz uzima slike poremećaja vena te ih klasificira s obzirom na stupanj poremećaja.

U ovom radu će se proučavati primjena U-Net modela i Attention U-Net modela. U-Net model i njegove inačice vrlo su popularne u svijetu segmentacije biomedicinskih slika te nije rijetkost naići na njihovu upotrebu u znanstvenim istraživanjima [1, 2, 4, 5]. Više o U-Net modelu biti će objašnjeno u poglavlju 4

3. DUBOKO UČENJE

Duboko učenje je grana umjetne inteligencije koja se bavi stvaranjem umjetnih dubokih neuronskih mreža koje mogu naučiti samostalno rješavati složene zadatke kroz obradu velikih količina podataka.

Duboko učenje je podskup strojnog učenja te je u osnovi neuronska mreža s velikim brojem slojeva. Ove neuronske mreže nastoje simulirati ponašanje ljudskog mozga kroz kombinaciju ulaznih podataka, težina i *bias*-a neurona.

U ovom poglavlju opisane su osnove dubokog učenja, uključujući njegovu arhitekturu, proces učenja i primjene.

3.1. Arhitektura neuronske mreže


Arhitektura dubokog učenja temelji se na umjetnim neuronskim mrežama (eng. *artificial neural networks*). One se sastoje od slojeva međusobno povezanih neurona. Pri radu svaki neuron u neuronskoj mreži prima ulaz iz drugih neurona u prethodnom sloju, izvodi računalnu operaciju nad tim ulazom i prenosi rezultat neuronima u sljedećem sloju. Taj se proces ponavlja kroz sve slojeve mreže sve dok konačni sloj ne proizvede predviđanje ili odluku. Ulazi u neuron su vrijednosti koje se prenose iz prethodnog sloja neuronske mreže. Ulazi su obično u obliku $x_1, x_2, \dots, x_n \in \mathbb{R}$ gdje je n broj ulaza u mrežu, a svaki element vektora odgovara jednom ulazu.

Neka je x iz \mathbb{R}^n vektor ulaznih podataka i neka su $w_1, w_2, \dots, w_n \in \mathbb{R}$ težine. Neuron je rezultat primjene aktivacijske funkcije na težinsku sumu ulaznih podataka i danih težina.

Također postoji i dodatni ulaz b koji se zove *bias* što je dodatni parametar koji omogućuje neuronu pomicanje funkcije aktivacije, pružajući fleksibilnost i omogućujući mreži bolje prilagođavanje podacima.

$$y = f\left(\sum_{i=1}^n x_i w_i + b\right) \quad (3-1)$$

gdje je $f : \mathbb{R} \rightarrow \mathbb{R}$ aktivacijska funkcija, a b težina koja povezuje *bias* neuron i sljedeći neuron.



SL. 3.1: Osnovni model neurona

3.2. Slojevi neuronske mreže

Pojam sloja unutar neuronske mreže odnosi se na skup neurona koji obavljaju operacije nad ulaznim podacima. Ti slojevi su složeni jedan na drugi te svaki sloj obavlja drugačiji izračun nad danim podacima.

Tri glavne vrste slojeva koji se koriste su:

1. Ulazni sloj

Prvi sloj u mreži, najčešće se sastoji od jednog neurona po ulaznoj značajki.

2. Skriveni sloj

Sloj(evi) mreže između ulaznog i izlaznog sloja. Obavlja izračune nad ulaznim podacima te ih transformira u oblik pogodan izlaznom sloju.

3. Izlazni sloj

Konačni sloj mreže u kojem se generiraju izlazni podaci. Prima podatke iz prethodnog sloja mreže i transformira ih u krajnji rezultat.

Svaki sloj povezan je sa sljedećim slojem putem skupa težina. Težine u neuronskoj mreži se koriste kako bi se regulirao doprinos svakog ulaza pri izračunavanju izlaza, dok se algoritmi učenja koriste za podešavanje tih težina u svrhu optimizacije mreže.

3.2.1 Tipovi slojeva

Duboke neuralne mreže imaju velik broj slojeva te svaki ima svoju ulogu. Ulazni sloj (eng. *input layer*) prima neobrađene podatke, dok je izlazni sloj (eng. *output layer*) odgovoran za prikaz krajnjeg predviđanja. Svi ostali, skriveni slojevi, odgovorni su za obradu ulaznih podataka i izdvajanje bitnih značajki.

