

UNIVERZA V LJUBLJANI  
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Gasper Spagnolo

## **Lokalizacija brezpilotnih letalnikov**

DIPLOMSKO DELO

UNIVERZITETNI ŠTUDIJSKI PROGRAM  
PRVE STOPNJE  
RAČUNALNIŠTVO IN INFORMATIKA

MENTOR: doc. dr. Luka Cehovin Zajc  
SOMENTOR: asist. Matej Dobrevski

Ljubljana, 2023

To delo je ponujeno pod licenco *Creative Commons Priznanje avtorstva-Deljenje pod enakimi pogoji 2.5 Slovenija* (ali novejšo različico). To pomeni, da se tako besedilo, slike, grafi in druge sestavnine dela kot tudi rezultati diplomskega dela lahko prosto distribuirajo, reproducirajo, uporabljajo, priobčujejo javnosti in predelujejo, pod pogojem, da se jasno in vidno navede avtorja in naslov tega dela in da se v primeru spremembe, preoblikovanja ali uporabe tega dela v svojem delu, lahko distribuira predelava le pod licenco, ki je enaka tej. Podrobnosti licence so dostopne na spletni strani creativecommons.si ali na Inštitutu za intelektualno lastnino, Strelška 1, 1000 Ljubljana.



Izvorna koda diplomskega dela, njeni rezultati in v ta namen razvita programska oprema je ponujena pod licenco GNU General Public License, različica 3 (ali novejša). To pomeni, da se lahko prosto distribuira in/ali predeluje pod njenimi pogoji. Podrobnosti licence so dostopne na spletni strani <http://www.gnu.org/licenses/>.

*Besedilo je oblikovano z urejevalnikom besedil L<sup>A</sup>T<sub>E</sub>X.*

**Kandidat:** Gasper Spagnolo

**Naslov:** Lokalizacija brezpilotnih letalnikov

**Vrsta naloge:** Diplomska naloga na univerzitetnem programu prve stopnje  
Računalništvo in informatika

**Mentor:** doc. dr. Luka Cehovin Zajc

**Somentor:** asist. Matej Dobrevski

**Opis:**

V zadnjem času postaja uporaba brezpilotnih letalnikov vse bolj razširjena in se uporablja v različnih področjih, kot so agrikultura, kartiranje, vojaške operacije in še mnogo drugih. Kljub njihovi vsestranskosti pa se poraja ključno vprašanje: kako se droni obnašajo, ko izgubijo stik z GPS sistemom? Diplomska naloga se osredotoča na to tematiko in predlaga metodo za lokalizacijo brezpilotnih letalnikov ob izgubi GPS signala.

**Title:** UAV localization

**Description:**

In recent times, the use of unmanned aerial vehicles (UAVs) has become increasingly prevalent, finding applications in various fields such as agriculture, mapping, military operations, and many others. Despite their versatility, a critical question arises: how do drones behave when they lose connection to the GPS system? This thesis focuses on this issue and proposes a method for localizing UAVs in the event of a GPS signal loss.



# Kazalo

## Povzetek

## Abstract

<b>1</b>	<b>Uvod</b>	<b>1</b>
<b>2</b>	<b>Teoreticno Ozadje</b>	<b>3</b>
2.1	Osnovni pojmi in terminologija . . . . .	3
<b>3</b>	<b>Transformerske nevronske mreze</b>	<b>9</b>
3.1	Transformerska arhitektura . . . . .	9
3.2	Zgradba transformerja . . . . .	11
3.3	Vision Transformer (ViT) . . . . .	19
3.4	Piramidni vision transformer (PVT) . . . . .	21
3.5	Piramidni vision transformer z uporabo lokalnih značilnosti (PCPVT) . . . . .	22
<b>4</b>	<b>Podatkovni set</b>	<b>25</b>
4.1	Dronske slike . . . . .	25
4.2	satelitske slike . . . . .	27
<b>5</b>	<b>Implementacija</b>	<b>31</b>
<b>6</b>	<b>Eksperimenti</b>	<b>39</b>
6.1	Izbira kriterijske funkcije . . . . .	39

6.2	Ucenje s Stratificiranim Vzorčenjem . . . . .	45
6.3	Vpliv velikosti Hanningovega okna na rezultate . . . . .	48
6.4	Regularizacija v modelu z uporabo izpuščanja nevronov . . . . .	49
<b>7</b>	<b>Sklepne ugotovitve</b>	<b>55</b>
	<b>Literatura</b>	<b>57</b>

# Seznam uporabljenih kratic

kratica	angleško	slovensko
<b>UAV</b>	unmanned aerial vehicle	brezpilotni letalnik
<b>DNN</b>	deep neural network	globoka nevronska mreza
<b>CNN</b>	convolutional neural network	konvolucijska nevronska mreza
<b>RDS</b>	relative distance score	ocena relativne razdalje
<b>MSE</b>	mean squared error	srednja kvadratna napaka
<b>FPI</b>	finding point in an image	iskanje tocke v sliki
<b>WAMF</b>	Weight-Adaptive Multi Feature fusion	Uteženo združevanje več značilk
<b>PCPVT</b>	Pyramid Vision Transformer with Conditional Positional encodings	Piramidni vizualni transformer s pogojnimi pozicijskimi kodiranji



# Povzetek

**Naslov:** Lokalizacija brezpilotnih letalnikov

**Avtor:** Gasper Spagnolo

V vzorcu je predstavljen postopek priprave diplomskega dela z uporabo okolja L<sup>A</sup>T<sub>E</sub>X. Vaš povzetek mora sicer vsebovati približno 100 besed, ta tukaj je odločno prekratek. Dober povzetek vključuje: (1) kratek opis obravnavanega problema, (2) kratek opis vašega pristopa za reševanje tega problema in (3) (najbolj uspešen) rezultat ali prispevek diplomske naloge.

**Ključne besede:** Lokalizacija UAV, geo-lokalizacija, globoko učenje, transformer.



# Abstract

**Title:** UAV localization

**Author:** Gasper Spagnolo

This sample document presents an approach to typesetting your BSc thesis using L<sup>A</sup>T<sub>E</sub>X. A proper abstract should contain around 100 words which makes this one way too short.

**Keywords:** UAV localization, geo-localization, deep learning, transformer.



# Poglavlje 1

## Uvod

Brezpilotni letalniki in sateliti se uporabljajo za iskanje in reševanje, kartiranje terena, kmetijsko spremeljanje, navigacijo dronov in podobne naloge. Raznolikost platform za tehnologijo oddaljenega zaznavanja prinaša veliko prednosti na teh področjih. Ljudje ne lahko le prek satelitov pridobijo podatkov velikega obsega, temveč tudi s pomočjo platform dronov pridobijo bolj jasne lokalne slike.

Trenutno se brezpilotni letalniki v glavnem zanašajo na satelitske signale za navigacijo in določitev položaja med letom. Vendar se v praksi satelitski signal močno oslabi po dolgi razdalji, kar lahko povzroči motnje sprejetega satelitskega signala na dronu. Zlasti na vojaškem področju je izguba satelitskega signala pogosta. Samozadostna lokalizacija in navigacija dronov v okoljih, kjer so satelitski signali omejeni ali moteni, postaja vse pomembnejša.

Da bi rešili problem avtonomne navigacije brezpilotnih letalnikov v okolju, kjer je uporaba satelitskih signalov omejena, so bile prejšnje metode večinoma izvedene z uporabo prepoznavanja slik. Lokalizacija naprave se doseže z ujemanjem slike letalnika z vsako sliko v satelitski slikovni bazi. Med procesom učenja so neprestano skrajševali razdaljo med slikami letalnikov in satelitskimi slikami podobnih regij preko metrike učenja. Metoda prepoznavanja slik je na nekaterih naborih podatkov dosegla odlične rezul-

tate. Vendar ima več problemov:

- Pred praktično uporabo je treba vnaprej pripraviti slikovno bazo za prepoznavanje, in vse slike v bazi so poslane modelu za izvleček značilnosti.
- Za doseganje bolj natančnega pozicioniranja, mora baza pokrivati čim večji obseg in slika poizvedbe mora biti izračunana z vsemi slikami v bazi. To prinaša večji skladiščenski in računski pritisk na računalnik.
- Ko se model posodobi, je treba posodobiti tudi ustrezeno bazo.

Povzemajoč, metoda prepoznavanja slik zahteva veliko predobdelovalnih operacij. Hkrati pa so tudi zahteve za skladiščno zmogljivost in računalniško moč precej velike.

S hitrim razvojem računalniškega vida se pojavlja geolokacija dronov na podlagi satelitskih slik, kjer iscemo tocko v sliki. Ta metoda, podobna sinergiji med človeškimi očmi in možgani, omogoča iskanje ustrezne lokacije v iskalnem zemljevidu (satelitska slika) na podlagi slike drona. Ko je lokacija iskanja najdena na iskalnem zemljevidu, lahko iz podatkov o zemljepisni širini in dolžini iskalnega zemljevida sklepamo o trenutnem položaju drona.

# Poglavlje 2

## Teoreticno Ozadje

### 2.1 Osnovni pojmi in terminologija

#### 2.1.1 Brezpilotni letalnik

Brezpilotni letalniki ali droni so zračna plovila, ki se lahko upravljajo na daljavo ali avtonomno preko programske opreme, ki je integrirana s senzorji in GPS sistemi. Droni imajo široko paleto uporabe v različnih industrijah, vključno z vojaško, komercialno, znanstveno in rekreativno uporabo. Droni so postali izjemno pomembni za zbiranje podatkov v realnem času, izvajanje raziskav in analiz na terenu, kot tudi za opravljanje nalog, ki so lahko za človeka nevarne ali nedostopne. Zaradi svoje fleksibilnosti in prilagodljivosti se uporablja v nalogah, kot so iskanje in reševanje, zaznavanje okoljskih sprememb, kmetijski nadzor, inspekcija infrastrukture, filmska produkcija, dostava paketov in še veliko več. Trg dronov je hitro rastoč in vključuje široko paleto proizvajalcev, ki ponujajo različne modele za različne namene in proračune. Kot tehnologija napreduje, se pojavljajo tudi novi izzivi, vključno z vprašanji zasebnosti, varnosti in zakonodajnimi ureditvami. Zato je to področje postalo predmet intenzivnih raziskav in razvoja, s ciljem optimizacije zmogljivosti, zanesljivosti in dostopnosti brezpilotnih letalnikov.

### 2.1.2 Satelit

Sateliti so objekti, ki krožijo okoli Zemlje ali drugih nebesnih teles in se uporabljajo za številne namene, vključno z komunikacijo, opazovanjem vremena, znanstvenimi raziskavami, navigacijo in še veliko več. Za komercialno in vojaško uporabo je pomembna zlasti komunikacijska satelitska tehnologija. Ta omogoča globalno povezljivost in prenos podatkov, kot so televizijski signali, telefonski klici in internet. Vremenski sateliti so ključni za napovedovanje vremena in spremljanje okoljskih sprememb, saj zagotavljajo nenehne in natančne podatke o atmosferskih razmerah. Navigacijski sateliti, kot je sistem Global Positioning System (GPS), omogočajo določanje položaja in časa na skoraj katerem koli mestu na Zemlji. Ta tehnologija je ključna za številne aplikacije, od vojaške navigacije do vsakodnevnega usmerjanja v prometu. Znanstveni sateliti se uporabljajo za študij nebesnih teles, vključno z Zemljo. Ta opazovanja lahko pomagajo pri razumevanju podnebnih sprememb, geoloških procesov in drugih pomembnih znanstvenih vprašanj. Lansiranje satelita je kompleksno in drago opravilo, ki zahteva natančno načrtovanje in usklajevanje. Sateliti morajo biti postavljeni na natančno določeno orbito, da bi zagotovili optimalno delovanje in izogibanje trkom z drugimi objekti v vesolju.

### 2.1.3 Geolokalizacija

Geolokalizacija je proces določanja geografske lokacije objekta, kot je mobilni telefon, računalnik, vozilo ali kateri koli druga povezana naprava. Ta postopek je postal ključen del sodobnih tehnologij in se uporablja v številnih aplikacijah in storitvah. Geolokalizacija je bistvena za sistem GPS in druge navigacijske sisteme, ki voznikom, pohodnikom in drugim omogočajo natančno navigacijo po poti do cilja. Podjetja uporabljajo geolokalizacijo za ciljno usmerjanje oglasov glede na lokacijo uporabnikov, kar omogoča, da so oglasi prilagojeni lokalnim zanimanjem in potrebam. Geolokalizacija se uporablja tudi v varnostnih aplikacijah, kot so sledenje vozil, iskanje izgubljen-

nih ali ukradenih naprav in nadzor nad dostopom do določenih storitev na podlagi lokacije. V socialnih omrežjih in aplikacijah, ki uporabljajo lokacijo, je geolokalizacija omogočila uporabnikom, da delijo svojo lokacijo, najdejo prijatelje v bližini ali odkrijejo lokalne dogodke in atrakcije. Geolokalizacija se uporablja tudi v različnih znanstvenih raziskavah, kot je spremljanje selitve živali, raziskovanje tektonskih premikov in analiza podnebnih sprememb. Kljub številnim uporabam obstajajo tudi izzivi pri uporabi geolokalizacije. Natančnost geolokalizacije je odvisna od številnih dejavnikov, vključno z dostopnostjo satelitskih signalov, gostoto urbanih območij in uporabljenou tehnologijo. Prav tako se pojavljajo vprašanja glede zasebnosti in varnosti, saj lahko nepooblaščeno sledenje vodi v zlorabo informacij o lokaciji.

