Zahvaljujem mentoru prof. dr. sc. Siniši Šegviću na savjetima i ukazanoj pomoći. Zahvaljujem kolegi Antoniu Ilinoviću na diskusijama i pomoći tijekom izrade rada. Također, zahvaljujem svojoj obitelji, prijateljima i kolegama na potpori tijekom mojeg dosadašnjeg obrazovanja.

SADRŽAJ

1. Uvod

Računalni vid kao jedna od temeljnih grana umjetne inteligencije omogućava računalima da izluče korisnu informaciju iz slika, videa ili sličnih vizualnih ulaza. Područje stereoskopske rekonstrukcije ima za cilj procijeniti trodimenzionalan položaj točaka koje su promatrane u dvije ili više slika, te kao takvo ima vrlo široke primjene uključujući autonomnu navigaciju, računalno modeliranje i virtualnu stvarnost. Kroz povijest postojali su klasični korespondencijski pristupi koji se temelje na udaljenostima u prostoru piksela odnosno ručno oblikovanim značajkama. Pojavom snažnijih računala primijenjeno je duboko učenje kojim je moguće korespondencijske metrike naučiti na stvarnim podacima. Za potrebe metoda utemeljene na nadziranom učenju potrebne su rektificirane stereoskopske slike s poznatom dubinskom informacijom.

U okviru ovog radu opisana je geometrija stereoskopskog para, kalibracija, rektifikacija i strojno naučeni modeli za ostvarivanje korespondencije. Zatim definirani su osnovni pojmovi i postupci korišteni u dubokom učenju. Predstavljen je podatkovni skup na kojem su izvršeni postupci treniranja i validacije. Opisan je model kojim je ostvareno korespondencijsko ugrađivanje slikovnih okana koji su korišteni u stereoskopskoj rekonstrukciji. Nadalje, opisan je postupak učenja takvog modela te eksperimentalno vrednovanje rekonstrukcijske točnosti.

2. Stereoskopska rekonstrukcija

2.1. Epipolarna geometrija

Epipolarna geometrija opisuje odnos točaka u slikama dobivenih iz dviju kamera. Važan ishod epipolarne geometrije jest epipolarno ograničenje koje uvelike smanjuje broj točaka koje je potrebno provjeriti pri traženju korespondentnih točaka. Slika 2.1 prikazuje točku X u 3D prostoru koja se snima iz dviju kamera. Točke C i C' prikazuju središta lijeve odnosno desne kamere. Projekcija točke X na ravninu lijeve kamere je x, a na ravninu desne kamere x'. Važno je napomenuti da su točke X, x i x' u istoj ravnini te zajedno sa centrima kamera C i C' čine tzv. *epipolarnu ravninu* π.

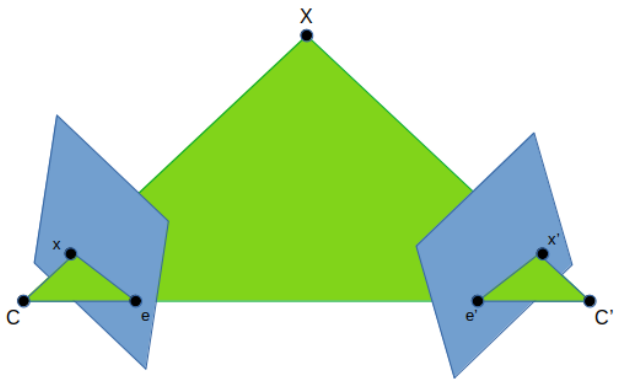

Slika 2.1: Epipolarnu ravninu definiraju promatrana točka X te središta dvaju kamera C i C'.

Nadalje, na slici su označeni *epipolovi* oznakama e i e' te oni prikazuju točke u kojima pravac koji povezuje centre kamera C i C' siječe slikovne ravnine.*Epipolarni pravci* spajaju x i e, te x' i e'. Ti pravci nastaju presjekom epipolarne ravnine sa slikovnom ravninom. Epipol je točka u kojoj se sijeku svi epipolarni pravci.
Poznavajući činjenicu da se točke X, C i C' nalaze u istoj ravnini te ako znamo položaj točke x, e i e' možemo procijeniti položaj točke x'. Vidimo da mogući položaji točke x'

nalaze se na epipolarnoj liniji. Tako definirano epipolarno ograničenje uvelike olakšava pronalaženje korespondentnih točaka.

2.2. Pretprocesiranje slika

Parametre geometrije sustava kamera moguće je podijeliti na dvije vrste: intrinsični i ekstrinsični. Ekstrinsični parametri opisuju odnos para stereo kamera. Intrinsični pak opisuju svojstva kamera koje se odnose na svaku kameru zasebno. Primjerice intrinsični parametri opisuju nesavršenost leća (na slici 2.2 prikazano je radijalno izobličenje), pomak senzora od centra leća te slične fizičke karakteristike kamera.

Slika 2.2: Primjeri radijalnog izobličenja. Izvor:[2]

S druge strane ekstrinsični nas parametri dovode do nužnih transformacija kojima se slike dovode u istu ravninu projekcije te se time postiže da pikseli horizontalnog pravca jedne slike imaju korespondencije na istom pravcu u drugoj slici. Taj pravac već je spomenut. Riječ je o epipolarnom pravcu. Ovakvim transformacijama uvelike se olakšava pronalaženje korespondentnih točaka koje u rektificiranom slučaju treba tražiti samo duž jedne linije uzduž epipolarnog pravca. Problem je sveden na jednu dimenziju. Intrinsične i ekstrinsične parametre dobivamo prikladnim kalibracijskim postupcima.