Postoji nekoliko tipova slojeva koji se često koriste u dubokim neuronskim mrežama:

- **Potpuno povezani slojevi**

U potpuno povezanim slojevima svaki neuron je povezan sa svakim neuronom u prethodnom i sljedećem sloju.

- **Konvolucijski slojevi**

Konvolucijski slojevi najčešće se koriste prilikom obrade slike. Kod ovakvog tipa sloja ulazni podaci su u obliku dvodimenzionalnog polja piksela, te slojevi koriste skup filtara za izdvajanje bitnih značajki iz ulazne slike.

- **Rekurentni slojevi**

Rekurentni slojevi obično se koriste za obradu sekvencijalnih podataka, poput vremenskih serija. Ključna karakteristika ovakvog tipa sloja je što omogućava mreži da zadrži informaciju o prethodnim koracima i koristi ju za obranu trenutnog koraka.

Bitno je napomenuti da konvolucijski i rekurentni slojevi mogu i ne moraju biti potpuno povezani.

3.3. Aktivacijske funkcije

Aktivacijske funkcije su matematičke funkcije koje određuju izlaz neurona na temelju težinskih suma ulaza. Često korištene aktivacijske funkcije uključuju sigmoid, tahn i ReLU (eng. *Rectified Linear Unit*).


3.3.1 ReLU

ReLU aktivacijska funkcija često se koristi u konvolucijskim neuralnim mrežama te je aktivacijska funkcija koja se koristi u UNet arhitekturi.

Funkciju prikazujemo u obliku

$$f(x) = \max(0, x) \quad (3-2)$$

Iz dane funkcije (3-2) vidi se kako ReLU primjenjuje prag na ulazne podatke, odnosno sve vrijednosti ispod nule postavlja na nulu, a pozitivne vrijednosti ostaju nepromijenjene. Važna prednost ReLU funkcije je što ne dolazi do problema nestajućeg gradijenta (pojava u kojoj gradijent postaje izrazito malen prilikom postupka povratne propagacije što dovodi do sporog ili neefikasnog učenja mreže) koji se pojavljuje u drugim aktivacijskim funkcijama poput sigmoida ili tahn funkcije kada gradijenti postanu vrlo mali. Nedostatak ReLU funkcije je što je podložan problemu "umirućih" neurona koji ako na ulazu konstantno dobijaju negativnu vrijednost zadržavaju vrijednost nula te prestanu pridonositi izlazu mreže. Taj se problem rješava upotrebom inačica ove funkcije poput *leaky ReLU* koja omogućava malu aktivaciju za negativne ulazne vrijednosti.



SL. 3.2: Graf ReLU funkcije

3.4. Učenje neuronskih mreža

U prethodnom potpoglavlju definirana je arhitekturu neuronskih mreža. Kako bi se prilagodila problemu koji rješava mreža prolazi kroz proces učenja. U ovom potpoglavlju biti će promotreni osnovni tipove učenja te najčešće korišteni algoritmi.

3.4.1 Osnovni tipovi učenja

Postoje tri osnovna tipa učenja:

- **Nadzirano (eng. *supervised*) učenje**

Prilikom nadziranog učenja mreža uči na temelju skupa podataka koji uključuje ulazne podatke i odgovarajuće ispravne izlazne vrijednosti koje su poznate prije učenja modela. Iterativnom metodom parametri modela se prilagođavaju s ciljem smanjenja pogreške između predviđenih i stvarnih izlaza. Ovakav tip učenja često se koristi u različitim područjima, poput prepoznavanja uzoraka, klasifikacije, regresije i prijevoda jezika.

- **Nenadzirano (eng. *unsupervised*) učenje**


Prilikom nenadziranog učenja mreža uči na temelju skupa podataka koji ne uključuje odgovarajuće izlazne vrijednosti. Umjesto toga, cilj je pronaći uzorke u podacima, odnosno povezati podatke sličnih svojstava. Ovaj tip učenja se često koristi za grupiranje podataka (eng. *clustering*) ili redukciji dimenzionalnosti (eng. *dimensionality reduction*) podataka. Nenadzirano učenje također može biti koristan alat u predobradi podataka prije primjene nadziranog učenja.