#### 2.1.4 Iskanje tocke v sliki

Iskanje točke v sliki (ang. Finding Point in Image, FPI) je postopek identifikacije in določanja posebnih točk ali predmetov v določeni sliki ali seriji slik. Ta tehnologija se je izkazala za pomembno v različnih aplikacijah, vključno z navigacijo in geolokalizacijo.

FPI je pozicijski standard, kjer je vhodna slika, ki jo je treba pozicionirati, poimenovana kot *query*, in slika, ki jo je treba pridobiti, se imenuje *search map*. Ta proces se lahko uporablja za različne naloge lokalizacije, kot so lokalizacija brezpilotnih letalnikov (UAV) in prečno geolokalizacijo. Glavni cilj je najti ustrezno lokacijo v iskalnem zemljevidu. FPI neposredno vnese poizvedbo in iskalni zemljevid v model, ki nato napove topotno kartu, ki predstavlja napovedano lokacijsko porazdelitev poizvedbe v iskalnem zemljevidu. Ena od ključnih prednosti metode FPI je, da ne zahteva veliko pripravljalnih podatkov ali operacij ekstrakcije značilnosti vnaprej. Edino shranjevanje, ki je potrebno, je iskalni zemljevid. Ta metoda omogoča hitro in natančno določanje lokacij v kompleksnih slikah in lahko služi številnim namenom. Na primer, v scenarijih brezpilotnih letalnikov bi FPI lahko uporabili za identifikacijo in sledenje specifičnih lokacij ali objektov na tleh iz zraka. V geolokacijskih aplikacijah bi FPI lahko uporabili za določanje loka-

cije na satelitskih posnetkih. Skupno gledano iskanje točke v sliki, še posebej s pomočjo FPI metode, predstavlja pomemben korak naprej v tehnologijah lokalizacije in navigacije. Ponuja elegantno rešitev za težave, ki jih lahko tradicionalne metode imajo pri obdelavi kompleksnih slik in informacij, in je primerna za široko paleto aplikacij in industrije.

### 2.1.5 Konvolucijska nevronska mreza

Konvolucijska nevronska mreža (CNN - Convolutional Neural Network) je posebna vrsta nevronskih mrež, zasnovana za obdelavo vizualnih podatkov. S svojo zmožnostjo avtomatičnega in prilagodljivega učenja hierarhičnih značilnosti iz vhodnih podatkov se CNN pogosto uporablja v nalogah strojnegavida, kot so razpoznavanje vzorcev, klasifikacija slik in iskanje točk vslikah. Struktura CNN vključuje konvolucijske plasti, ki izvajajo konvolucijsko operacijo s pomočjo majhnih filtrirnih matrik za odkrivanje lokalnih značilnosti, kot so robovi, tekture in oblike. To sledi združevalnim plastem, ki zmanjšajo dimenzionalnost slike, hkrati pa ohranijo pomembne informacije. Na koncu se uporablja polno povezane plasti, ki združijo lokalne značilnosti v globalno razumevanje slike, kar omogoča klasifikacijo ali regresijo. CNN se izkaže za zelo učinkovito v primerjavi z drugimi tipi nevronskih mrež v nalogah, povezanih z obdelavo slik, zlasti zaradi sposobnosti zajemanja prostorskih hierarhij značilnosti. To pomeni, da so sposobne razumeti in reprezentirati sliko na več ravneh abstrakcije.

### 2.1.6 Siamska nevronska mreža

Siamska nevronska mreža (Siamese Neural Network) je posebna vrsta nevronske mreže, ki se uporablja predvsem za primerjavo ali razlikovanje med dvema vhodoma. Glavna značilnost siamske nevronske mreže je, da vsebuje dve ali več identičnih podmrež, ki delijo iste uteži in parametre. Te podmreže vzporedno obdelujejo vhodne podatke in na koncu se rezultati združijo, da se določi razlika ali podobnost med vhodnimi podatki.

Struktura:

- **Dva vhoda:** Siamska mreža sprejme dva vhoda, ki ju želi primerjati.
- **Dve identični podmreži:** Vsak vhod se obdeluje skozi svojo podmrežo. Obe podmreži imata enako strukturo in delita iste uteži.
- **Združevanje rezultatov:** Na koncu se izhodi obeh podmrež združijo, da se določi razlika ali podobnost med vhodnimi podatki.

Siamske nevronske mreže se pogosto uporabljajo v nalogah, kot so preverjanje podobnosti, prepoznavanje obrazov, preverjanje pristnosti in druge naloge, kjer je pomembno ugotoviti, ali sta dva vzorca podobna ali različna.

### 2.1.7 Toplotna karta

Toplotna karta je grafična predstavitev podatkov, kjer vrednosti v matriki predstavljajo različne barve. Ponavadi se uporablja za prikazovanje, kako se določena spremenljivka razporedi po dvodimensionalnem prostoru. To je zelo uporabno pri vizualizaciji razmerij, povezav ali gostote v velikih naborih podatkov. Toplotne karte so priljubljene v mnogih znanstvenih in poslovnih aplikacijah. V statistiki in strojnem učenju se lahko uporablja za prikaz korelacij med različnimi značilnostmi. V biologiji se pogosto uporablja za prikazovanje izražanja genov, v geografiji pa za vizualizacijo gostote prebivalstva ali druge geolokacijske podatke. Ena od prednosti toplotne karte je, da omogoča hitro in intuitivno razumevanje kompleksnih naborov podatkov. Vizualizacija barvnih prehodov pomaga opazovalcu, da hitro zazna vzorce in trende, ki bi jih bilo težje zaznati v tabelaričnih ali tekstovnih prikazih.



# Poglavlje 3

## Transformerske nevronske mreže

### 3.1 Transformerska arhitektura

#### 3.1.1 Predhodni mehanizmi

Preden so obstajali transformerji, so bile najpogostejše metode za obvladovanje zaporedij v jezikovnih modelih rekurentne nevronske mreže (RNN) in njihove različice, kot so dolgokratni kratkotrajni spomini (LSTM) in obogatene RNN (GRU). Najpogostejša uporaba teh modelov v kontekstu strojnega prevajanja ali drugih nalog pretvarjanja zaporedja v zaporedje je bila uporaba strukture kodirnik-dekodirnik. V tej strukturi je bilo zaporedje vhodnih besed ali tokenov kodirano v latentni prostor z uporabo RNN (kodirnik), ta latentni vektor pa je bil nato uporabljen za generiranje zaporedja izhodnih besed ali tokenov z uporabo drugega RNN (dekodirnik). Problem s to strukturo je bil, da je bil latentni prostor omejen na velikost fiksne dolžine in je moral vsebovati vse informacije iz izvornega zaporedja, ki so potrebne za generiranje ciljnega zaporedja. To je omejevalo model pri obvladovanju dolgih zaporedij, saj je bilo težko ohraniti informacije iz zgodnjega dela zaporedja do konca. Da bi to težavo rešili, so raziskovalci vključili mehanizem pozor-

nosti, ki je omogočil dekodirniku, da se osredotoči na različne dele izvornega zaporedja na različnih stopnjah generiranja ciljnega zaporedja. To je bil velik napredok, ki je omogočil boljše obvladovanje dolgih zaporedij.

Članek, ki je predstavil to idejo za strojno prevajanje, je bil ”Neural Machine Translation by Jointly Learning to Align and Translate”[1], objavljen leta 2015. To je bil ključni korak k razvoju Transformerske arhitekture, ki je bila kasneje predstavljena v članku ”Attention is All You Need”[7] leta 2017.

### 3.1.2 Razlag RNN kodirnik-dekodirnik arhitekture

Definirajmo problem strojnega prevajanja kot iskanje najboljše ciljne sekvence  $\vec{E} = (e_0, e_1, \dots, e_m)$  glede na dane izvorne besede  $\vec{F} = (f_0, f_1, \dots, f_n)$ . Ta problem lahko izrazimo kot optimizacijo pogojne verjetnosti  $P(\vec{E}|\vec{F})$ . Začnimo z opisom RNN-kodirnik-dekodirnik arhitekture. Imamo dva RNN modela, kodirnik  $RNN_{enc}$  in dekodirnik  $RNN_{dec}$ . Kodirnik z zaporedjem vektorjev  $\vec{F}$  proizvede skrito stanje  $h_n$ :

$$h_n = RNN_{enc}(f_n, h_{n-1}) \quad (3.1)$$

Začetno stanje  $h_0$  je pogosto postavljeno ali na nič ali se ga mreza nauči. Dekodirnik nato uporablja to skrito stanje, da generira ciljno zaporedje  $\vec{E}$ :

$$e_t = RNN_{dec}(e_{t-1}, h_{t-1}) \quad (3.2)$$

Opomba: pri učenju se za  $e_{t-1}$  pogosto uporablja dejanska vrednost iz ciljnega zaporedja (ne izhod modela), kar je znano kot ”teacher forcing”. Izvorna zaporedja besed  $\vec{F}$  se tako vnašajo v kodirnik, ki generira skrita stanja za vsako besedo:

$$\vec{H} = \text{Encoder}(\vec{F}) \quad (3.3)$$

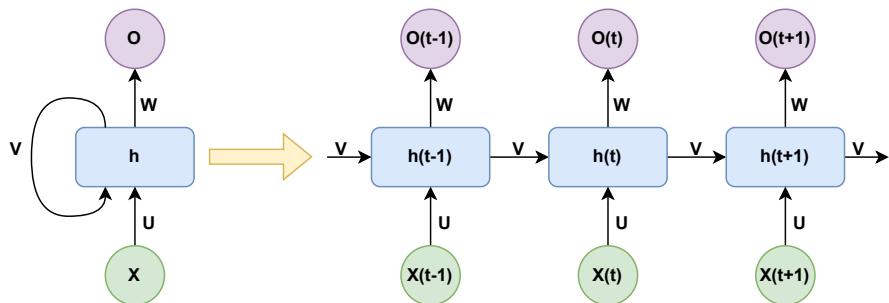
Za vsako besedo v ciljnem zaporedju  $\vec{E}$  se potem izračuna ponderirana vsota skritih stanj iz kodirnika:

$$\vec{a}_t = \text{Attention}(\vec{H}, e_{t-1}) \quad (3.4)$$

Potem se ta vektor uporabi za napoved ciljne besede:

$$e_t = \text{Decoder}(\vec{d}_t, e_{t-1}) \quad (3.5)$$

Ta pristop omogoča, da dekodirnik upošteva vse besede v izvornem zaporedju, ne samo prejšnje besede v ciljnem zaporedju, kar izboljša kakovost prevoda. Vendar je to zgolj matematična formulacija koncepta. Dejanski detajli, kot so vrste in struktura kodirnika in dekodirnika, so odvisni od specifičnega modela, ki ga uporabljamo.

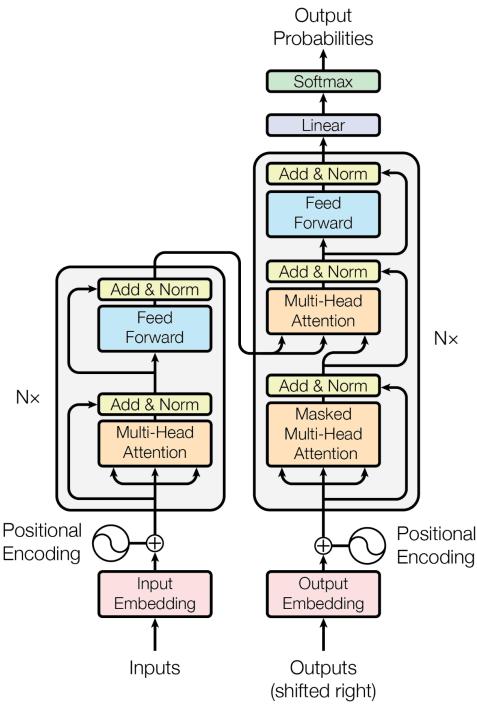


Slika 3.1: Skica RNN modela

## 3.2 Zgradba transformerja

V kontekstu strojnega prevajanja so avtorji v članku "Attention is all you need" [7] o pozornosti predstavili novo vrsto arhitekture, ki se loteva mnogih pasti modelov, ki temeljijo na RNN. Kljub vsem napredkom pri kodirnikih-dekodirnikih RNN, ki smo jih obravnavali zgoraj, je ostalo dejstvo, da so RNN težko paralelizabilni, ker zaporedno obdelujejo vhod. Ključna inovacija tega članka je, da so RNN in njihova skrita stanja v celoti nadomeščena z operacijami na osnovi pozornosti, ki so v mnogih problematičnih režimih bolj učinkovite.

Transformerski model je model kodirnika-dekodirnika. Kodirnik sestavlja  $N$  blokov na levi, dekodirnik pa  $N$  blokov na desni, vidno na sliki 3.2.



Slika 3.2: Izgled transformerskega modela, iz clanka "Attention is all you need" [7].

Med ucenjem se vhodne besede  $\vec{F} = (f_0, \dots, f_n)$  hkrati prenesejo v prvi blok kodirnika, izhod tega bloka pa se nato prenese v njegovega naslednika. Postopek se ponavlja, dokler vseh  $N$  blokov kodirnika ni obdelalo vhoda. Vsak blok ima dve komponenti: plast večglave samopozornosti, ki ji sledi polno povezana plast z aktivacijami ReLU, ki obdeluje vsak element vhodne sekvence vzporedno. Tako večglavi sloj pozornosti kot polno povezana plast sledita koraku *Dodaj in Normiraj - dodaj* se nanaša na residualno povezavo, ki doda vhod vsake plasti na izhod, *normiraj* pa se nanaša na normalizacijo plasti. Ko je vhod prešel skozi vse bloke kodiranja, ostane kodirana predstavitev  $\vec{F}$ .