2.2.1. Rektifikacija i kalibracija

Za postupak rektifikacije važni su ekstrinsični parametri kamera dok na njihov izračun utječu intrinsični faktori. Transformacijom slika rektifikacijom dobivamo slike čiji

pikseli u prostoru odgovaraju točkama na istoj visini, a nalaze se duž iste epipolarne linije.

Slika 2.3: Prikaz epipolarnih linija u rektificiranim slikama skupa KITTI 2015.

Postupak kalibracije se provodi kroz nekoliko koraka, a uključuje šahovsku ploču koja je pogodna zbog svojih svojstava. Prvi je korak traženje šahovskih polja. Postupak se nastavlja određivanjem izobličenja i ostalih parametara uz pomoć šahovskih polja.
Slika 2.2 prikazuje par slika iz stereo kamera koji je rektificiran. Slike su iz skupa KITTI 2015 te se na njima vide epipolarne linije. Lako je primijetiti da iste točke u prostoru nalaze na istoj visini, odnosno na istoj epipolarnoj liniji. Ovakvom transformacijom korespondentne piksele potrebno je tražiti samo na istoj y-koordinati.

2.3. Disparitet

Prijašnjim postupcima kalibracije i rektifikacije omogućen je postupak računanja dispariteta, odnosno postupak računanja koji za svaki piksel koji je nastao lijevom kamerom određuje piksel slike koja je nastala desnom kamerom, ali pomaknutog za udaljenost d piksela po horizontalnoj osi. *Disparitet* je definiran kao horizontalni pomak d između dvaju korespondentnih piksela u slikama nastalim iz dviju konkurentnih stereo kamera. Kao rezultat računanja dispariteta nastaje mapa dispariteta koja sadrži disparitet za svaki piksel referentne kamere. Odnos piksela slike iz lijeve kamere, koja je u ovom slučaju referentna, i slike iz desne kamere definira se kao:

$$I_L(x, y) = I_D(x - d, y) \tag{2.1}$$

gdje su I_L i I_D slike nastale lijevom odnosno desnom kamerom, respektivno. Uređenim parom (x, y) opisani su pikseli slike iz lijeve kamere, a njemu korespodentni pikseli u slikama iz desne kamere označeni su pomakom za disparitet d po horizontalnoj osi $(x - d, y)$. Važno je napomenuti da su slike u skupu KITTI 2015 rektificirane i kalibrirane što znači da korespodentne piksele tražimo samo po horizontalnoj osi. Pomoću izračunatog dispariteta moguće je izraziti odnos između piksela kamera i

dubine scene kao:

$$Z = f\frac{B}{d} \tag{2.2}$$

gdje je dubina scene, odnosno udaljenost objekta od kamere označena sa Z, d je disparitet,s B je označena udaljenost između središta kamera, a s f je označena fokalna udaljenost kamere. Iz jednadžbe 2.2 vidljiva je obrnuta proporcionalnost između udaljenosti objekta od kamera, te dispariteta s druge strane. Kada je položaj objekta blizu kamere, disparitet će biti velik. A kako se udaljavamo od kamere, disparitet se smanjuje i u beskonačnosti postiže vrijednost 0.

Na slici 2.4 je vidljivo da su epipolarne linije paralelne te im je y-koordinata za korespondentne piksele jednaka. Disparitet je označen slovom d i prikazuje horizontalni pomak.