- **Učenje podrškom (eng. *reinforcement learning*)**

Prilikom učenja podrškom mreža uči putem interakcije s okolinom te dobiva nagradu ili kaznu ovisno o svom postupku. Cilj ovog tipa učenja je naučiti mrežu da donosi odluke koje će rezultirati maksimalnom nagradom u nekom specifičnom okruženju. Ovaj tip učenja koristi se u robotici, razvoju igara i upravljanjem resursima, gdje se nagrade mogu primijeniti kao sredstvo za optimizaciju ponašanja mreže.

3.4.2 Gradijentni spust

Gradijentni spust (eng. *Gradient descent*) je optimizacijski algoritam koji se koristi za minimizaciju funkcije gubitka iterativnim mijenjanjem vrijednosti težina. To se postiže "spuštanjem" od neke točke prema nižim vrijednostima na grafu funkcije gubitka dok ne dođemo do lokalnog minimuma. Važno je napomenuti da u slučaju problema koji uključuju konveksne funkcije želimo doći do globalnog minimuma.



SL. 3.3: Primjer gradijentnog spusta na funkciji $f(x) = x^2$

3.4.3 Funkcija gubitka

Funkcija gubitka (eng. *Loss Function*) je funkcija koja mjeri razliku između predviđene izlazne vrijednosti modela i stvarne izlazne vrijednosti te se koristi za vođenje procesa učenja tijekom nadziranog učenja. Funkciju gubitka možemo prikazati na sljedeći način:

$$L(\theta) = \frac{1}{n} \sum_{i=1}^n l(f(x_i; \theta), y_i) \quad (3-3)$$

gdje su:

- θ - parametri modela (težine)
- x_i - ulazne vrijednosti
- y_i - stvarna vrijednost
- $f(x_i; \theta)$ - predviđena vrijednost
- $l(\cdot)$ - funkcija gubitka za jedan uzorak
- n - broj uzoraka na kojima se mreža trenira

3.4.4 Povratna propagacija

Nakon promatranja pojmova gradijentnog spusta i funkcije gubitka u ovom potpoglavlju biti će objašnjena njihova primjena na algoritmu povratne propagacije.

Propagacija unazad (eng. *Backpropagation*) je algoritam koji se koristi za izračunavanje gradijenta funkcije gubitka u neuronskim mrežama, što je ključno za njihovo treniranje.


Backpropagation sastoji se od dva dijela: propagacije unaprijed (eng. *Forward propagation*) koja izračunava izlaze za zadane ulaze. Nakon toga povratnom propagacijom računa se gradijent funkcije gubitka po svakom parametru mreže, od izlaza prema ulazu kroz mrežu, koristeći lančano pravilo derivacije.

U skladu s izračunatim gradijentom funkcije gubitka ažuriraju se vrijednosti težina. Ovaj postupak ponavlja se do ispunjenja kriterija zaustavljanja koji može biti dostizanje minimalne vrijednosti funkcije gubitka ili dostizanje maksimalnog broja iteracija.

3.4.5 Problemi učenja mreže

Prilikom treniranja mreže krajnji rezultati ovise o brojnim parametrima. Dva najčešća problema s kojima se moguće susresti prilikom učenja su pretjerano usklađivanje modela na podatke za učenje (eng. *Overfitting*) i podusklađivanje (eng. *Underfitting*).


U ovom potpoglavlju biti će opisana ta dva problema te ih prikazati na primjeru binarnog klasifikacijskog problema.



SL. 3.4: Primjer pretjeranog usklađivanja [6]

Na slici 3.4 Prikazan je primjer pretjeranog usklađivanja modela na podacima za učenje. Model se previše prilagodio podacima za treniranje jer je vidljivo kako je svaki podatak skupa za treniranje točno klasificiran. *Overfitting* se najčešće događa ako je model pretjerano složen, izrazito osjetljiv na šum i varijacije u podacima. Rezultat je model koji nije primjenjiv na nove, nepoznate, podatke.


Moguća rješenja za sprječavanje ovog problema su treniranje na većem skupu podataka, smanjenje kompleksnosti modela ili uvođenje postupka regularizacije. Najčešće korišteni postupci regularizacije su isključivanje (eng. *Dropout*) te L1 i L2 regularizacija. Detalji o L1 i L2 regularizaciji mogu se naći u [21]



SL. 3.5: *Primjer podusklađivanja modela [6]*

Na slici 3.5 Prikazan je primjer podusklađivanja modela. *Underfitting* je problem u potpunosti suprotan prethodnom. Pojavljuje se kada mreža nije dovoljno ili adekvatno trenirana za problem koji rješava. Tada model daje loše rezultate i na skupu za treniranje i na novim podacima. Ovakav problem može se dogoditi ako je problem presložen za model ili model nije dovoljno osjetljiv na varijacije u podacima. Moguća rješenja za sprječavanje ovog problema uključuju povećanje kompleksnosti modela, broja parametara i slojeva modela.