Dekodirnik pa sestoji iz treh korakov: maske večglave samopozornosti, večglave plasti pozornosti, ki povezuje kodirano izvorno predstavitev z dekodirnikom, in polno povezane plasti z aktivacijami ReLU. Tako kot v ko-

dirniku, vsaki plasti sledi plast *Dodaj in Normiraj*. Dekodirnik sprejme vse ciljne besede  $\vec{E} = (e_0, \dots, e_m)$  kot vhod. V procesu napovedovanja besede  $e_i$  ima dekodirnik dostop do prej generiranih besed. Ne more pa imeti dostopa do besed, ki sledijo  $e_i$ , saj te še niso bile generirane. Maskiranje med učenjem nam omogoča, da posnemamo pogoje, s katerimi se bo model soočil med sklepanjem. Obstaja nekaj ključnih razlik od kodirnika - ena je, da so vhodi v prvo operacijo pozornosti v blokih dekodirnika maskirani, zato ime plasti. To pomeni, da se lahko katera koli beseda v ciljnem izhodu nanaša samo na besede, ki so prišle pred njo. Razlog za to je preprost: med sklepanjem generiramo predvideni prevod  $\vec{E}$  besedo za besedo z uporabo izvornega stavka  $\vec{F}$ .

Druga razlika od kodirnika je druga večglava plast pozornosti, ki se imenuje tudi plast pozornosti kodirnika-dekodirnika. Za razliko od plasti pozornosti na začetku blokov kodirnika in dekodirnika ta plast ni plast samopozornosti.

### 3.2.1 Scaled Dot-Product Attention

Ta funkcija se uporablja v vseh plasteh pozornosti v transformerju. Za zdaj bomo razčlenili matematiko za to operacijo, samo da dobimo občutek, katera števila gredo kam. Kasneje se bomo osredotočili na njegove aplikacije v članku [7].

$$\text{Attention}(Q, K, V) = \text{softmax} \left( \frac{QK^T}{\sqrt{d_k}} \right) V \quad (3.6)$$

Scaled Dot-Product Attention je skoraj identičen Dot-Product Attention-u, omenjenem prej pri Luongu [1]. Edina razlika je, da je vhod v softmax skaliran s faktorjem  $\frac{1}{\sqrt{d_k}}$ .

V članku in predhodni literaturi se vrstice  $Q \in \mathbb{R}^{m \times d_k}$  imenujejo "poizvedbe", vrstice  $K \in \mathbb{R}^{n \times d_k}$  "ključi", in končno vrstice  $V \in \mathbb{R}^{n \times d_v}$  "vrednosti". Upoštevati je potrebno, da se za izvedbo mora število ključev in

vrednosti  $n$  ujemati, vendar se lahko število poizvedb  $m$  razlikuje. Prav tako se mora dimenzionalnost ključev in poizvedb ujemati, vendar se lahko dimenzionalnost vrednosti razlikuje.

Izpeljimo izracun pozornosti. Zaceli bomo z zapisom posameznih vrstic  $Q$  in  $K$ , nato pa bomo izrazili produkt  $QK^T$  v smislu teh vrstic:

$$Q = \begin{pmatrix} q_0 \\ q_1 \\ \vdots \\ q_m \end{pmatrix},$$

$$K^T = \begin{pmatrix} k_0 & k_1 & \cdots & k_n \end{pmatrix}, \quad (3.7)$$

$$QK^T = \begin{pmatrix} q_0 \cdot k_0 & q_1 \cdot k_0 & \cdots & q_m \cdot k_0 \\ q_0 \cdot k_1 & q_1 \cdot k_1 & \cdots & q_m \cdot k_1 \\ \vdots & \vdots & \ddots & \vdots \\ q_0 \cdot k_n & q_1 \cdot k_n & \cdots & q_m \cdot k_n \end{pmatrix}.$$

Nato pridobimo naše uteži pozornosti tako, da vsak element delimo z  $\sqrt{d_k}$  in uporabimo funkcijo softmax nad vsako vrstico:

$$\text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right) = \begin{pmatrix} \text{softmax}\left(\frac{1}{\sqrt{d_k}} \cdot \langle q_0 \cdot k_0, q_1 \cdot k_0, \dots, q_m \cdot k_0 \rangle\right) \\ \text{softmax}\left(\frac{1}{\sqrt{d_k}} \cdot \langle q_0 \cdot k_1, q_1 \cdot k_1, \dots, q_m \cdot k_1 \rangle\right) \\ \vdots \\ \text{softmax}\left(\frac{1}{\sqrt{d_k}} \cdot \langle q_0 \cdot k_n, q_1 \cdot k_n, \dots, q_m \cdot k_n \rangle\right) \end{pmatrix} \quad (3.8)$$

$$= \begin{pmatrix} s_{0,0} & s_{1,0} & \cdots & s_{m,0} \\ s_{0,1} & s_{1,1} & \cdots & s_{m,1} \\ \vdots & \vdots & \ddots & \vdots \\ s_{0,n} & s_{1,n} & \cdots & s_{m,n} \end{pmatrix}^T$$

kjer za vsako vrstico  $i$ , kot rezultat operacije softmax, velja  $\sum_{j=0}^n s_{i,j} = 1$ . Zadnji korak je množenje te matrike z  $V$ :

$$\begin{aligned} \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V &= \begin{pmatrix} s_{0,0} & s_{1,0} & \cdots & s_{m,0} \\ s_{0,1} & s_{1,1} & \cdots & s_{m,1} \\ \vdots & \vdots & \ddots & \vdots \\ s_{0,n} & s_{1,n} & \cdots & s_{m,n} \end{pmatrix} \begin{pmatrix} v_0 \\ v_1 \\ \vdots \\ v_n \end{pmatrix} \\ &= \begin{pmatrix} \sum_{i=0}^m s_{i,0}v_0 \\ \sum_{i=0}^m s_{i,1}v_1 \\ \vdots \\ \sum_{i=0}^m s_{i,n}v_n \end{pmatrix} \end{aligned} \quad (3.9)$$

Tukaj lahko opazimo, da mehanizem pozornosti rezultira v seriji uteženih povprečij vrstic  $V$ , kjer uteži določajo vhodne poizvedbe in ključe. Vsaka od  $m$  poizvedb v  $Q$  rezultira v specifični uteženi vsoti vektorskih vrednosti. Pomembno je omeniti, da v tem posebnem postopku ni nobenih učljivih parametrov - sestavljen je izključno iz matričnih in vektorskih operacij. Poglejmo si se posamezno vrstico  $i$  uteži pozornosti:

$$\text{softmax}\left(\frac{1}{\sqrt{d_k}} \cdot Q \cdot K_i\right) = \frac{1}{S} \cdot \exp\left(\frac{Q \cdot K_i}{\sqrt{d_k}}\right) \quad (3.10)$$

kjer je  $S$  normalizacijska konstanta:

$$S = \sum_{j=0}^m \exp\left(\frac{q_j \cdot k_i}{\sqrt{d_k}}\right) \quad (3.11)$$

Če pogledamo, kako so uteži konstruirane, je izvor imen "poizvedbe", "ključi" in "vrednosti" jasnejši. Tako kot v zgosceni tabeli tabeli ta operacija izbira želene vrednosti preko ustrezajočih, ena-na-ena ključev. Ključi, ki jih iščemo, so označeni z poizvedbami - skalarni produkt med danim ključem in poizvedbo lahko izrazimo kot kot  $\theta$  med njima:

$$q_i \cdot k_j = |q_i| |k_j| \cos(\theta) \quad (3.12)$$

Uporaba eksponentne funkcije povečuje pozitivne vrednosti kosinusa in zmanjšuje negativne. To pomeni, da če sta dva vektorja bolj poravnana (manjši kot med njima), bo njihova zastopanost v vektorju pozornosti večja. Nasprotno pa, če sta dva vektorja manj poravnana (večji kot med njima), bo njihova zastopanost v vektorju pozornosti manjša. To je smiselno, saj želimo, da model daje večjo pozornost tistim ključem, ki so bolj relevantni za dano poizvedbo. Zato je bližje kot sta si ključ  $\vec{k}_j$  in poizvedba  $\vec{q}_i$  po kotu, večja je njihova zastopanost v vektorju pozornosti.

Še ena pomanjkljivost, ki so jo raziskovalci opazili pri modelih, ki temeljijo na RNN (Recurrent Neural Networks) arhitekturi, je, da imajo težave z uporabo informacij iz elementov, ki so bili opaženi daleč v preteklosti. To je posledica tega, kar se imenuje "problem dolgih časovnih razdalj", kjer se informacije iz preteklih korakov postopoma izgubljajo skozi čas. Bolj splošno, RNN imajo težave z povezovanjem zaporednih informacij, ki so med seboj daleč narazen. Tehnike, kot so pozornost na skritih stanjih (attention on hidden states) in dvosmerni modeli (bidirectional models), so bili poskusi za odpravo te težave in so služili kot naravni prehod v tehnike v tem članku.

Avtorji pozornosti omenijo, da delijo vhode v softmax funkcijo z  $\sqrt(d_k)$ , da bi ublažili učinke velikih vhodnih vrednosti, ki bi vodile do majhnih gradientov med ucenjem. Za lazje razumevanje, zakaj veliki argumenti softmax vodijo do majhnih gradientov, lahko konstruiramo primer. Začnimo z definicijo softmax funkcije:

$$\text{softmax}(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)} \quad (3.13)$$

Gradient softmax funkcije je izračunan kot:

$$\frac{\partial \text{softmax}(x_i)}{\partial x_j} = \text{softmax}(x_i) * (\delta_{ij} - \text{softmax}(x_j)) \quad (3.14)$$

kjer  $\delta_{ij}$  je Kroneckerjev delta, ki je enak 1, če sta i in j enaka, in 0 sicer. Če upoštevamo skaliranje, dobimo:

$$\frac{\partial \text{softmax}(x_i/C)}{\partial x_j} = \frac{1}{C} * \text{softmax}(x_i/C) * (\delta_{ij} - \text{softmax}(x_j/C)) \quad (3.15)$$

kjer C je faktor skaliranja. Iz tega lahko vidimo, da skaliranje zmanjšuje velikost gradientov, kar lahko pomaga pri stabilizaciji učenja.

### 3.2.2 Multi-Head Attention

Večglava pozornost (Multi-Head Attention) je razširitev mehanizma pozornosti Scaled Dot-Product Attention. V večglavi pozornosti se vhodni podatki (poizvedbe, ključi in vrednosti) najprej transformirajo v več različnih prostorov z uporabo linearnih preslikav. Nato se za vsak niz izračuna funkcija pozornosti Scaled Dot-Product Attention. Rezultati teh funkcij pozornosti se nato združijo skupaj v eno matriko. Končno, ta matrika se preslika nazaj v izvirni prostor z uporabo druge linearne preslikave, da se pridobi končni rezultat večglave pozornosti. Avtorji to izrazijo v spodnji obliki:

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W_O \quad (3.16)$$

Vsak  $\text{head}_i$  je rezultat izvajanja Scaled Dot-Product Attention na  $i$ -tem nizu transformiranih poizvedb, ključev in vrednosti:

$$\text{head}_i = \text{Attention}(QW_{Qi}, KW_{Ki}, VW_{Vi}) \quad (3.17)$$

kjer so  $Q \in \mathbb{R}^{m \times d_{\text{model}}}$ ,  $K \in \mathbb{R}^{n \times d_{\text{model}}}$ , in  $V \in \mathbb{R}^{n \times d_{\text{model}}}$ . Poleg tega, ob upoštevanju hiperparametra  $h$ , ki označuje število glavnih pozornosti, velja:  $W_{Qi} \in \mathbb{R}^{d_{\text{model}} \times d_k}$ ,  $W_{Ki} \in \mathbb{R}^{d_{\text{model}} \times d_k}$ ,  $W_{Vi} \in \mathbb{R}^{d_{\text{model}} \times d_v}$ , in  $W_O \in \mathbb{R}^{hd_v \times d_{\text{model}}}$ .

Dokazimo, da se matrično množenje izide. Najprej vemo iz prejšnjega razdelka, da bo vsaka matrika  $\text{head}_i$  imela enako število vrstic kot  $QW_{Qi}$  in enako število stolpcev kot  $VW_{Vi}$ . Ker velja  $QW_{Qi} \in \mathbb{R}^{m \times d_k}$  in  $VW_{Vi} \in \mathbb{R}^{n \times d_v}$ , to pomeni, da je  $\text{head}_i \in \mathbb{R}^{m \times d_v}$ . Ko združimo  $h$  takih matrik, dobimo

matriko v  $\mathbb{R}^{m \times hd_v}$ . Množenje z  $W_O$  daje matriko v  $\mathbb{R}^{m \times d_{\text{model}}}$ . Kar drzi - začeli smo z  $m$  poizvedbami v  $Q$  in končali z  $m$  odgovori v izhodu operatorja.

Vsak izračun glave ima drugačno linearne preslikavo za matrike ključev, poizvedb in vrednosti. Vsaka od teh preslikav se nauči med učenjem.