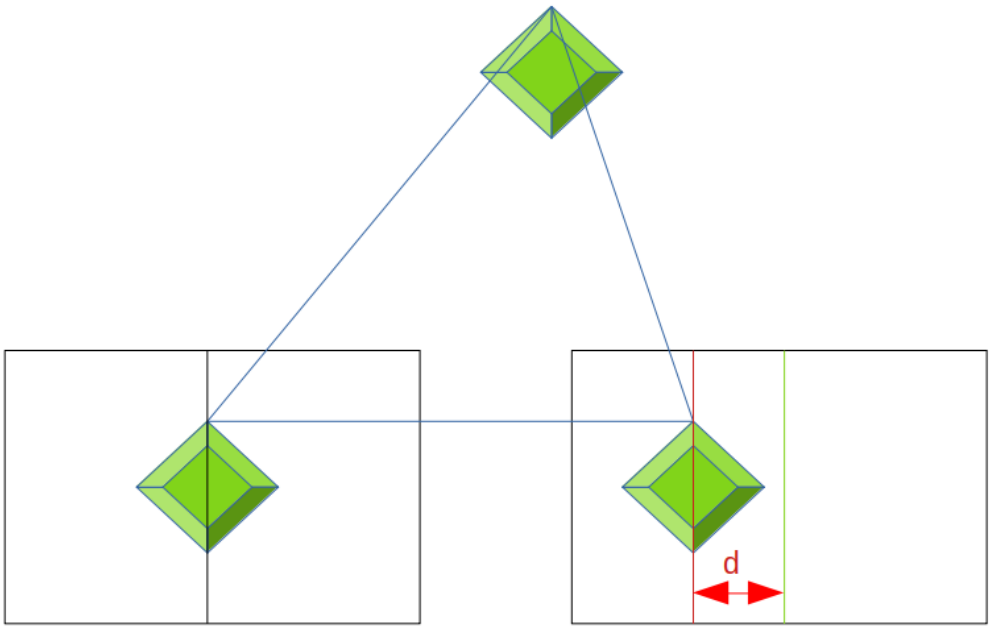

Slika 2.4: Prikaz objekta u slikama iz lijeve i desne kamere. Plavom bojom označena je epipolarna ravnina. Okomitim osima označene su projicirane točke u lijevoj, odnosno desnoj slici. Crvenom bojom je označena prava projekcija koristeći epipolarnu ravninu, dok je zelenom bojom označena preslika lijeve projekcije. Disparitet je označen slovom d.

2.4. Algoritam stereoskopske rekonstrukcije

Postupak stereoskopske korespondencije je zapravo postupak pronalaženja istih piksela u međusobno konkurentnim slikama koji odgovaraju istoj točki u trodimenzionalnom prostoru. Postoje dvije vrste korespondencija, *rijetke* i *guste*. Razlika je u tome što rijetke ne izračunavaju disparitete za sve piksele, dok guste to rade. Područja primjene se razlikuju. Rijetke korespondencije koristimo za procjenu gibanja kamere. Guste korespondencije koristimo za rekonstrukciju strukture scene. Postupak guste korespondencije je tim teži što se prilikom izračuna susreće s nekim anomalijama u slikama, primjerice područjima bez teksture, refleksivnim podlogama na kojima se svjetlost drugačije lomi i odbija te točkama koje se iz jedne kamere vide, a iz druge ne (*stereoskopska sjena*).
Dolazimo do algoritama za stereoskopsku rekonstrukciju. Takvi algoritmi generalno se provode (ili podskupom) u sljedeća četiri koraka ([3], [9]):

1. izračunavanje razlike između dvaju slikovnih okana, odnosno izračun podatkovnih cijena po prije definiranoj mjeri razlike
2. prikupljanje podatkovnih cijena za disparitete koji se razmatraju
3. izračun mape dispariteta, odnosno odabir najmanje prikupljene cijene za svaki piksel uz optimizaciju
4. zaglađivanje mape dispariteta

Prvi je korak ovog generičkog algoritma za stereoskopsku rekonstrukciju izračun podatkovnih cijena. Izračun podatkovnih cijena klasični algoritmi rade nad pojedinačnim pikselima dok moderni algoritmi spajaju prva dva koraka. Izračun nam govori kolika je razlika između dvaju slikovnim okana, a razlika koja se koristi je definirana prije. Mjere razlike mogu biti sljedeće:

- srednja kvadratna razlika
- srednja apsolutna razlika
- kvadratna razlika između intenziteta piksela
- apsolutna razlika između intenziteta piksela

U klasičnim algoritmima rezultat prvog koraka je volumen cijene na razini piksela $C_0(x, y, d)$ dok je rezultat drugog koraka volumen cijene na razini okana $C(x, y, d)$. Drugi korak generičkog algoritma je prikupljanje podatkovnih cijena, tj. agregacija. Na početku je postavljena granica za maksimalan disparitet pa se tijekom ovog koraka izračunava podatkovna cijena za sve disparitete i skupa od 0 do D te ćemo tako za svaki piksel imati $D + 1$ podatkovnih cijena.

Treći korak algoritma je korak optimizacije čiji izlaz je mapa dispariteta. Nakon što su izračunate podatkovne cijene za razmatran skup dispariteta, treba odabrati metodu za izračun mape dispariteta. U praksi postoje *lokalne* i *globalne*. Lokalne metode govore da je korespondencija na području s najmanjim disparitetom. Područje može biti 2D ili 3D te se prikupljanje može primjerice izvesti konvolucijom. S druge strane, globalne metode u većini slučajeva preskaču korak prikupljanja podatkovnih cijena te odmah nakon izračuna podatkovnih cijena vrše optimizaciju. Globalne metode minimiziraju kriterij pronalaženja korespondentih piksela nad cijelom slikom. Odnos između ovih metoda može se svesti na to da su lokalne brže, no globalne daju puno glađe mape dispariteta što ih čini kvalitetnijima.

Zadnji korak koji je naveden je zaglađivanje mapa dispariteta. Ovaj je korak opcionalan i neke metode ga koriste. Glavni je cilj ovog koraka uklanjanje šuma koji je mogao nastati generiranjem mape.

3. Duboko učenje

Duboko učenje jest grana strojnog učenja koja se ubrzano razvija. Duboki modeli sastoje se od 3 ili više skrivena sloja, a sve što je manje od toga naziva se *plitkim* modelima. Cilj takvih neuronskih mreža je isporučiti gigantski kapacitet koji može profitirati od velikih skupova podataka. Zahvaljujući razvoju grafičkih kartica omogućen je ubrzan razvoj dubokog učenja. Moderne grafičke kartice mogu isporučiti računsku snagu za obavljanje desetaka milijardi množenja u sekundi.