Na kraju, promotrimo primjer optimalnog (eng. *well-fitted*) modela:



SL. 3.6: *Primjer dobro usklađenog modela [6]*

Iz slike 3.6 vidljivo je kako je većina podataka točno klasificirana, ali postoji nekoliko netočno klasificiranih podataka koji se smatraju podacima koji odskakuju od ostalih zbog šuma ili varijacije (eng. *Outlier*). Zaključak koji je moguće donjeti je da je pri ovako istreniranom modelu granica odluke dobro postavljena.

3.5. Konvolucijske neuronske mreže

Konvolucijske neuronske mreže (CNN) u posljednjih su nekoliko godina postale sve popularniji alat strojnog učenja za rješavanje problema analize slike. Za razliku od tradicionalnih vrsta mreža, dizajnirane su za rukovanje visokodimenzionalnim ulaznim podacima.

Ovaj tip mreže baziran je na principu funkcioniranja vizualnog korteksa u kojem različiti objekti potiču uzбудu različitih regija, odnosno stanice će se aktivirati na temelju oblika i orijentacije objekata. Odatle dolazi i ideja o slojevima koji pružaju različite dijelove slike na različitim slojevima. Ta ideja se kasnije razvila i dovela do konceptata poput dijeljenja težine.


U ovom poglavlju biti će proučena arhitektura ovog tipa neuronskih mreža te ključne karakteristike koje ih opisuju.

3.5.1 Arhitektura konvolucijskih neuronskih mreža

Konvolucijske mreže koriste jedinstvene karakteristike koje pružaju slike kao ulazni podaci. Za razliku od običnih mreža, u kojima su neuroni raspoređeni u dvodimenzionalnim slojevima, konvolucijske mreže koriste tri dimenzije - širinu, visinu i dubinu.

Konvolucijske mreže koriste poseban tip slojeva- konvolucijske slojeve. Ovakvi slojevi često nisu potpuno povezani, već su povezani samo s nekim neuronima prethodnog sloja.

Ovaj tip mreže također se razlikuje po pitanju izlaznog sloja. Primjerice, bavimo li se problemom klasifikacije slika, izlaz iz mreže nije slika, već vektor koji predstavlja vjerojatnosti da slika pripada određenoj klasi.



SL. 3.7: Primjer neuronske mreže [7]

Na slici 3.7 prikazan je primjer neuronske mreže, u ovom primjeru crvenom bojom označen je ulazni sloj. Visina i širina opisane su dimenzijama slike, a dubina bi u ovom slučaju bila jednaka 3 (Crvena, Zelena i Plava boja).

3.5.2 Konvolucijski slojevi

Konvolucija je matematička operacija koja se često koristi u obradi signala i slika. Konvolucija dviju funkcija, f i g , definirana je kao integral njihovog umnoška, pomaknutog po x-osi za t :

$$(f * g)(t) = \int_{-\infty}^{\infty} f(\tau)g(t - \tau)d\tau \quad (3-4)$$

funkciju $g(t)$ može se zamisliti kao filter koji se primjenjuje na signal $f(t)$.


Kada se radi o slikama kao ulaznim podacima, one su predstavljene kao dvodimenzionalni signali. Neka I predstavlja ulaznu sliku, a K filter (također poznat kao jezgra) veličine $m \times n$. Tada je konvolucija definirana kao:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n l(I(i + m, j + n)K(m, n)) \quad (3-5)$$

Jezgra je u osnovi matrica manjih dimenzija od ulaznih podataka koja sadrži težine. Prilagođavanjem tih težina jezgre uče prepoznati specifične uzorke u ulaznim podacima.

Postupak primjene konvolucije sastoji se od klizanja filter matrice preko ulaznih podataka. Prema formuli (3-5) elementi filtra množe se s odgovarajućim elementima matrice ulaznih podataka, te se rezultati zbrajaju. Taj se proces ponavlja te je krajnji rezultat nova matrica značajki.

Na slici 3.8 prikazana je vizualizacija operacije konvolucije na dvodimenzionalni ulaz.