### Maskiranje vhodov

En način za maskiranje vhodov je preprosto dodajanje matrike  $M$  k argumentu ki vsebuje 0 v spodnjem trikotniku in  $-\infty$  povsod drugje:

$$\begin{aligned} & \frac{1}{\sqrt{d_k}} Q' K'^T + M = \\ & \left( \begin{array}{ccccc} \frac{1}{\sqrt{d_k}} \vec{q}_0 \cdot \vec{k}'_0 & \vec{q}_0 \cdot \vec{k}'_1 & \cdots & \vec{q}_0 \cdot \vec{k}'_n \\ \vec{q}_1 \cdot \vec{k}'_0 & \vec{q}_1 \cdot \vec{k}'_1 & \cdots & \vec{q}_1 \cdot \vec{k}'_n \\ \vdots & \vdots & \ddots & \vdots \\ \vec{q}_n \cdot \vec{k}'_0 & \vec{q}_n \cdot \vec{k}'_1 & \cdots & \vec{q}_n \cdot \vec{k}'_n \end{array} \right) + \left( \begin{array}{ccccc} 0 & -\infty & -\infty & \cdots & -\infty \\ -\infty & 0 & 0 & \cdots & -\infty \\ -\infty & \vdots & \vdots & \vdots & \vdots \\ -\infty & 0 & 0 & \cdots & 0 \\ -\infty & 0 & 0 & \cdots & 0 \end{array} \right) \\ & = \frac{1}{\sqrt{d_k}} \left( \begin{array}{ccccc} \vec{q}_0 \cdot \vec{k}'_0 & -\infty & -\infty & \cdots & -\infty \\ \vec{q}_1 \cdot \vec{k}'_0 & \vec{q}_1 \cdot \vec{k}'_1 & -\infty & \cdots & -\infty \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ \vec{q}_{n-1} \cdot \vec{k}'_0 & \vec{q}_{n-1} \cdot \vec{k}'_1 & \vec{q}_{n-1} \cdot \vec{k}'_2 & \cdots & -\infty \\ \vec{q}_n \cdot \vec{k}'_0 & \vec{q}_n \cdot \vec{k}'_1 & \vec{q}_n \cdot \vec{k}'_2 & \cdots & \vec{q}_n \cdot \vec{k}'_n \end{array} \right) \end{aligned} \quad (3.18)$$

Nato ima izvajanje softmaxa na vsaki vrstici učinek pošiljanja vseh  $-\infty$  celic na 0, pri čemer ostanejo samo veljavni izrazi za pozornost.

### 3.2.3 Pozornost kodirnik-dekodirnik

Tretja in zadnja uporaba pozornosti v članku [7] je pozornost kodirnik-dekodirnik, ki se uporablja v blokih dekodirnika neposredno po sloju maske večglave pozornosti, da se povežejo izvorne in ciljne sekvene. Medtem ko so pri samopozornosti vsi trije vhodi enaka matrika, to tukaj ne velja.

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W_O, \quad \text{head}_i = f(Q, K, V)$$

Ko govorimo o pozornosti med kodirnikom in dekodirnikom, je edina razlika od prej v tem, da  $Q$  izhaja iz sloja maske večglave pozornosti, medtem ko sta  $K$  in  $V$  kodirani predstavitevi  $\vec{F}$ . Lahko bi razmišljali o tem tako, da model zastavlja vprašanje o tem, kako se vsak položaj v ciljni sekvenci nanaša na izvor, in pridobiva predstaviteve izvora za uporabo pri generiranju naslednje besede v cilju. Pomembno je poudariti, da vsi bloki dekodirnika prejmejo enake podatke od kodirnika. Od prvega do  $N$ -tega bloka dekodirnika vsak uporablja kodirano izvorno sekvenco kot ključe in vrednosti.

### 3.3 Vision Transformer (ViT)

Transformerji so prvotno bili omejeni na obdelavo zaporedij, kar je idealno za jezik, vendar ne nujno za slike, ki so običajno 2D. To se je spremenilo z razvojem Vision Transformerja (ViT) s strani Google-a [5]. Namesto da bi slike obdelovali kot 2D mreže pikslov (kot to počnejo konvolucijske nevronске mreže), Vision Transformer slike obravnava kot zaporedje majhnih kvadratov ali ”oblizev”. To omogoča uporabo enakih tehnik samo-pozornosti, ki so bile učinkovite v jezikovnih modelih, tudi za obdelavo slik. Ta pristop je pokazal obetavne rezultate, saj je Vision Transformer dosegel ali presegel učinkovitost konvolucijskih nevronskih mrež na številnih nalogah računalniškega vida.

#### ViT arhitektura

- Razdelitev slike na oblize: Slika velikosti  $H \times W \times C$  se razdeli na kvadrate (oblize) velikosti  $P \times P$ , kjer je  $H$  višina,  $W$  širina,  $C$  število barvnih kanalov in  $P$  velikost obliza. To ustvari  $(H \cdot W)/P^2$  oblizev. Vsak obliz se nato zravna v 1D vektor dolžine  $P^2 \cdot C$ . Linearne projekcije: Vsak 1D vektor  $x$  se prenese skozi enostaven linearni model (npr. polno povezano plast), da se pretvori v vektorski vložek. To se lahko

zapiše kot:

$$z = Wx + b$$

kjer sta  $W$  in  $b$  uteži in pristranskost linearne plasti.

- Dodajanje pozicijskih vložkov: Ker transformerji ne vsebujejo nobene inherentne informacije o relativni ali absolutni poziciji vložkov v zaporedju, se dodajo pozicijski vložki. To so enaki vektorji, ki se dodajo vložkom oblikev, da bi modelu dali nekaj informacij o tem, kje se oblik nahaja v sliki. Če je  $z_i$  vložek  $i$ -tega oblikev in  $p_i$  pozicijski vložek, potem je končni vložek  $e_i$  določen kot:

$$e_i = z_i + p_i$$

- Transformerjevi bloki: Zaporedje vložkov (zdaj z dodanimi pozicijskimi vložki) se nato prenese skozi več blokov transformerjev. Ti bloki vsebujejo večglavo samo-pozornost in mreže feed-forward, ki omogočajo modelu, da se nauči, kako povezati različne dele slike. Večglava samo-pozornost se lahko zapiše kot:

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W_O$$

kjer je  $\text{head}_i = \text{Attention}(QWQi, KW_{Ki}, VW_{Vi})$ ,  $Q$ ,  $K$  in  $V$  so poi-zvedbe, ključi in vrednosti,  $W_{Qi}$ ,  $W_{Ki}$ ,  $W_{Vi}$  in  $W_O$  so uteži, ki se naučijo, in  $\text{Attention}$  je funkcija samo-pozornosti.

- Klasifikacijska glava: Na koncu se uporabi klasifikacijska glava (ponavadi ena polno povezana plast), da se izračuna končna napoved za dano nalogu (npr. klasifikacija slik). To se lahko zapiše kot:

$$y = \text{softmax}(W_2 \text{ReLU}(W_1 e))$$

kjer sta  $W_1$  in  $W_2$  uteži polno povezanih plasti,  $e$  je vložek, ki izhaja iz transformerjevih blokov, in ReLU in softmax sta aktivacijski funkciji.

### 3.4 Piramidni vision transformer (PVT)

Piramidni Vision Transformer (PVT) [9] je bil razvit z namenom vključitve piramidne strukture v okvir Transformerja, kar omogoča generiranje večrazsežnih značilnostnih map za naloge goste napovedi, kot so zaznavanje objektov in semantična segmentacija. Arhitektura PVT je razdeljena na štiri stopnje. Vsaka od teh stopenj je sestavljena iz plasti za vdelavo obližev, imenovane "patch embedding", in iz več plasti Transformer kodirnika. Značilnost te arhitekture je, da izstopna ločljivost štirih stopenj postopoma zmanjšuje, kar sledi piramidni strukturi. Na najvišji stopnji je ločljivost značilnostne mape največja, medtem ko se na najnižji stopnji zmanjša.

Za boljše razumevanje, poglejmo podrobnejše prvo stopnjo: Vhodna slika velikosti  $H \times W \times 3$  je razdeljena na obliže velikosti  $4 \times 4 \times 3$ . To pomeni, da je število obližev enako  $HW/4^2$ . Vsak obliž je nato sploščen in prenesen v linearno projekcijo, kar rezultira v vdelanih obližih velikosti  $HW/4^2 \times C1$ . Ti vdelani obliži, skupaj z dodano vdelavo položaja, prehajajo skozi Transformer kodirnik z  $L1$  plastmi. Izhod iz tega kodirnika je nato preoblikovan v značilnostno mapo  $F1$  velikosti  $H/4 \times W/4 \times C1$ .

Matematično to lahko izrazimo kot:

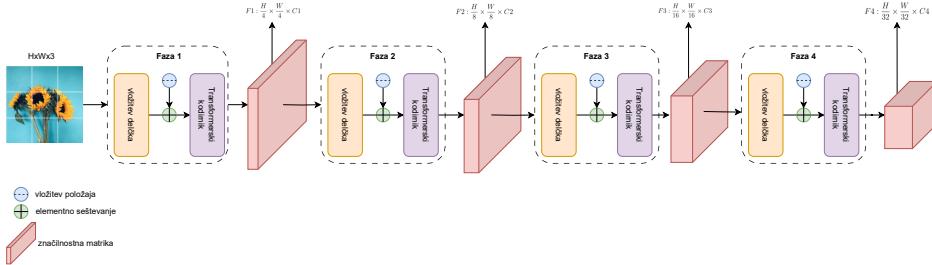
$$F1 = \frac{H}{4} \times \frac{W}{4} \times C1 \quad (3.19)$$

Naslednje stopnje PVT sledijo podobnemu pristopu, vendar z različnimi ločljivostmi in dimenzijami. Na primer, značilnostne mape  $F2, F3$  in  $F4$  so pridobljene z različnimi koraki, ki so 8, 16 in 32 slikovnih pik glede na vhodno sliko.

Ena izmed ključnih inovacij v PVT je uporaba pozornosti za zmanjšanje prostorskega obsega (SRA) namesto tradicionalne večglave pozornostne plasti (MHA). Ta pristop omogoča PVT, da učinkovito obdela značilnostne mape visoke ločljivosti.

V primerjavi z Vision Transformer (ViT), PVT prinaša večjo prilagodljivost, saj lahko generira značilnostne mape različnih meril/kanalov v različnih fazah. Poleg tega je bolj vsestranski, saj se lahko enostavno vključi in upo-

rabi v večini modelov za spodnje naloge. Prav tako je bolj prijazen do računalništva in spomina, saj lahko obdela značilnostne mape višje ločljivosti ali daljše sekvence.



Slika 3.3: Skica PVT modela

### 3.5 Piramidni vision transformer z uporabo lokalnih značilnosti (PCPVT)

Twins-PCPVT [3] je zasnovan na osnovi PVT in CPVT [2]. Glavna razlika med Twins-PCPVT in PVT je v načinu, kako se uporablja pozicijski kodiranji. V PVT so uporabljena absolutna pozicijska kodiranja, medtem ko Twins-PCPVT uporablja pogojna pozicijska kodiranja (CPE), ki so bila predlagana v CPVT.

PVT je uvedel piramidni večstopenjski dizajn, da bi bolje obravnaval naloge goste napovedi, kot so zaznavanje objektov in semantična segmentacija. Vendar je bilo presenetljivo ugotovljeno, da je manjša učinkovitost PVT-ja predvsem posledica uporabe absolutnih pozicijskih kodiranj. Absolutna pozicijska kodiranja se soočajo s težavami pri obdelavi vhodov različnih velikosti, kar je pogosto v nalogah goste napovedi.

V Twins-PCPVT so absolutna pozicijska kodiranja nadomeščena s pogojnimi pozicijskimi kodiranjji (CPE), ki so pogojena na vhodih in se lahko naravno izognejo zgoraj omenjenim težavam. Generator pozicijskega kodiranja (PEG), ki generira CPE, je postavljen za prvim kodirnim blokom vsake

stopnje. Uporablja najpreprostejšo obliko PEG, tj. 2D globinsko konvolucijo brez normalizacije serije.

$$CPE = f(PEG(E_1, E_2, \dots, E_n)) \quad (3.20)$$

Kjer je CPE pogojno pozicijsko kodiranje,  $f$  je funkcija, ki generira kodiranje na podlagi vhodnih značilnosti, in  $E_i$  so značilnosti iz različnih stopenj kodirnika. Twins-PCPVT združuje prednosti tako PVT kot CPVT, kar ga naredi enostavnega za učinkovito implementacijo. Eksperimentalni rezultati so pokazali, da ta preprosta zasnova lahko doseže zmogljivost nedavno predlaganega Swin transformerja [6].