U sljedećim će odjeljcima biti predstavljeni osnovni pojmovi i koncepti korišteni prilikom oblikovanja modela i procesa učenja.

3.1. Osnovni pojmovi u dubokom učenju

3.1.1. Perceptron

U ranim počecima dubokog učenja došlo se do ideje potpuno povezanih modela. Jedan je od takvih modela višeslojni perceptron. Iako su danas potpuno povezani modeli u manjoj upotrebi, zanimljivo je pogledati koje mane novi modeli imaju za ispraviti.

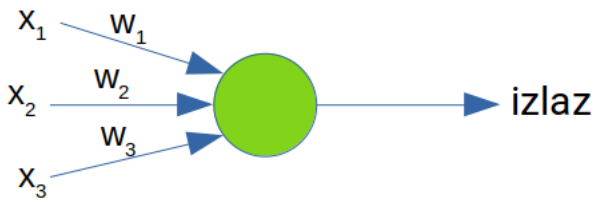

Slika 3.1: Jednostavni TLU perceptron koji ima 3 binarna ulaza i proizvodi 1 binaran izlaz. Težinama w_1, w_2 i w_3 su definirani doprinosi jednog neurona na drugi. Izlaz neurona definiran je umnoškom težina i binarnih ulaza te praga kojim se uspoređuje.

TLU (*Threshold Logic Unit*) perceptron prvi su definirali McCulloch i Pitts. Na slici 3.1 prikazan je jednostavni TLU perceptron. TLU perceptron ima više binarnih ulaza koji su označeni s x_1, x_2 i x_3 te proizvodi binarni izlaz. Rosenblatt je, kako bi odredio izlaz, definirao težine (u ovom slučaju w_1, w_2 i w_3). Težinama se mogu opisati doprinosi jednog neurona na drugi, odnosno koliko jedan utječe na drugog. Ovime je izlaz neurona definiran sumom umnoška težina i binarnih ulaza te praga s kojim s uspoređuje:

$$\begin{cases} 0, \sum_{k=1}^{n} w_k x_k \leq prag & \text{(3.1a)} \\ 1, \sum_{k=1}^{n} w_k x_k > prag & \text{(3.1b)} \end{cases}$$

Jedan sloj dubokog modela čine perceptroni koji se nalaze u jedan ispod drugog. Izlaz svakog perceptrona izračunava se tako koristeći izlaze prethodnog sloja i definirane težine za svaki od ulaznih perceptrona. Gornju formulu moguće je transformirati tako što se prag uvede nova varijabla $b = -prag$ koja označava pristranost (engl. *bias*). Pristranost definira koliko je lako natjerati neuron da kao izlaz izbaci 1. Ukoliko je pristranost vrlo velik broj, izlaz će u većini slučajeva biti 1 dok je za vrlo negativan broj suprotna situacija. Izmijenjena jednadžba glasi:

$$\begin{cases} 0, \sum_{k=1}^{n} w_k x_k + b \leq 0 & \text{(3.2a)} \\ 1, \sum_{k=1}^{n} w_k x_k + b > 0 & \text{(3.2b)} \end{cases}$$

Linearnu funkciju koju smo izveli možemo predstaviti i u matričnom obliku:

$$f = step(w^T x + b) \tag{3.3}$$

gdje *step* označava nelineranu funkciju koja kao izlaz u slučaju pozitivnog ulaza vraća 1, a u slučaju negativnog ulaza vraća 0.

3.1.2. Prijenosne funkcije

Primarni cilj prijenosnih funkcija je omogućiti da se primijete sitne promjene na ulazu. Prijenosne odlučuju hoće li neki izlaz biti aktivan ili ne. Aktivaciju neurona možemo predstaviti sljedećom formulom:

$$a^k = \sigma_k(W_k^T a^{k-1} + b) \tag{3.4}$$

gdje a^k označava aktivaciju neurona trenutnog sloja, a^{k-1} aktivaciju neurona prijašnjeg sloja, a σ označava aktivacijsku funkciju.

Prva funkcija koja će biti objašnjena je sigmoidalna funkcija čiji je izraz dan u nastavku:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \tag{3.5}$$

Glavno je obilježje sigmoidalne funkcije to što je njezina kodomena na skupu od 0 do 1 te ju to čini primjenjivom u regresijskim i klasifikacijskim problemima. Veliki pozitivni brojevi poprimit će vrijednost 1 dok će jako negativni brojevi poprimiti vrijednost 0. Također, prednost je što je derivabilna pa omogućuje učenje u kojem se koristi gradijentni spust. Glavni je nedostatak zbog kojeg se sve manje koristi za aktiviranje latentnih reprezentacija jest problem nestajanja gradijenata (engl. *vanishing gradient problem*). Problem govori da gradijenti postaju toliko mali da ne nose nikakvu informaciju koja bi se mogla iskoristiti za učenje. Uzrok malih gradijenata je konstantno smanjenje istih tijekom puno iteracija. Prikaz grafa funkcije je na slici 3.2.