SL. 3.8: Konvolucija na primjeru 2D matrice [8, 9]

Konvolucijski slojevi sastoje se od više konvolucijskih filtera koji uče izdvajati specifične značajke iz ulaznih podataka. Time konvolucijski sloj generira više matrica značajki. One se zatim obrađuju aktivacijskom funkcijom. Izlaz aktivacijske funkcije ujedno je i konačan izlaz konvolucijskog sloja.

3.5.3 Slojevi sažimanja

Sažimanje (eng. *Pooling*) je funkcija koja se često koristi u konvolucijskim neuralnim mrežama. Svrha ove operacije je smanjivanje uzorka značajki i smanjenje dimenzionalnosti podataka, ali pritom zadržavajući dubinu. Primjenjuje se nakon konvolucijskih slojeva kako bi se izvukle najvažnije značajke te kako bi se poboljšala ukupna učinkovitost mreže.

Ovaj tip slojeva obično se koristi nakon konvolucijskih slojeva. Njihov važan cilj je učiniti izlazne vrijednosti manje osjetljivima na male promjene u ulaznim podacima.

Poput konvolucijskih slojeva, *pooling* slojevi također imaju definiranu veličinu filtra koja određuje količinu piksela koja se promatra pri izvođenju operacije sažimanja. Najčešće korištene veličine su 2x2 ili 3x3.

Pri operaciji sažimanja filter matrica klizi preko matrice ulaznih podataka te agregira vrijednosti u jednu vrijednost. Postupak kojim se odlučuje ta vrijednost ovisi o vrsti sloja *pooling*a, od kojih su najčešći:

- **Max pooling**

Pronalazi i zadržava najveću vrijednost unutar promatranog prozora vrijednosti

- **Pooling na temelju prosječnih vrijednosti**

Pronalazi prosječnu vrijednost svih vrijednosti unutar promatranog prozora.

4. UNET I PODTIPOVI


U posljednjih nekoliko godina područje računalnog vida doživjelo je značajan porast u razvoju modela dubokog učenja za različite primjene, uključujući segmentaciju slike. U-Net je jedan od popularnijih modela za segmentaciju slike koji su 2015. godine predstavili na Sveučilištu Freiburg u Njemačkoj[10].

Radi se o konvolucijskoj neuronskoj mreži koju su ubrzo primjenili na segmentaciju biomedicinskih slika zbog učinkovitosti pri primjeni na složene slike s finim detaljima. Pokazala se posebno korisna u primjenama poput segmentacije organa i klasifikacije stanica.

Uz izvorni U-Net model, postoji i nekoliko inačica koje su razvijene kako bi se učinkovitost poboljšala s obzirom na različite primjene.

Ovo poglavlje opisati će arhitekturu U-Net modela te razmotriti njegovu inačicu Attention U-Net, njene prednosti i nedostatke te na koji način se razlikuje u odnosu na originalnu U-Net arhitekturu.

4.1. Izvorni U-Net model



SL. 4.1: Arhitektura U-Net mreže (primjer za 32x32 piksela) [10]


U-Net arhitektura[10] prikazana na slici 4.1 poznata je po svojoj strukturi oblika slova U. Plavi pravokutnici predstavljaju višekanalne mape značajki(eng. *feature map*). Broj kanala naznačen je na vrhu pravokutnika. Bijeli pravokutnici predstavljaju kopirane mape značajki. Strelice označavaju različite operacije. Ovakva arhitektura posebno je korisna za zadatke u kojima je važna precizna lokalizacija poput segmentacije biomedicinskih slika.

Mreža se primarno sastoji od enkodera (lijeva strana) i dekodera(desna strana). Zadatak enkodera je izvlačenje značajki iz ulazne slike, a dekodeer rekonstruira mapu značajki. Enkoder slijedi tipičnu arhitekturu konvolucijske mreže. Ponavlja se primjena dviju konvolucija 3x3, svaka praćena RELU aktivacijskom funkcijom i 2x2 max pooling operacijom sa korakom 2.

Zadatak dekodera sastoji se od povećavanja mape značajki, potom slijedi 2x2 konvolucija koja upola smanjuje broj kanala značajki te povezivanje s odgovarajućom mapom značajki iz enkoderskog puta. Nakon toga ponavljaju se 3x3 konvolucija i ReLU aktivacijska funkcija.


U završnom sloju koristi se 1x1 konvolucija za mapiranje svakog vektora značajki na željeni broj klasa.