# Poglavlje 4

## Podatkovni set

### 4.1 Dronske slike

Nabor podatkov, ki ga predstavljamo, je bil zasnovan z namenom raziskovanja in analize dronov v različnih mestnih scenarijih. Osredotoča se na dve ključni območji:

1. Gosto pozidana mestna območja z zgradbami in
2. odprte zelene površine, kot so parki in travniki.

Zajem slik je bil izveden na naključnih poteh po mestu, kar omogoča širok spekter scenarijev in situacij. V mestnih območjih je poudarek na razumevanju, kako se brezpilotni letalniki lokalizirajo in navigirajo med visokimi zgradbami, kjer so lahko GPS signali zmanjšani ali moteni. V zelenih območjih je cilj razumeti, kako se brezpilotni letalniki obnašajo v okoljih, kjer so vizualni vzorci manj raznoliki in se teren lahko zdi monoton. V naboru podatkov za ucenje je 10.000 slik iz desetih mest, pri čemer vsako mesto prispeva 1.000 slik. Brezpilotni letalniki so bili kalibrirani na višini 150 metrov nad navedeno nadmorsko višino mesta. Kamere na brezpilotnih letalnikih imajo vidno polje 80 stopinj in so usmerjene pravokotno na središče Zemlje. Vse slike so bile ustvarjene z uporabo orodja Google Earth Studio

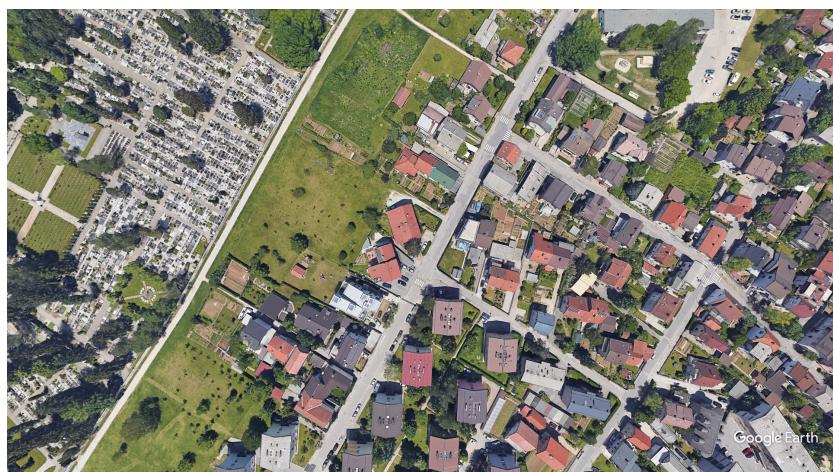
Mesta, vključena v ucni nabor podatkov, so:

- **Maribor:** Nadmorska višina: 272m, Višina drona: 150m, Skupaj: 422m nad morsko gladino.
- **Trst:** Nadmorska višina: 23m, Višina drona: 150m, Skupaj: 173m nad morsko gladino.
- **Zagreb:** Nadmorska višina: 158m, Višina drona: 150m, Skupaj: 308m nad morsko gladino.
- **Gradec:** Nadmorska višina: 353m, Višina drona: 150m, Skupaj: 503m nad morsko gladino.
- **Celovec:** Nadmorska višina: 446m, Višina drona: 150m, Skupaj: 596m nad morsko gladino.
- **Videm:** Nadmorska višina: 113m, Višina drona: 150m, Skupaj: 263m nad morsko gladino.
- **Pula:** Nadmorska višina: 17m, Višina drona: 150m, Skupaj: 167m nad morsko gladino.
- **Pordenone:** Nadmorska višina: 24m, Višina drona: 150m, Skupaj: 174m nad morsko gladino.
- **Szombathely:** Nadmorska višina: 212m, Višina drona: 150m, Skupaj: 362m nad morsko gladino.
- **Benetke:** Nadmorska višina: -1m, Višina drona: 150m, Skupaj: 149m nad morsko gladino.

Dodatno je bil v nabor dodan tudi testni nabor podatkov za Ljubljano, ki vključuje 1.000 slik.

Vsaka slika je opremljena z oznakami lokacije kamere v sistemu ECEF. Sistem ECEF (Earth Centered, Earth Fixed) je globalni koordinatni sistem z izhodiščem v središču Zemlje.

Ta nabor podatkov ponuja vpogled v izzive in možnosti, ki jih brezpilotni letalniki srečujejo v različnih mestnih okoljih, in je ključnega pomena za razvoj naprednih algoritmov za lokalizacijo in navigacijo.



Slika 4.1: Primer dronske slike.

## 4.2 satelitske slike

Za vsako dronsko sliko sem poiskal ustrezni satelitski "tile" ali ploščico. Ta korak je bil ključnega pomena, saj je zagotovil, da so satelitske slike popolnoma usklajene z dronskimi slikami v smislu geografske lokacije. Ko sem identificiral ustrezni satelitski ploscici, sem jo prenesel neposredno iz Mapbox API-ja, priznanega vira za visokokakovostne satelitske slike. Da bi zagotovil dodatno globino in kontekst za vsako lokacijo, nisem prenesel samo osrednje ploscice, temveč tudi vse njegove sosednje ploščice. Te sosednje ploščice so bile nato združene z osrednjo ploščico za ustvarjanje enotne TIFF datoteke. Ta pristop je omogočil, da sem imel na voljo širšo regijo za analizo in učenje.

Ko sem imel pripravljene TIFF datoteke, sem začel z učnim procesom. Za vsako iteracijo učenja sem iz vsake TIFF datoteke naključno izrezal regijo velikosti 400x400 pikslov. Ključnega pomena je bilo, da se je točka lokalizacije

vedno nahajala nekje znotraj te izrezane regije. Ta metoda je zagotovila, da je bil model izpostavljen širokemu naboru scenarijev in kontekstov, hkrati pa je ohranila natančnost in relevantnost lokalizacijskih podatkov. S tem pristopom sem uspešno sestavil nabor podatkov, ki združuje najboljše iz obeh svetov: detajlnost dronskih slik in širino satelitskih slik, kar omogoča poglobljeno analizo in učinkovito učenje.

Ko govorimo o ploscicah v kontekstu kartografije in GIS (Geografski informacijski sistem), se običajno nanašamo na kvadratne segmente, ki pokrivajo Zemljo in se uporabljajo za hitrejše in učinkovitejše prikazovanje zemljevidov na spletu. Sistem ploscic je zelo priljubljen v spletnih kartografskih aplikacijah, kot je Google Maps.

Za pretvorbo geografskih koordinat (latitude in longitude) v ploscicne koordinate ( $x, y$ ) na določeni ravni povečave z uporabo Mercatorjeve projekcije, lahko izrazimo:

- Pretvorba geografskih koordinat v radiane:

$$\begin{aligned} \text{lat}_{\text{rad}} &= \text{latitude} \times \frac{\pi}{180}, \\ \text{lon}_{\text{rad}} &= \text{longitude} \times \frac{\pi}{180} \end{aligned}$$

- Pretvorba radianov v normalizirane koordinate Mercatorja:

$$\begin{aligned} x &= \frac{\text{lon}_{\text{rad}} = +\pi}{2\pi}, \\ y &= \frac{\pi - \log(\tan(\frac{\pi}{4} + \frac{\text{lat}_{\text{rad}}}{2}))}{2\pi} \end{aligned}$$

- Pretvorba normaliziranih koordinat v ploscicne koordinate:

$$\begin{aligned} \text{tile}_x &= \text{floor}(x \times 2^z), \\ \text{tile}_y &= \text{floor}(y \times 2^z) \end{aligned}$$



Slika 4.2: Primer pripadajoče satelitske slike za dronsko sliko.



# Poglavlje 5

## Implementacija

### 5.0.1 Motivacija

Pri sledenju objektov raziskovalci sledenje izvajajo z izračunom podobnosti med predlogo in iskalnim območjem v trenutnem okviru. Metoda iskanja točk znotraj slike izhaja iz metode na področju sledenja objektov, vendar je ta metoda bolj zapletena kot sledenje objektov. To je zato, ker sta predloga (dronska slika) in iskalna slika (satelitske slike) iz različnih pogledov, kar povzroča veliko variabilnost.

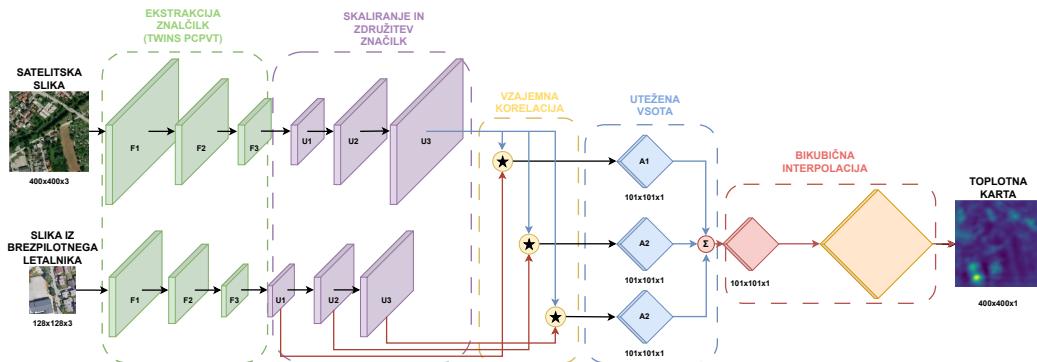
Metoda iskanja točk z uporabo slike uporablja satelitsko sliko kot iskalno sliko in dronsko sliko kot poizvedbeno sliko. Nato se slike, posnete z dronom, in satelitske slike ustreznih območij prenesejo v end-to-end (celovito?) omrežje. Po obdelavi je rezultat toplotna karta, točka z najvišjo vrednostjo na toplotni karti pa je lokacija drona, kot jo napove model. Nato to lokacijo preslikamo na satelitsko sliko. Položaj drona lahko določimo glede na informacije o geografski širini in dolžini, ki jih ohranja satelitska slika. V FPI avtorji uporabljajo dva Deit-S brez deljenih uteži kot modula za ekstrakcijo značilnosti za vertikalne poglede slik drona in satelitskih slik [4]. Nato se ekstrahirane značilnosti podvržejo izračunu podobnosti, da se pridobi toplotna karta. Končno preslikamo lokacijo z najvišjo vrednostjo toplotne karte na satelitsko sliko, da določimo lokacijo brezpilotnega letalnika.

V FPI se za izračun podobnosti uporablja zadnja plast zemljevidnih

značilnosti [4]. Ker je končni izhodni zemljevid stisnjen 16-krat, model izgubi veliko prostorskih informacij. Izguba prostorskih informacij prinese nepopravljivo izgubo končne natančnosti pozicioniranja.

Za izboljšanje lokalizacijske zmogljivosti modela je bila uporabljena struktura piramidnih značilnosti (Twins-PCPVT) in modul utežno prilagodljivega združevanja večznačilnostnih lastnosti(WAMF)

V osnovi modela so bile narejene izboljšave z uporabo dveh močnejših PCPVT-S kot modulov za ekstrakcijo značilnosti iz brezpilotnega letalnika in satelitske slike. Da bi bolje izvlekli informacije večih meril in obdržali več prostorskih informacij, so prvotno izvlečene značilnosti poslane v omrežje piramide značilnosti za nadaljnjo ekstrakcijo značilnosti, nato pa se modul WAMF uporablja za izračun podobnosti in fuzijo več značilnosti. Končno so združene značilnosti povečane, da se ustvari končna izhodna napovedna mapa. Na izhodu dobimo toplotno karto iste velikosti kot vhodna satelitska slika v WAMF-FPI.



Slika 5.1: Skica arhitekture modela

### 5.0.2 Modul za ekstrakcijo značilnosti

WAMF-FPI uporablja strukturo, podobno omrežju Siamese, vendar se razlikuje od tradicionalnega sledenja objektom. Med satelitskimi in slikami brezpilotnega letalnika je velika razlika, saj izvirajo iz različnih naprav. Zato

veji slike brezpilotnega letalnika in satelitske slike v WAMF-FPI ne uporabljata metode deljenja uteži. WAMF-FPI uporablja satelitske slike ( $400 \times 400 \times 3$ ) in slike brezpilotnega letalnika ( $128 \times 128 \times 3$ ) kot vhod modela, nato pa se značilnosti slik ekstrahirajo s pomočjo PCPVT-S. Natančneje, odstranili smo zadnjo stopnjo PCPVT-S in uporabili samo prve tri stopnje za ekstrakcijo značilnosti. Ko je velikost vhodnih slik  $400 \times 400 \times 3$  in  $128 \times 128 \times 3$ , lahko iz obeh vej pridobimo značilnostne mape z obliko  $25 \times 25 \times 320$  in  $8 \times 8 \times 320$ . V nasprotju z Deit-S, uporabljenim v FPI [4], ima PCPVT-S piramidno strukturo, ki se lahko bolje prilagodi nalogi goste napovedi. Uporaba piramidne strukture postavlja temelje za kasnejšo uporabo modula WAMF. Hkrati omrežje z piramidno strukturo lahko učinkovito zmanjša količino izračunov in izboljša hitrost izračuna. To je zelo pomembno za dejansko implementacijo metode.

Po uporabi PCPVT-S za ekstrakcijo informacij iz slike, se izračun podobnosti izvede neposredno na zadnjih značilnostnih mapah. Končni izhod pa je stisnjen le za faktor štiri v primerjavi z vhodom. Katerega se potem z bikubicno interpolacijo poveca na velikost vhodne satelitske slike.

Lokalizacijska pristranskost, ki jo povzroča nizka ločljivost značilnostne mape, je izključena pri viru. Ker ima plitva značilnostna mapa z visoko ločljivostjo več prostorskih informacij, je globoka značilnostna mapa z bogatimi semantičnimi informacijami združena z lateralno povezovalno strukturo.

WAMF-FPI uporablja konvolucijske mreže za ekstrakcijo značilnosti iz vhodnih slik. Konvolucija je matematična operacija, ki omogoča filtriranje vhodnih podatkov (v tem primeru slik) z uporabo določenega jedra ali filtra. Ta operacija omogoča modelu, da ”vidi” in prepozna različne vzorce in značilnosti v slikah.

Začetno fazo obdelave v WAMF-FPI predstavlja uporaba konvolucijskega jedra velikosti ena. Ta korak je namenjen prilagoditvi kanalske dimenzije tri-stopnjske značilnostne mape, ki je bila pridobljena s pomočjo PCPVT-S. Stevilo izhodnih kanalov nastavljeno na 64, kar omogoča kompaktno in učinkovito predstavitev značilnosti. Po tem koraku se na značilnostnih ma-

pah zadnjih dveh stopenj izvede operacija upsamplinga. Ta operacija poveča ločljivost značilnostnih map, kar omogoča bolj natančno lokalizacijo. Pridobljene značilnostne mape se nato združijo z značilnostnimi mapami istega merila, ki jih izhaja iz osnovnega modela.