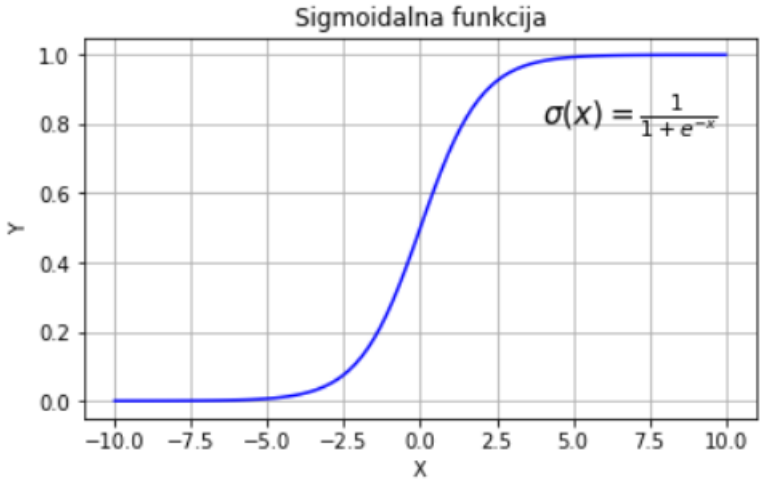

Slika 3.2: Graf sigmoidalne funkcije

Funkcija koja je usko vezana uz sigmoidalnu je *tangens hiperbolni*. Kodomena ove funkcije na intervalu je od -1 do 1. Problem nestajanja gradijenata isto je tako prisutan. Kako je bliska sigmoidalnoj, možemo uspostaviti odnos između njih koji je oblika:

$$\tanh(x) = 2\sigma(2x) - 1 \tag{3.6}$$

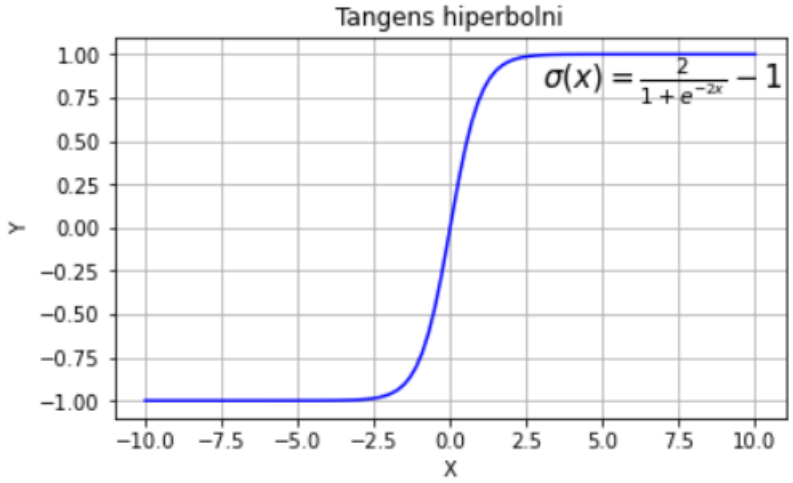

Slika 3.3: Graf funkcije tangensa hiperbolnog

Sljedeća prijenosna funkcija koja se koristi je zglobnica (engl. *ReLU - rectified linear unit*). Ova prijenosna funkcija propušta pozitivne vrijednosti dok negativne vrijednosti ne propušta. Glavna je prednost ove funkcije što ne guši gradijente dok joj je nedostatak što za negativne vrijednosti uvijek daje 0 (nemamo mogućnost finog podešavanja parametara mreže). Izraz koji ju opisuje je oblika:

$$f(x) = max(0, x) \tag{3.7}$$

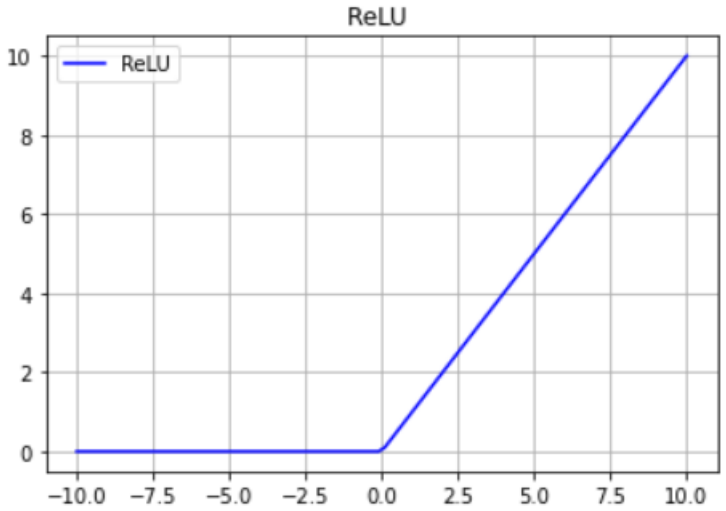

Slika 3.4: Graf funkcije ReLU

Moguće je napraviti modifikaciju zglobnice tako da za negativne vrijednosti daje vrlo male vrijednosti te se takva prijenosna funkcija naziva propusnom zglobnicom (engl. *LReLU - leaky rectified linear unit*). U nastavku slijedi izraz koji ju opisuje:

$$f(x) = \begin{cases} x, x > 0 & \text{(3.8a)} \\ \alpha x, x \leq 0 & \text{(3.8b)} \end{cases}$$

α je parametar, odnosno u praksi vrlo mali pozitivan broj. Na slici 3.5. je vidljivo da negativne vrijednosti propušta uz prigušenje dok na slici 3.4. obična zglobnica ne propušta.