4.2. Attention U-Net



SL. 4.2: Arhitektura Attention U-Net segmentacijskog modela[12]

Attention U-Net[12] je proširenje U-Net arhitekture u koji je uvedena uporaba *attention* mehanizma kako bi selektivno istaknuli važne značajke. Mreža slijedi enkoder-dekoder strukturu izvorne U-Net mreže uz sljedeću preinaku: mehanizmi pažnje (eng. *attention gates*) uključeni su u svaki korak dekodiranja.



SL. 4.3: Mehanizam pažnje[12]

Mehanizam pažnje sastoji se od dvije grane: prva uzima mapu značajki iz enkodera, a druga uzima mapu značajki iz prethodnog sloja dekodera. Mehanizam pažnje primjenjuje se tako da se izračunavaju mape pažnje koje prikazuju važnost svakog dijela mapa značajki. Mape pažnje generiraju se uporabom konvolucijskih slojeva i aktivacijskih funkcija. One se zatim množe s mapama značajki. Ovim postupkom bitne značajke biti će istaknute a irelevantne suzbijene u novoj mapi značajki koja se zatim koristi u sljedećem sloju dekodiranja.

Uključivanjem mehanizma pažnje unaprijeđen je izvorni U-Net model mogućnošću selektivnog fokusa na bitne značajke.

5. USPOREDBA MODELA

5.1. Baza podataka

Baza podataka korištena u svrhu treniranja i testiranja U-Net i Attention U-Net modela sastoji se od slika rana na stopalima. Originalna baza podataka dio je natjecanja u segmentaciji slika rana na stopalima iz 2021. godine [13].

U svrhu boljeg učenja mreže te kako bi baza podataka za učenje, testiranje i validaciju bila opširnija napravljena je augmentacija slika rotacijom, zamućenjem ili dodavanjem šuma. Nakon proširivanja količine podataka, konačan skup za treniranje sadrži 9600 slika, a skup za testiranje 200 slika. Ulazne slike su RGB formata a njihove odgovarajuće oznake (eng. *lable*) su binarnog oblika, odnosno pikseli označeni jedinicama predstavljaju ozljedu kože na slici, a pikseli označeni nulom ostali dio slike.

U nastavku su prikazani primjeri manipulacije slikama:




(a) Originalna slika



(b) Zamućena slika



(c) Slika zarotirana za 180 stupnjeva i dodan šum



(d) Zamućena slika zarotirana za 90 stupnjeva u desnu stranu

SL. 5.1: Primjeri augmentacije slike

5.2. Učenje modela

Modeli kojima se bavi ovaj radu napisani su u Pytorch-u, python biblioteci namijenjenoj za razvijanje modela strojnog učenja, te je njihova implementacija javno dostupna na GitHub-u[14].

Modeli su učeni na 500 i 1000 epoha, te su ti modeli zasebno evaluirani. U ovom eksperimentu postavljena su dva pitanja. Ima li razlika u broju epoha utjecaj na rezultate te će biti uspoređena točnost predviđanja modela na skupu podataka koji je odabran za ovaj rad.

5.3. Evaluacija modela

Za evaluaciju modela koristiti će se Dice koeficijent sličnosti koji se često koristi za evaluaciju performansi konvolucijskih neuralnih mreža.

Dice koeficijent mjeri preklapanje između predviđene segmentacijske mape i stvarne vrijednosti (eng. *ground truth*).

Matematički definiran je kao:

$$Dice = \frac{2 * \text{preklapanje}}{\text{Ukupan broj piksela u predviđenoj mapi} + \text{Ukupan broj piksela u stvarnoj mapi}} \quad (5-6)$$

Vrijednost Dice koeficijenta kreće se od 0 do 1, gdje 0 označava da ne postoji podudaranje dok 1 označava savršeno podudaranje.

5.4. Rezultati

Na kraju procesa učenja modeli se evaluiraju na temelju rezultata tijekom učenja. U nastavku su prikazani DICE koeficijenti pojedinog modela u ovisnosti s brojem epoha treniranja modela.

	U-Net	Attention U-Net
500 epoha	0.75661	0.78429
1000 epoha	0.76236	0.77121

Tab. 5.1: Vrijednost DICE koeficijenta nakon treniranja s obzirom na broj epoha treniranja modela

Nakon toga naučeni modeli testirani su i evaluirani na skupu testnih podataka koji sadrži 200 slika te pripadajuće oznake (eng. *lable*). Rezultati, tj. DICE koeficijenti prikazani su u tablici 5.2.