V zadnjem koraku se značilnosti dodatno ekstrahirajo z uporabo konvolucijskega jedra velikosti 3. Ta korak omogoča modelu, da izloči bolj kompleksne in globoke značilnosti iz združenih map. Končni rezultat je združena značilnostna mapa, ki vsebuje tako plitve (prostorske) kot globoke (semantične) značilnosti. Ta kombinacija omogoča modelu, da učinkovito prepozna in lokalizira objekte na vhodnih slikah.

### 5.0.3 Arhitektura utežno prilagodljivega združevanja večznačilnostnih lastnosti(WAMF)

Modul za združevanje značilnosti je zasnovan tako, da združuje informacije iz dveh ločenih vhodnih tokov, v tem primeru iz UAV (brezpilotnega letalnika) in SAT (satelita). Ta modul uporablja piramido značilnosti iz obeh in izračuna korelacije med njimi, da jih združi v en sam izhod.

Za začetek se izvedejo konvolucijske operacije na značilnostnih mapah UAV in SAT. Konvolucijske operacije so izvedene s konvolucijskimi jedri velikosti  $1 \times 1$ , kar omogoča prilagoditev kanalskih dimenzij značilnostnih map.

Za UAV značilnostne mape:

$$U1_{\text{UAV}} = \text{Conv1}_{\text{UAV}}(s3_{\text{UAV}}) \quad (5.1)$$

$$U2_{\text{UAV}} = \text{Upsample}(U1_{\text{UAV}}) + \text{Conv2}_{\text{UAV}}(s2_{\text{UAV}}) \quad (5.2)$$

$$U3_{\text{UAV}} = \text{Upsample}(U2_{\text{UAV}}) + \text{Conv3}_{\text{UAV}}(s1_{\text{UAV}}) \quad (5.3)$$

Za SAT značilnostne mape:

$$U1_{\text{SAT}} = \text{Conv1}_{\text{SAT}}(s3_{\text{SAT}}) \quad (5.4)$$

$$U2_{\text{SAT}} = \text{Upsample}(U1_{\text{SAT}}) + \text{Conv2}_{\text{SAT}}(s2_{\text{SAT}}) \quad (5.5)$$

$$U3_{\text{SAT}} = \text{Upsample}(U2_{\text{SAT}}) + \text{Conv3}_{\text{SAT}}(s1_{\text{SAT}}) \quad (5.6)$$

Kjer je Upsample funkcija, ki poveča prostorsko resolucijo značilnostne mape z uporabo bikubične interpolacije.

$$A1 = \text{corr}(U1_{\text{UAV}}, U3_{\text{SAT}}) \quad (5.7)$$

$$A2 = \text{corr}(U2_{\text{UAV}}, U3_{\text{SAT}}) \quad (5.8)$$

$$A3 = \text{corr}(U3_{\text{UAV}}, U3_{\text{SAT}}) \quad (5.9)$$

Kjer je corr funkcija za izračun korelacije med dvema značilnostnima mapama.

Korelacija v kontekstu obdelave slik je postopek izračuna podobnosti med dvema slikama ali značilnostnima mapama. V osnovi ena značilnostna mapa (poimenovana poizvedba) ”drsi” čez drugo značilnostno mapo (poimenovana iskalna regija) in izračuna podobnost med njima na vsaki lokaciji. Rezultat tega postopka je nova značilnostna mapa, imenovana korelacijska mapa, kjer vsaka vrednost predstavlja stopnjo podobnosti med poizvedbo in delom iskalne mape na določeni lokaciji.

Matematično je korelacija med dvema funkcijama  $f$  in  $g$  definirana kot:

$$(f \star g)(t) = \int_{-\infty}^{\infty} f^*(\tau)g(t + \tau)d\tau \quad (5.10)$$

Kjer je  $f^*$  kompleksno konjugirana funkcija  $f$ .

V kontekstu diskretnih signalov, kot so slike ali značilnostne mape, je korelacija definirana kot:

$$(f \star g)[n] = \sum_{m=-\infty}^{\infty} f^*[m]g[n+m] \quad (5.11)$$

Nazadnje se izvede uteženo združevanje teh treh koreliranih značilnostnih map s pomočjo naučljivih uteži:

$$\text{fused\_map} = w_1 \cdot A1 + w_2 \cdot A2 + w_3 \cdot A3 \quad (5.12)$$

Za dokončanje postopka se uporabi bikubična interpolacija, da se fused\_map poveča na velikost vhodne satelitske slike. Na izhodu dobimo topotno karto iste velikosti kot vhodna satelitska slika v WAMF-FPI.

#### 5.0.4 RDS metrika

Da bi lahko ovrednotili in primerjali zmogljivost našega modela, uporabljamo metriko RDS [8]. Zaradi različnih meril podatkov v naboru podatkov vsak piksel v različnih satelitskih slikah predstavlja različno razdaljo. Čeprav model morda najde točko, ki je na satelitski sliki blizu dejanske lokacije, lahko v resničnem prostoru povzroči veliko napako. Da bi se izognili težavam zaradi spremembe merila, RDS izračuna relativno razdaljo na ravni pikslov med napovedano in dejansko točko.

Enačba za izračun RDS je naslednja:

$$RDS = e^{-k \times \sqrt{\left(\frac{dx}{w}\right)^2 + \left(\frac{dy}{h}\right)^2}} \quad (5.13)$$

Kjer so:

- $w$  širina piksla satelitske slike,
- $h$  višina piksla satelitske slike,
- $dx$  pikselska razdalja med vodoravnimi koordinatami napovedane pozicije in dejanske pozicije,

- $dy$  pikselska razdalja med navpičnimi koordinatami napovedane pozicije in dejanske pozicije,
- $k$  je faktor merila, ki je v tem delu postavljen na 10.



# Poglavlje 6

## Eksperimenti

V tem poglavju se bom osredotocil na eksperimente, ki sem jih izvedel.

### 6.1 Izbira kriterijske funkcije

Zanimalo me je kako se bo model obnesel, ko izbiramo razlicne kriterijske funkcije.

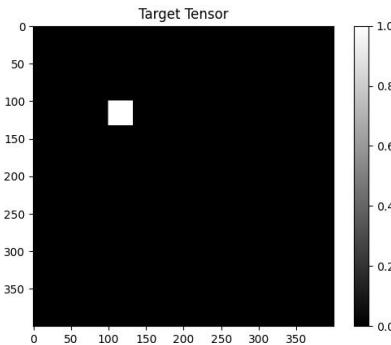
#### 6.1.1 Hanningova kriterijska funkcija

V clanku WAMF-FPI [8] so avtorji predlagali uporabo Hanningove kriterijske funkcije. Prvi pomemben vidik te funkcije izgube je dodelitev uteži vzorcem. Namesto enakega pomena vseh pozitivnih vzorcev, funkcija izgube Hanning dodeli različne uteži glede na lokacijo vzorca.

To je zato, ker je pomembnost središčnega položaja veliko večja kot pomembnost robovih položajev, kar v kontekstu satelitskih slik logično smiselno. Za normalizacijo teh pozitivnih uteži se uporablja Hanningovo okno, za normalizacijo negativnih utezi, pa

$$1/\#\text{negativnih vzorcev}$$

. Uteži so dodeljene tako, da je vsota uteži pozitivnih in negativnih vzorcev enaka 1. Toda ker je število negativnih vzorcev običajno večje od števila po-



Slika 6.1: Primer vzorca, sredisce je tocka lokacije vzorca.

zitivnih vzorcev, postane utež negativnih vzorcev manjša. Da bi to popravili, se uvede hiperparameter , imenovan Negativna utež (NG), ki prilagodi utež negativnih vzorcev.

Hanningova funkcija:

$$\text{Hanning}(n) = \begin{cases} 0.5 + 0.5 \cos\left(\frac{2\pi n}{M-1}\right) & \text{za } 0 \leq n \leq M-1 \\ 0 & \text{sicer} \end{cases} \quad (6.1)$$

Utezi primerov:

- Utez negativnih vzorcev:

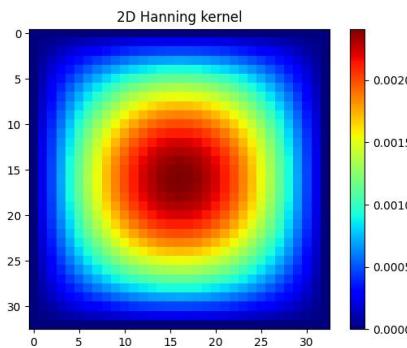
$$w_{pos} = NG/(NN(NW + 1))$$

- Utez pozitivnih vzorcev:

$$w_{neg} = HN(n)/(NW + 1)$$

Kjer je:

- **NG** je Negativna utež
- **NN** je stevilo vseh uzorcev
- **NW** je normalizacijski faktor
- **HN(n)** je vrednost Hanningove funkcije na lokaciji n



Slika 6.2: Hanningovo jedro

### 6.1.2 Gaussova utežena srednja kvadratna napaka

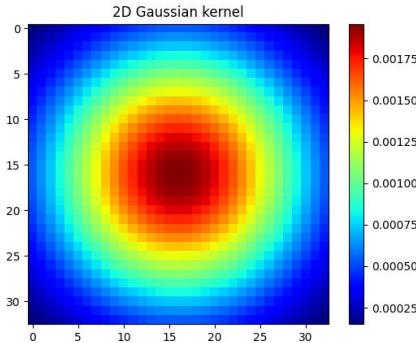
Gaussova utežena srednja kvadratna napaka (Gaussian Weighted Mean Squared Error - GWMSE) je modificirana funkcija izgube, namenjena izboljšanju modelov, ki obravnavajo podatke, kot so satelitske slike. Glavna značilnost GWMSE je dodeljevanje uteži vzorcem, na zelo podoben nacin kot pri Hanningovi funkciji izgube. Namesto enakega pomena vseh pozitivnih vzorcev, GWMSE različnim vzorcem dodeljuje različne uteži glede na njihovo lokacijo. Za normalizacijo teh uteži se uporablja Gaussova funkcija.

Gaussova funkcija:

$$\text{Gauss}(n) = \begin{cases} \exp\left(-\frac{(n-\mu)^2}{2\sigma^2}\right) & \text{za } 0 \leq n \leq M-1 \\ 0 & \text{sicer} \end{cases} \quad (6.2)$$

### 6.1.3 Hanningova utežena srednja kvadratna napaka

Hanningova utežena srednja kvadratna napaka (Hanning Weighted Mean Squared Error - HWMSE) je spremenjena funkcija izgube, namenjena izboljšanju modelov, ki obravnavajo podatke, kot so satelitske slike. Glavna značilnost HWMSE je dodeljevanje uteži vzorcem na zelo podoben način kot pri Gaussovi funkciji izgube. Namesto enakega pomena vseh pozitivnih vzorcev, HWMSE različnim vzorcem dodeljuje različne uteži glede na njihovo



Slika 6.3: Gaussovo jedro

lokacijo. Za normalizacijo teh uteži se uporablja Hanningovo okno.

Hanningova funkcija je podana kot:

$$\text{Hanning}(n) = \begin{cases} 0.5 + 0.5 \cos\left(\frac{2\pi n}{M-1}\right) & \text{za } 0 \leq n \leq M-1 \\ 0 & \text{sicer} \end{cases} \quad (6.3)$$

#### 6.1.4 Križno utežena srednja kvadratna napaka

Funkcija izgube križno utežena srednja kvadratna napaka (Cross-Weighted Mean Squared Error - CW-MSE) je napredna različica standardne srednje kvadratne napake (Mean Squared Error - MSE), ki vključuje uteževanje dveh različnih skupin vzorcev: tistih, katerih resnična vrednost je večja od 0 (t.i. "resničnih" vzorcev) in tistih, katerih resnična vrednost je manjša ali enaka 0 (t.i. "ne-resničnih" vzorcev). Končna funkcija izgube se izračuna kot utežena kombinacija srednjih kvadratnih napak za "resnične" in "ne-resnične" vzorce, pri čemer se uteži vzorcev različnih skupin prekrižajo. Ta pristop se formalno izraža z naslednjo enačbo:

$$\text{loss} = \frac{\text{true\_weight} \cdot N_{\text{true}} \cdot \text{MSE}_{\text{false}} + \text{false\_weight} \cdot N_{\text{false}} \cdot \text{MSE}_{\text{true}}}{N_{\text{all}}} \quad (6.4)$$

- $N_{\text{true}}$ : število vzorcev, katerih resnična vrednost je večja od 0.

- $N_{\text{false}}$ : število vzorcev, katerih resnična vrednost je enaka ali manjša od 0.
- $N_{\text{all}}$ : skupno število vzorcev.
- $\text{MSE}_{\text{true}} = \frac{1}{N_{\text{true}}} \sum_{i=1}^{N_{\text{true}}} (y_i - \hat{y}_i)^2$  za vzorce, katerih resnična vrednost je večja od 0.
- $\text{MSE}_{\text{false}} = \frac{1}{N_{\text{false}}} \sum_{i=1}^{N_{\text{false}}} (y_i - \hat{y}_i)^2$  za vzorce, katerih resnična vrednost je enaka ali manjša od 0.
- `true_weight` in `false_weight`: uteži, dodeljene skupinama *true* in *false*.