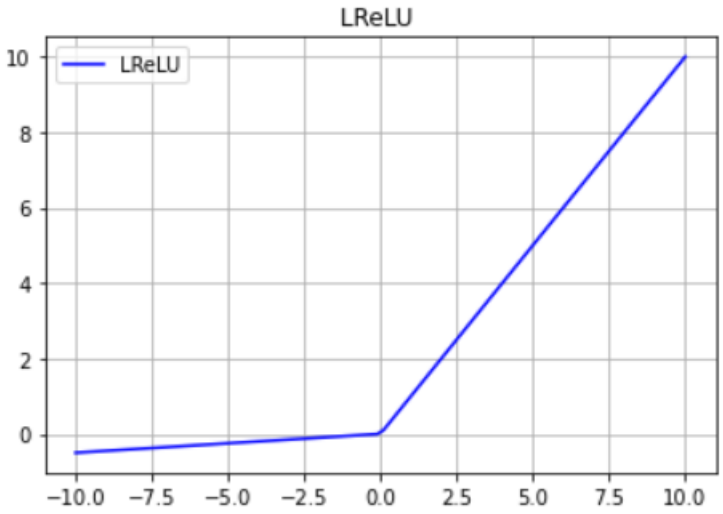

Slika 3.5: Graf funkcije LReLU

3.1.3. Konvolucijski slojevi

Konvolucijski slojevi osnovni su gradivni element konvolucijskih dubokih modela. Kako je u radu riječ o slikama, bit će predstavljena $2D$ konvolucija, operacija filtriranja. Uloga filtriranja je uočavanje i učenje uzoraka koji se nalaze na slikama. Konvolucijski slojevi čine konvolucije ulaza s različitim filtrima, drugi naziv je jezgra (engl. *kernel*). Izlaz iz 2D konvolucije je aktivacijska mapa, odnosno mapa značajki, dok je izlaz cijelog konvolucijskog sloja više mapa značajki. Kako dubina tijekom prolaska kroz mrežu raste, identificiraju se sve specifičniji uzorci. Tijekom unaprijednog prolaza, jezgra se provlači po matričnoj reprezentaciji slike i računa se skalarni umnožak između jezgre i ulaza na svakom položaju.

$$\begin{bmatrix} x_{11} & x_{12} & x_{13} \\ x_{21} & x_{22} & x_{23} \\ x_{31} & x_{32} & x_{33} \end{bmatrix} * \begin{bmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \end{bmatrix} = \begin{bmatrix} x_{11}w_{11} + x_{12}w_{12} & x_{12}w_{11} + x_{13}w_{12} \\ +x_{21}w_{21} + x_{22}w_{22} & +x_{22}w_{21} + x_{23}w_{22} \\ \\ x_{21}w_{11} + x_{22}w_{12} & x_{22}w_{11} + x_{23}w_{12} \\ +x_{31}w_{21} + x_{32}w_{22} & +x_{32}w_{21} + x_{33}w_{22} \end{bmatrix} \tag{3.9}$$

Jednadžbom 3.9 prikazana je konvolucija ulaza dimenzije $3x3$ primjenom jezgre dimenzija $2x2$. Jezgra se provlači po ulaznoj matrici (računa se skalarni umnožak) i nastaje izlazna mapa značajki dimenzija $2x2$. Iz ovog je vidljivo da se konvolucijom smanjuje dimenzija ulaza.

Ukoliko želimo zadržati rezoluciju slike nakon konvolucijskog sloja, potrebno je uvesti nadopunjavanje (engl. *padding*). Najčešće je korištena metoda popunjavanja nulama. Još jedan od hiperparametara je korak (engl. *stride*). Korak govori o tome koliko se jezgra pomiče u vertikalnom i horizontalnom smjeru. U jednadžbi 3.9 je korišten korak 1.

3.2. Učenje dubokih modela

Učenje dubokih modela, u generalnom slučaju neuronske mreže, je postupak tijekom kojeg se modelu na ulaz daju podaci iz skupa za učenje. Tijekom procesa učenja model ažurira težine u slojevima s ciljem kako bi što bolje aproksimirao izlaznu funkciju. Za početak bismo uveli algoritam strojnog učenja kao trojke (model, gubitak, optimizacijski postupak). Sastavni dio takvog algoritma je funkcija gubitka kojom procijenjujemo koliko odstupamo od pravih vrijednosti. U procesu učenja provodi se minimizacija funkcije gubitka. Ukoliko na skupu podataka gubitak ispada malen, a na skupu podataka koje još nije vidio ispada izražen, govorimo o tzv. prenaučenosti modela, što znači da model nema sposobnost generalizacije. Druga krajnost je podučenost. Ona govori da model loše radi na znanim i neznanim podacima, odnosno da uopće ne uči te posljedično loše generalizira.

Postoji nekoliko pristupa učenju, nadzirano učenje u kojem se modelu predaju parovi oblika (ulaz, željeni izlaz), nenadzirano u kojem se modelu samo predaju ulazni podaci, te podržano učenje u kojem se maksimizira kumulativna nagrada. U ovom radu bit će razmatrano nadzirano učenje.