	U-Net	Attention U-Net
500 epoha	0.71684	0.76037
1000 epoha	0.71734	0.74531

Tab. 5.2: Vrijednost Dice koeficijenta na testnom skupu podataka s obzirom na broj epoha treniranja modela

Promatrajući tablice 5.1 i 5.2 može se zaključiti da je razlika u DICE koeficijentima između istog modela treniranog na 500 i 1000 epoha izrazito malena, što znači da je modele bilo dovoljno trenirati na 500 epoha. Ipak treba biti oprezan prio odabiru broja epoha. Primjerice U-Net model treniran na 15 epoha imao je DICE koeficijent 0.19642 što je znatno lošiji rezultat u odnosu na model treniran na većem broju epoha. Nadalje, promatrajući same rezultate dobija se uvid u točnost predviđanja pojedinih modela. U-Net i Attention U-Net daju slične rezultate, Attention U-Net daje neznatno bolje predviđanje ali moguće je zaključiti da oba modela dobro označavaju traženo područje na ulaznoj slici. U nastavku biti će prikazani primjeri slika. Žutom bojom naznačeno je točno označeno područje rane (eng. *ground truth*). Preko točno označenog područja ljubičastom bojom naznačena je predikcija modela treniranog na 1000 epoha.



(a) Predikcija U-Net modela



(b) Predikcija Attention U-Net modela



(c) Predikcija U-Net modela



(d) Predikcija Attention U-Net modela

SL. 5.2: Prikaz preklapanja istinite oznake i predikcije modela

6. ZAKLJUČAK

U ovom radu proučene su osnove neuronskih mreža, specifično konvolucijskih neuronskih mreža. Rad se usredotočio na opis U-Net mreže te inačice Attention U-Net. Mreže su primjenjene na bazu podataka različitu od one za koju su razvijene. Originalna baza podataka sadržavala je slike magnetne rezonance mozga, a u ovom radu korištena je baza podataka slika rana na stopalima.

Učenjem oba modela na istom skupu podataka te učenjem na 500 i 1000 epoha ukupno je naučeno 4 modela koji su na testnom skupu podataka dali različite rezultate.

Modeli su evaluirani uporabom DICE koeficijenta čija vrijednost se kreće između 0 i 1. Rezultat 1 označava savršeno poklapanje između predviđene vrijednosti i istinite vrijednosti, a rezultat 0 nedostatak poklapanja u potpunosti.

Utvrđeno je kako modeli trenirani na 500 epoha daju gotovo iste (ili bolje, kao što je to u slučaju Attention U-Net mreže) rezultate.

I izvorni U-Net model i Attention U-Net model daju dobre rezultate prema DICE koeficijentu od 0.72 za izvorni U-Net model, te 0.76 za Attention U-Net modela.

Ovim završnim radom utvrđeno je kako pri primjeni na augmentiranu bazu podataka koja sadrži slike rana na stopalima Attention U-Net daje neznatno bolje rezultate od izvorne U-Net arhitekture.