Python implementacija funkcije izgube CW-MSE je naslednja:

```

1  class CrossWeightedMSE(nn.Module):
2      def __init__(self, true_weight=1, false_weight=1):
3          super(CrossWeightedMSE, self).__init__()
4          self.mse_loss = nn.MSELoss(reduction="none")
5          self.true_weight = true_weight
6          self.false_weight = false_weight
7
8      def forward(self, input, target):
9          N_all = target.numel()
10         N_true = torch.sum(target > 0.0).item()
11         N_false = N_all - N_true
12
13         true_mask = target > 0.0
14         false_mask = torch.logical_not(true_mask)
15
16         MSE_true = torch.mean(self.mse_loss(input[true_mask], target[
17             true_mask]))
17         MSE_false = torch.mean(self.mse_loss(input[false_mask], target[
18             false_mask]))
18
19         loss = (
20             self.true_weight * N_true * MSE_false
21             + self.false_weight * N_false * MSE_true
22         ) / N_all
23
24         return loss

```

Kriterijska funkcija	vrednost	$RDS_{train}$	$RDS_{val}$
Hanningova kriterijska funkcija	8.49	0.893	0.709
Gaussovo utezena srednja kvadratna napaka	0.001	0.077	0.074
Hanningovo utežena srednja kvadratna napaka	4.04e-06	0.061	0.059
Križno utežena srednja kvadratna napaka	0.007	0.07	0.06

Tabela 6.1: Rezultati ob uporabi razlicnih kriterijskih funkij.

### 6.1.5 Primerjava rezultatov

### 6.1.6 Analiza rezultatov

#### Hanningova kriterijska funkcija

Hanningova kriterijska funkcija, znana tudi po svoji edinstveni značilnosti dodeljevanja uteži vzorcem glede na njihovo lokacijo, je v testiranju pokazala zavidljive rezultate. S skupno vrednostjo 8.49 in  $RDS_{train}$  vrednostjo 0.893 na učni množici se je izkazala kot izredno učinkovita za trening set. Čeprav je bila njena učinkovitost na validacijski množici, kjer je dosegla  $RDS_{val}$  vrednost 0.709, nekoliko nižja, so rezultati še vedno zelo obetavni. Primer je viden na sliki 6.4.

Ključna prednost Hanningove funkcije je v njeni zmožnosti prilagajanja uteži vzorcem glede na njihov položaj, kar se zdi še posebej primerno pri analizi satelitskih slik. V teh slikah je središčni položaj pogosto bistven, medtem ko robovi morda niso tako pomembni. To naravno prilagodljivost Hanningove funkcije lahko opazimo v njenih rezultatih, ki jih dosegla v obravnavanem primeru.

#### Gaussovo utežena srednja kvadratna napaka

Čeprav je Gaussova utežena srednja kvadratna napaka prav tako zasnovana na principu dodeljevanja uteži glede na lokacijo vzorca, rezultati kažejo, da ne dosega enake uspešnosti kot Hanningova funkcija. Z  $RDS_{train}$  vrednostjo 0.077 na učni množici in  $RDS_{val}$  vrednostjo 0.74 na validacijski množici so

njeni rezultati precej slabši v primerjavi s Hanningovo funkcijo. Primer je viden na sliki 6.5.

Čeprav obe funkciji temeljita na podobnem principu, se zdi, da Hanningova funkcija bolje odraža posebnosti in značilnosti satelitskih slik.

### **Hanningovo utežena srednja kvadratna napaka**

Pri tej funkciji se je izkazalo, da mreža ni dosegla želenih rezultatov. Namesto, da bi se mreža naučila prepoznati in interpretirati relevantne značilnosti satelitskih slik, se je večinoma učila šuma. Praktično, model se ni naučil nič koristnega, kar nakazuje, da Hanningovo utežena srednja kvadratna napaka morda ni primerna za to vrsto podatkov ali za uporabljeni model. Primer je viden na sliki 6.6.

### **Križno utežena srednja kvadratna napaka**

Podobno kot pri Hanningovi uteženi srednji kvadratni napaki se je tudi pri Križno uteženi srednji kvadratni napaki pokazalo, da mreža večinoma prepoznavata in se uči šuma. Rezultati so bili nezadovoljivi in kažejo na to, da ta funkcija ni najbolj primerna za analizo satelitskih slik s tem pristopom. Primer je viden na sliki 6.7.

**Zaključek:** Hanningova kriterijska funkcija se je v obravnavanem primeru izkazala kot najbolj učinkovita. Njena edinstvena sposobnost prilaganja uteži glede na lokacijo vzorca se zdi še posebej primerna za obravnavo satelitskih slik, kar je morda razlog za njeno premoč nad ostalimi obravnavanimi funkcijami izgube.

## **6.2 Ucenje s Stratificiranim Vzorčenjem**

### **6.2.1 Stratificirano vzorčenje**

Stratificirano vzorčenje je metoda vzorčenja, pri kateri se celoten nabor podatkov razdeli na ločene podskupine ali strate. Vsak stratum predstavlja

določeno kategorijo ali razred v naboru podatkov. V kontekstu mest bi lahko vsako mesto predstavljalo svoj stratum. Namen stratificiranega vzorčenja je zagotoviti, da je vsak vzorec reprezentativen za celoten nabor podatkov.

Zakaj je stratificirano vzorčenje pomembno?

1. **Ohranjanje Distribucije:** Stratificirano vzorčenje zagotavlja, da se razmerje vzorcev v vsakem stratumu ohranja enako kot v celotnem naboru podatkov. To je še posebej pomembno, ko je distribucija podatkov v vsakem stratumu (v tem primeru mesto) ključnega pomena za analizo. Na primer, če želimo, da je naš vzorec reprezentativen za različna mesta, bi uporabili stratificirano vzorčenje, da zagotovimo, da so vsa mesta ustrezno zastopana.
2. **Natančnost:** Stratificirano vzorčenje lahko poveča natančnost ocen, saj zmanjšuje variabilnost znotraj vsakega strata. To pomeni, da so vzorci iz vsakega strata bolj homogeni, kar lahko vodi do natančnejših rezultatov.

Slabosti stratificiranega vzorčenja:

1. **Omejena Generalizacija:** Čeprav stratificirano vzorčenje zagotavlja, da so vse kategorije ali razredi v naboru podatkov ustrezno zastopani v vzorcu, to lahko pomeni, da model morda ni tako dobro pripravljen na povsem nove, nevidene podatke. Model je lahko optimiziran za specifično distribucijo podatkov, ki je bila uporabljena med ucenjem in validacijo.
2. **”In-Distribution” Validacija** Ker se vzorci za ucenje in validacijo izbirajo iz iste distribucije (stratificirane distribucije), model morda ne bo dobro deloval na ”out-of-distribution” podatkih. To pomeni, da čeprav model morda kaže visoko natančnost na validacijskem naboru, to ne zagotavlja, da bo enako dobro deloval na podatkih, ki se močno razlikujejo od originalne distribucije.

### 6.2.2 Rezultati

Nacin	Hanningova izguba	$RDS_{train}$	$RDS_{val}$
Train test split ucenje	8.49	0.893	0.709
Ucenje s stratificiranim uzorcenjem	3.17	0.750	0.731

Tabela 6.2: Rezultati ob uporabi stratificiranega uzorcenja.

Iz rezultatov 6.2 je razvidno, da je uporaba stratificiranega vzorčenja vplivala na rezultate.

Za boljše razumevanje uspešnosti modelov je ključno upoštevati tudi njihovo zmogljivost na validacijskih naborih podatkov. To je še posebej pomembno, saj nam validacija daje vpogled v to, kako dobro model predvijava rezultate na nevidenih podatkih. Če primerjamo rezultate  $RDS_{val}$  med obema pristopoma, opazimo, da je model, ki je bil naučen s stratificiranim vzorčenjem, dosegel rahlo višjo uspešnost (0.731) v primerjavi z modelom, ki je bil naučen s tradicionalno metodo "train-test split" (0.709). To kaže, da se je model, ki je bil naučen s stratificiranim vzorčenjem, nekoliko bolje spoprijel s generalizacijo na nevidenih podatkih. To dejstvo podkrepiti tudi zmanjšana razlika med uspešnostjo na učni in validacijski množici v primeru stratificiranega vzorčenja. Večja konsistentnost rezultatov med učno in validacijsko množico je lahko pokazatelj, da model ni pretirano prilagojen in se lahko bolje generalizira na nove podatke. Torej, medtem ko je tradicionalna "train-test split" metoda doseгла višjo uspešnost na učni množici, se zdi, da stratificirano vzorčenje ponuja bolj zanesljive in stabilne rezultate na validacijski množici, kar je ključnega pomena za ocenjevanje realne zmogljivosti modela. V našem primeru se zdi, da stratificirano vzorčenje ponuja bolj robusten in stabilen model za obravnavane satelitske slike. Vendar pa je pomembno upoštevati tudi omejitve stratificiranega vzorčenja, kot so omejena generalizacija in potencialne težave pri "out-of-distribution" podatkih.

## 6.3 Vpliv velikosti Hanningovega okna na rezultate

Velikost Hanningovega okna igra ključno vlogo pri določanju uteži vzorcev. Zaradi narave Hanningove kriterijske funkcije velikost okna neposredno vpliva na razporeditev in obliko uteži, dodeljenih vzorcem v satelitskih slikah.

### 6.3.1 Dinamika različnih velikosti Hanningovih oken

Ko je velikost okna majhna, bo okno zajelo ožji del vzorcev, kar lahko povzroči težave s povratnim razširjanjem med učenjem modela. Če je obmocje, ki ga pokriva okno, premajhno, kriterijska funkcija ne more efektivno vplivati na celotno mrežo, kar vodi do potencialno slabše uspešnosti modela. Nasprotno, preveliko okno lahko privede do izgube natančnosti. Čeprav kriterijska funkcija zajema širši del vzorcev, lahko pomembni detajli postanejo zamegljeni, kar vodi do manj natančnih rezultatov.

### 6.3.2 Eksperimentalni rezultati

V naših testiranjih smo ugotovili, da je najbolje najti uravnovezeno velikost Hanningovega okna, ki omogoča modelu, da efektivno uči in hkrati ohranja natančnost pri predikcijah. V ta namen smo izvedli več iteracij, kjer smo eksperimentirali z različnimi velikostmi oken.

TUKAJ SE PRIDEJO GRAFI Z REZULTATI, 27, 29, 31, 33, 35, 37, 39, 41 velikosti hanningovega okna treba malo pocakat se

## 6.4 Regularizacija v modelu z uporabo izpuščanja nevronov

### 6.4.1 Izpuščanje nevronov

V svetu strojnega učenja je regularizacija ključna tehnika, ki se uporablja za preprečevanje prekomernega prilagajanja modela. Prekomerno prilagajanje se pojavi, ko model postane preveč specifičen za učni nabor podatkov, kar pomeni, da se ”preveč nauči” podrobnosti in šuma v učnih podatkih, kar vodi v slabo zmogljivost na novih, nevidenih podatkih. Med različnimi tehnikami regularizacije je ”izpuščanje nevronov” (v angleščini ”dropout”) ena izmed najbolj priljubljenih in učinkovitih metod za nevronske mreže. Koncept izpuščanja nevronov je preprost, a močan: med usposabljanjem se določen odstotek nevronov v mreži naključno ”izklopi” ali izpusti. To pomeni, da se med posameznim prehodom naprej določeni nevroni (in njihove povezave) začasno odstranijo iz mreže.

V modelu sem uporabil izpuščanje nevronov na več ključnih mestih:

1. **Izpuščanje Nevronov v Modelu Twins:** Izpuščanje nevronov je bilo uporabljeno za regulacijo različnih komponent modela, vključno z deli, kot so `attn_drop`, `proj_drop`, `head_drop`, `mlp_drop1`, `mlp_drop2` in `pos_drops..`. Vsaka od teh komponent ima svojo specifično vlogo v arhitekturi modela. Z dodanjem izpuščanja nevronov na te komponente sem dodal dodatno raven regularizacije, ki pomaga preprečiti prekomerno prilagajanje.
2. **Izpuščanje Nevronov v Modulu za Združevanje Značilnosti:** Po vsaki konvolucijski operaciji v fuzijskem delu modela sem dodal izpuščanje nevronov. Konvolucijske plasti lahko hitro postanejo kompleksne in se prekomerno prilagodijo podatkom, zlasti ko delujejo na visokodimenzionalnih značilnostih. Z dodanjem izpuščanja nevronov po vsaki konvolucijski plasti sem zmanjšal to tveganje in povečal robustnost modela.

Izpuščanje nevronov je ena izmed najbolj učinkovitih tehnik regularizacije za nevronske mreže. Z njegovo uporabo v modelu sem zagotovil, da je model bolj robusten in manj nagnjen k prekomernemu prilaganju na učne podatke. V kompleksnih modelih, kot je Twins, kjer je veliko komponent, ki se lahko prekomerno prilagodijo podatkom, je uporaba izpuščanja nevronov ključnega pomena za zagotavljanje natančnih in zanesljivih rezultatov.