3.2.1. Funkcija gubitka

Kako bismo procijenili koliko model odstupa od željenih vrijednosti izlaza koristimo funkciju gubitka. Ako model loše procjenjuje, gubitak će biti velik. Kod problema klasifikacije najčešće je korištena unakrsna entropija (engl. *cross-entropy loss*):

$$L_{CE} = -\sum_{i=1}^{n} t_i \cdot log(p_i) \tag{3.10}$$

t_i označava ciljnu vrijednost, a p_i izračunatu vrijednost izlaza. Operacija koja koristi unakrsnu entropiju, a daje vjerojatnosnu reprezentaciju izlaza modela je funkcija *softmax*:

$$f_j(z) = \frac{e^{z_j}}{\sum_k e^{z_k}} \tag{3.11}$$

U okviru rada koristi se specifična funkcija gubitka koja je opisana u kasnijem odjeljku.

3.2.2. Gradijentni spust

U prijašnjem pododjeljku definirana je funkcija gubitka, cilj učenja modela je minimizirati gubitak. Kako bi se parametri pomicali u smjeru minimuma funkcije gubitka izračunava se gradijent funkcije gubitka.
Neka je zadana funkcija gubitka koja ovisi o težinama **W** i pomacima **b**. Gradijenti funkcije gubitka mogu se zapisati kao:

$$\nabla L_w = \left(\frac{\partial L}{\partial w_1}, ..., \frac{\partial L}{\partial w_n} \right) \tag{3.12}$$

$$\nabla L_b = \left(\frac{\partial L}{\partial b_1}, ..., \frac{\partial L}{\partial b_n} \right) \tag{3.13}$$

n predstavlja broj parametara.
U iteracijama gradijentnog spusta parametri se ažuriraju prema sljedećim izrazima:

$$W_{i+1} = W_i - \epsilon \cdot \nabla L_w(\mathbf{W}, \mathbf{b}) \tag{3.14}$$

$$b_{i+1} = b_i - \epsilon \cdot \nabla L_b(\mathbf{W}, \mathbf{b}) \tag{3.15}$$

ϵ je tzv. stopa učenja (engl. *learning rate*), a predstavljena je malim pozitivnim realnim brojem.[4]

3.2.3. Optimizacija

Kad govorimo o optimizaciji, najkorištenija metoda je svakako gradijentni spust. Ukoliko se koristi gradijentni spust treba biti svjestan određenih problema koji se mogu javiti. Neki od problema su postojanje više lokalnih minimuma i spora konvergencija. U ovom radu je korišten ADAM optimizator, a svakako potrebno je spomenuti i stohastički gradijentni spust (SGD) optimizator.

Glavna ideja optimizatora SGD je procijeniti gradijent cijelog skupa uzoraka sa malim slučajno odabranim podskupom uzoraka (mini-grupa, engl. *minibatch*). Već i veličine od 128 daju vrlo dobru aproksimaciju gradijenta. U usporedbi s "običnim" gradijentnim spustom (GD) to znatno ubrzava proces učenja, jer se kod GD izračun treba provesti za cijeli skup. Stohastički gradijentni spust često se kombinira sa zaletom koji ubrzava učenje. Umjesto ažuriranja težina koristeći samo trenutno izračunat gradijent, zalet također uzima u obzir i prethodno ažuriranje, pomnoženo s faktorom umanjivanja α. [6]
Modifikacija u odnosu na GD je vidljiva sljedećom jednadžbom:

$$v = \alpha v + \nabla L_w \tag{3.16}$$

v je trenutno akumuliran zalet, a α je zalet.

Adaptive Moment Estimation (ADAM) je optimizator koji kombinacijom zaleta ubrzava pronalazak globalnog minimuma. Glavna značajka ADAM-a je što koristi prosječno eksponencijalno kretanje gradijenta i kvadratnog gradijenta, te ga to čini izrazito efikasnim na velikim skupovima podataka i u radu s velikim brojem parametara [1].

3.2.4. Regularizacija

Kako bi se izbjegla prenaučenost modela (engl. overfitting), odnosno loša generalizacija modela potrebno je uvesti regularizatore koji imaju za cilj spriječiti prenaučenost. Tehnike regularizacije u strojnom učenju povećavaju pristranosti i smanjuju varijancu modela.
Jedna od metoda koje se koriste je dodavanje regularizacijskog člana funkciji gubitka. Pri tome treba spomenuti $L1$ i $L2$ regularizaciju, kojima se kažnjava norma vektora težina:

$$L_R = L + \lambda \cdot \sum_i |w_i| \tag{3.17}$$

$$L_R = L + \lambda \cdot \sum_i w_i^2 \tag{3.18}$$

Izrazom (3.17) opisana je $L1$ regularizacija, a (3.18) $L2$ regularizacija.

Regularizacijska metoda koja istovremeno povećava učinkovitost modela je normalizacija grupe (engl *batch norm*). Normalizacija grupe primjenjuje se prije nelinearnosti, a cilj joj je svesti izlaz na normalnu jediničnu razdiobu. Takav pristup postiže da sve komponente ulaza u slojeve imaju sličnu razdiobu, čime se postiže ubrzanje učenja. U postupku normalizacije po grupi, za svaku izlaznu mapu značajki računaju se srednja vrijednost i varijanca po sljedećim izrazima:

$$\mu_B = \frac{1}{m} \sum_{i=1}^{m} \mathbf{x}_i \tag{3.19}$$

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^{m} (\mathbf{x}_i - \mu_B) \tag{3.20}$$

gdje B označava mini grupu, a x vrijednost ulaza. Nelinearnost se onda primjenjuje na tako normaliziranom izlazu.