LITERATURA

- [1] Norihiko Ohura, Ryota Mitsuno, Masanobu Sakisaka, Yuta Terabe, Yuki Morishige, Atsushi Uchiyama, Takumi Okoshi, Iizaka Shinji, and Akihiko Takushima. Convolutional neural networks for wound detection: The role of artificial intelligence in wound care. *Journal of Wound Care*, 28(Sup10), 2019.
- [2] Daniel Y.T. Chino, Lucas C. Scabora, Mirela T. Cazzolato, Ana E.S. Jorge, Caetano Traina-Jr., and Agma J.M. Traina. Segmenting skin ulcers and measuring the wound area using deep convolutional networks. *Computer Methods and Programs in Biomedicine*, 191:105376, 2020.
- [3] Dina Abdelhafiz, Jinbo Bi, Reda Ammar, Clifford Yang, and Sheida Nabavi. Convolutional neural network for automated mass segmentation in mammography. *BMC Bioinformatics*, 21(S1), 2020.
- [4] Gustavo Blanco, Agma J.M. Traina, Caetano Traina Jr., Paulo M. Azevedo-Marques, Ana E.S. Jorge, Daniel de Oliveira, and Marcos V.N. Bedo. A superpixel-driven deep learning approach for the analysis of dermatological wounds. *Computer Methods and Programs in Biomedicine*, 183:105079, 2020.
- [5] Bruno Oliveira, Helena R. Torres, Pedro Morais, Fernando Veloso, António L. Baptista, Jaime C. Fonseca, and João L. Vilaça. A multi-task convolutional neural network for classification and segmentation of chronic venous disorders. *Scientific Reports*, 13(1), 2023.
- [6] R. Grbić. Predavanja kolegija osnove strojnog učenja, fakultet elektrotehnike, računarstva i informacijskih tehnologija osijek, 2023.
- [7] Stanford university cs231n: Deep learning for computer vision.
- [8] Andreas Norrstig. Visual object detection using convolutional neural networks in a virtual environment. *DIVA*, May 2019.
- [9] David Hilazo Aguilera. Study of deep learning models for class-agnostic counting, Mar 2021.
- [10] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation, May 2015.
- [11] Md Zahangir Alom, Mahmudul Hasan, Chris Yakopcic, Tarek M. Taha, and Vijayan K. Asari. Recurrent residual convolutional neural network based on u-net (r2u-net) for medical image segmentation, May 2018.
- [12] Ozan Oktay, Jo Schlemper, Loic Le Folgoc, Matthew Lee, Mattias Heinrich, Kazunari Misawa, Kensaku Mori, Steven McDonagh, Nils Y Hammerla, Bernhard Kainz, and et al. Attention u-net: Learning where to look for the pancreas, May 2018.
- [13] Foot ulcer segmentation challenge 2021.
- [14] Bigmb. Bigmb/unet-segmentation-pytorch-nest-of-unets: Implementation of different kinds of unet models for image segmentation - unet , rcnn-unet, attention unet, rcnn-attention unet, nested unet.
- [15] Francesca Nuzzo. Sanity checks for explanations of deep neural networks predictions. *Webthesis*, Oct 2020.

- [16] A.J.G van de Ven. A deep graph convolutional neural network aiding in finding feasible shunt plans. Sep 2018.
- [17] Henok Hagos Gidey. Automated hip knee ankle angle determination using convolutional neural networks, Jan 1970.
- [18] Hung Dao. Image classification using convolutional neural networks, 2020.
- [19] Malav Bateriwala and Pierrick Bourgeat. Enforcing temporal consistency in deep learning segmentation of brain MR images. *CoRR*, abs/1906.07160, 2019.
- [20] E. Alpaydin. Introduction to machine learning, mit press, 2014.
- [21] S. Raschka. Python machine learning: Machine learning and deep learning with python, scikit-learn, and tensorflow 2, 3rd edition, 2019.
- [22] Ekin Tiu. Metrics to evaluate your semantic segmentation model, Oct 2020.

SAŽETAK

Završni rad prikazuje proces primjene modela dubokog učenja na nove podatke. Obraduju se osnovni principi dubokog učenja te njihova primjena na duboke neuronske mreže. Nadalje, detaljno je opisana arhitektura konvolucijskih neuronskih mreža te pobliže opisana arhitektura dvije konvolucijske neuronske mreže kojima se rad bavi: U-Net i Attention U-Net. Uspoređeni su navedeni modeli te evaluirani uporabom DICE koeficijenta. U završnom su radu navedeni prednosti, nedostaci te rezultati usporedbe navedenih modela na augmentiranom skupu podataka na kojem mreže nisu izvorno razvijane.

Ključne riječi: Duboko učenje, Konvolucijske duboke neuralne mreže, U-Net, Evaluacija modela

ABSTRACT

The final thesis presents the process of applying deep learning models to new data. It covers the basic principles of deep learning and their application to deep neural networks. Furthermore, it provides a detailed description of the architecture of convolutional neural networks and specifically describes the architecture of two convolutional neural networks addressed in the thesis: U-Net and Attention U-Net. These models are compared and evaluated using the DICE coefficient. The thesis discusses the advantages, disadvantages, and results of comparing these models on an augmented dataset on which the networks were not originally developed.

Keywords: Deep learning, Convolutional neural networks, U-Net, model evaluation

ŽIVOTOPIS

Nives Grčić rođena je 18. veljače 2002. u Osijeku. Upisuje Prirodoslovno-matematičku gimnaziju u Osijeku 2016. godine. 2020. godine upisuje Fakultet elektrotehnike, računarstva i informacijskih tehnologija na Sveučilištu Josipa Juraja Strossmayera u Osijeku, smjer računarstvo.