## Rezultati

Parameter	UAV	Satelite	Združevanje
dropout	0.1	0.1	0.1
attn_drop	0.1	0.1	-
proj_drop	0.1	0.1	-
head_drop	0.1	0.1	-
mlp_drop1	0.1	0.1	-
mlp_drop2	0.1	0.1	-
pos_drops	0.05	0.05	-

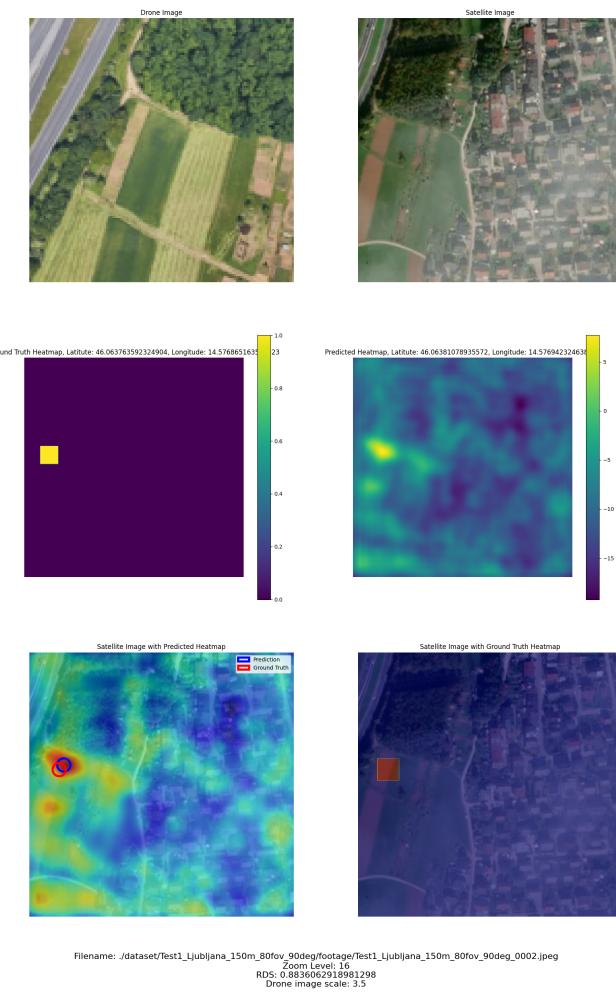
Tabela 6.3: Parametri z uravnovesenim izpustom nevronov.

Parameter	UAV	Satelite	Združevanje
dropout	0.15	0.05	0.05
attn_drop	0.15	0.05	-
proj_drop	0.15	0.05	-
head_drop	0.15	0.05	-
mlp_drop1	0.15	0.05	-
mlp_drop2	0.15	0.05	-
pos_drops	0.1	0.05	-

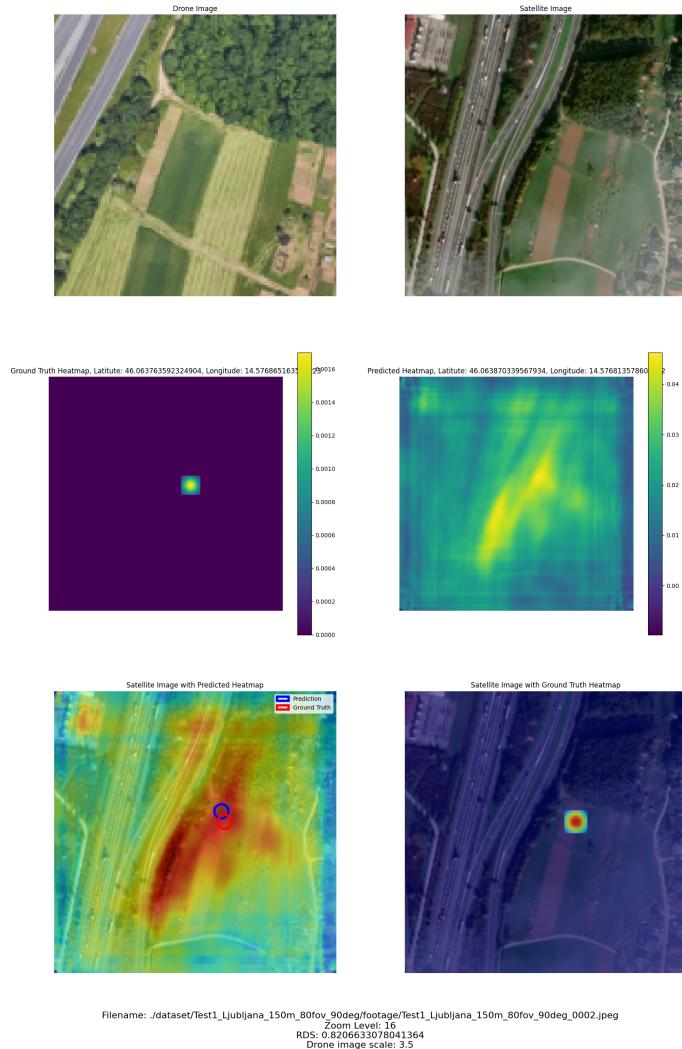
Tabela 6.4: Parametri z neuravnovesenim izpustom nevronov.

Nacin	Hanningova izguba	$RDS_{train}$	$RDS_{val}$
Brez izpuscanja nevronov	8.49	0.893	0.709
Z uravnovesenim izpuscanjem nevronov	5.49	0.725	0.690
Z neuravnovesenim izpuscanjem nevronov	5.42	0.725	0.719

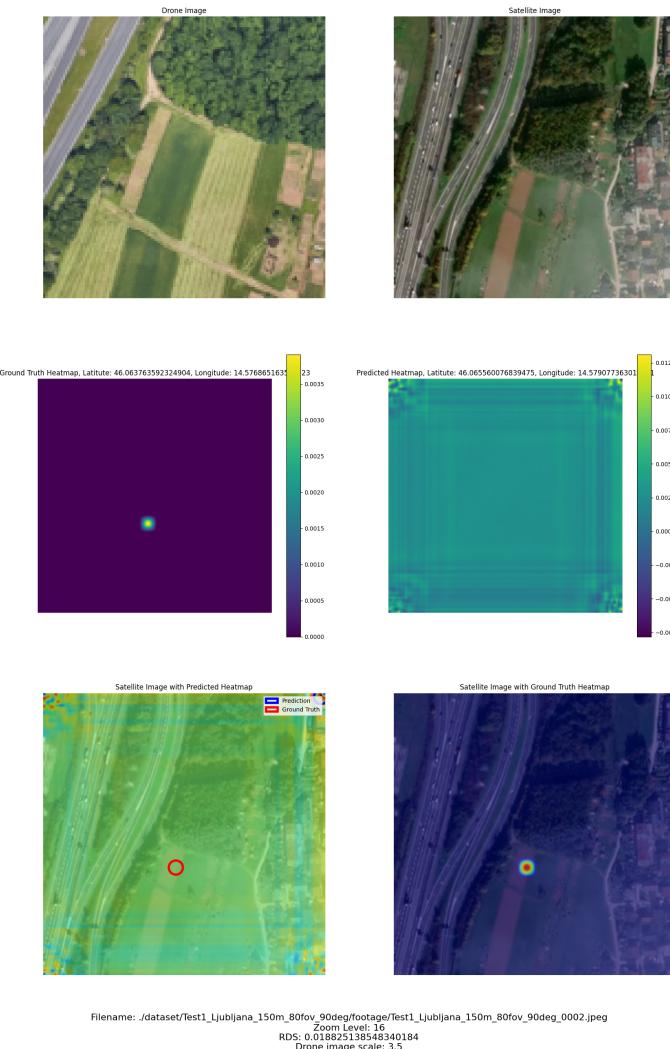
Tabela 6.5: Rezultati ob uporabi razlicnih izpustov.



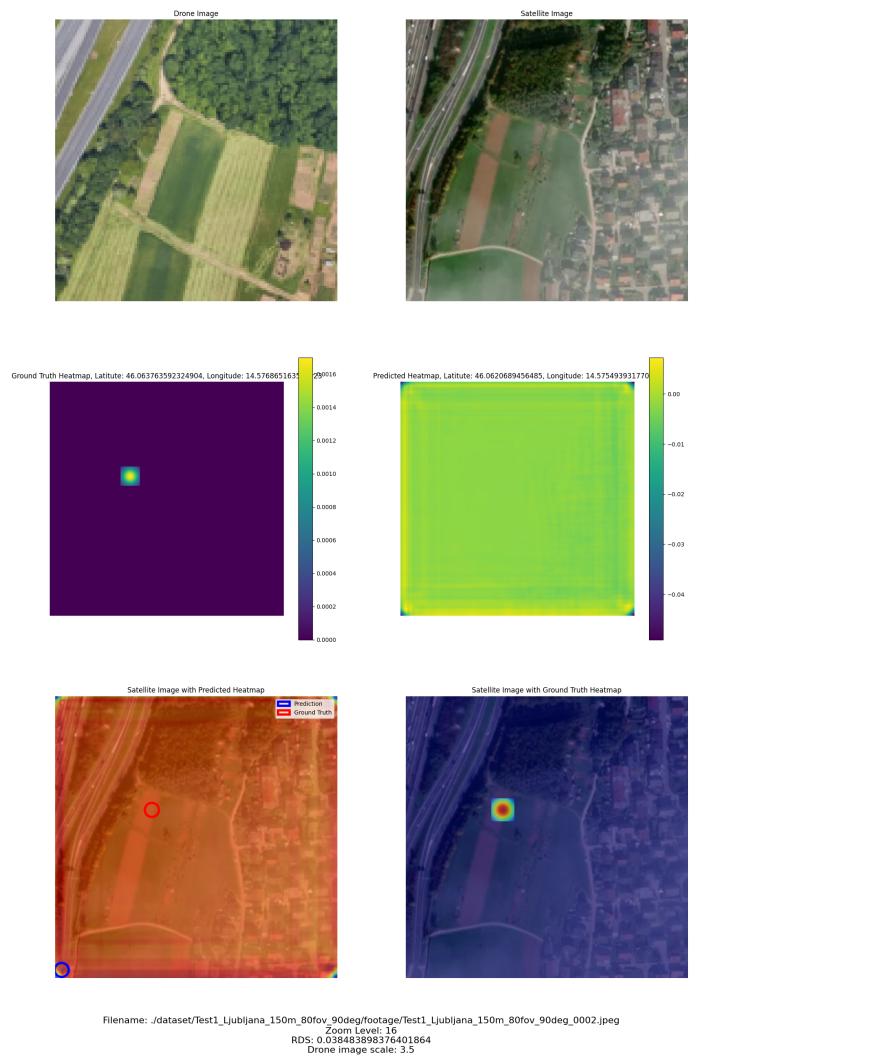
Slika 6.4: Primer izhoda ob uporabi Hanningove kriterijske funkcije



Slika 6.5: Primer izhoda ob uporabi Gaussovo utežene srednje kvadratne napake



Slika 6.6: Primer izhoda ob uporabi Hanningove utežene srednje kvadratne napake



Slika 6.7: Primer izhoda ob uporabi Križno utežene srednje kvadratne napake

# Poglavlje 7

## Sklepne ugotovitve

Uporaba L<sup>A</sup>T<sub>E</sub>Xa in BIBL<sup>A</sup>T<sub>E</sub>Xa je v okviru Diplomskega seminarja **obvezna!** Izbira – L<sup>A</sup>T<sub>E</sub>X ali ne L<sup>A</sup>T<sub>E</sub>X – pri pisanju dejanske diplomske naloge pa je prepuščena dogovoru med diplomantom in njegovim mentorjem.

Res je, da so prvi koraki v L<sup>A</sup>T<sub>E</sub>Xu težavni. Ta dokument naj služi kot začetna opora pri hoji. Pri kakršnihkoli nadaljnjih vprašanjih ali napakah pa svetujemo uporabo Googla, saj je spletnih strani za pomoč pri odpravljanju težav pri uporabi L<sup>A</sup>T<sub>E</sub>Xa ogromno.

Preden diplomo oddate na sistemu STUDIS, še enkrat preverite, če so slovenske besede, ki vsebujejo črke s strešicami, pravilno deljene in da ne segajo preko desnega roba. Poravnavo po vrsticah lahko kontrolirate tako, da izvorno datoteko enkrat testno prevedete z opcijo **draft**, kar vam pokaže predolge vrstice.



# Literatura

- [1] Dzmitry Bahdanau, Kyunghyun Cho in Yoshua Bengio. “Neural Machine Translation by Jointly Learning to Align and Translate”. V: *arXiv preprint arXiv:1409.0473* (2015).
- [2] Xiangxiang Chu in sod. “Conditional positional encodings for vision transformers”. V: *arXiv preprint arXiv:2102.10882* (2021).
- [3] Xiangxiang Chu in sod. “Twins: Revisiting the design of spatial attention in vision transformers”. V: *Advances in Neural Information Processing Systems* 34 (2021), str. 9355–9366.
- [4] Ming Dai in sod. “Finding Point with Image: An End-to-End Benchmark for Vision-based UAV Localization”. V: *arXiv preprint arXiv:2208.06561* (2022).
- [5] Alexey Dosovitskiy in sod. “An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale”. V: *arXiv preprint arXiv:2010.11929* (2020).
- [6] Ze Liu in sod. “Swin transformer: Hierarchical vision transformer using shifted windows”. V: *Proceedings of the IEEE/CVF international conference on computer vision*. 2021, str. 10012–10022.
- [7] Ashish Vaswani in sod. “Attention is all you need”. V: *Advances in neural information processing systems* 30 (2017).
- [8] Guirong Wang in sod. “WAMF-FPI: A Weight-Adaptive Multi-Feature Fusion Network for UAV Localization”. V: *Remote Sensing* 15.4 (2023), str. 910.

- [9] Wenhui Wang in sod. “Pyramid Vision Transformer: A Versatile Backbone for Dense Prediction without Convolutions”. V: *arXiv preprint arXiv:2102.12122* (2021).