4. Podatkovni skup za učenje

Kako je već rečeno, u ovom radu učenje je nadzirano. Podatkovni skup KITTI jedan je od skupova koji se koriste u učenju postupka stereoskopske rekonstrukcije. U sljedećem pododjeljku bit će predstavljen podatkovni skup KITTI 2015, njegove specifičnosti, te postupci pripreme podataka.

4.1. Podatkovni skup KITTI 2015

Podatkovni skup KITTI 2015, skup je od 200 stereo parova slika za koje su laserski izmjerene mape dispariteta. Stereo par slika je unaprijed kalibriran i rektificiran. Primjer uz odgovarajuće disparitete prikazan je na slici 4.1. Podatkovni skup često se koristi za vrednovanje postupaka stereoskopske rekonstrukcije za autonomnu vožnju. Podatkovni skup je podijeljen na skup za učenje kojeg čini 80% slika (od indeksa 0 do 159), dok preostalih 20% (od indeksa 160 do 199) čini skup za validaciju.
Mape dispariteta su vrlo rijetke: dispariteti su izmjereni laserski samo u malenom podskupu svih piksela. Rijetke mape će na mjestima piksela za koje nije izmjeren disparitet imati vrijednost nula. Primjer takvih piksela su oni koji prikazuju udaljene objekte, kao što je nebo. Takvo mjerenje proizlazi iz toga što je disparitet obrnuto proporcionalan udaljenosti, te poprima vrijednost nula u beskonačnosti.
Također napravljena je intervencija na područjima slike na kojima se nalazi automobil. Intervencija se sastojala od proguščivanja dispariteta na mjestima automobila. Ova intervencija je od važnosti kod rekonstrukcijskih algoritama jer se na automobilu nalaze refleksivne površine poput stakla koje u dvjema kamerama stereoskopskog para mogu izgledati drugačije. [8]

Slika 4.1: Primjer iz podatkovnog skupa KITTI 2015. Gornja slika prikazuje referentnu lijevu sliku, a donja slika prikazuje odgovarajuću mapu dispariteta dobivenu laserskim senzorom.

5. Duboko učenje u kontekstu stereoskopske rekonstrukcije

U ovom poglavlju bit će predstavljena arhitektura dubokog modela koji se koristi za stereoskopsku rekonstrukciju. Metoda koristi ugrađivanje okana u visokodimenzionalan metrički prostor, pri čemu je moguće uspoređivanje po sličnosti koje koristimo u traženju korespondentnih piksela.

5.1. Ugrađivanje okana u metrički prostor

Algoritmi stereoskopske rekonstrukcije zahtijevaju robusno pronalaženje korespondencija s obzirom na šum, dok s druge strane tražimo da pronalaženje korespondencija na pikselima bez teksture nosi određenu informaciju. Razmatran duboki model koji uči na slikama s poznatim disparitetima zadovoljava uvjete prije spomenute metrike algoritma za stereoskopsku rekonstrukciju.

U ovom radu se koristi duboki model za ugrađivanje slika u visokodimenzionalan prostor. [7] Duboki model sastoji se od 4 konvolucijska sloja, pri čemu svaki sloj ima 64 značajke (engl. features). Za konvoluciju je korištena jezgra veličine $3x3$. Na ulaz modela dovodimo slikovno okno koje je dimenzija PxP, dok je izlaz modela ugrađivanje okna u 64 dimenzionalan vektor. Ono što konvolucijskoj arhitekturi daje prednost je što ugrađivanje provodi u jednom prolazu nad cijelom slikom. Prilikom takvog ugrađivanja koristi se nadopunjavanje nulama da se dobije izlaz istih prvih dviju dimenzija. Nadalje, ulaz je slika dimenzija WxH, a izlaz ugrađivanje čije su dimenzije $WxHx64$. Kako bismo mogli koristi kosinusnu sličnost (objašnjeno kasnije), potrebno je normirati izlaze na jedinični vektor duž osi značajki.

Nakon što je dubokim modelom ostvareno ugrađivanje okana u visokodimenzionalan prostor, moguće je provesti izračun mape dispariteta. Razmatramo jedan par slika I_L i I_D. Provedenim ugrađivanjem i normiranjem nastaju E_L i E_D spomenutih dimenzija $WxHx64$. Nad takvim reprezentacijama tražimo korespondentne piksele. Kako je već spomenuto slike su rektificirane, što nam omogućuje usporedbu samo po horizontalnoj dimenziji. U ovom radu razmatrat će se dispariteti u intervalu $[0...D]$, pri čemu je D maksimalan disparitet u skupu KITTI i iznosi 229. Kako je lijeva slika referentna, desna ugrađivanja posmičemo za disparitete u razmatranom intervalu uzduž horizontalne osi. Nakon posmaka vrši se skalarni umnožak vektora na odgovarajućim indeksima. Takvim množenjem dobiva se vektor dimenzija $WxHxD$, na čijim trećim dimenzijama se nalaze mjere sličnosti piksela.

Opisana mjera sličnosti vektora naziva se *kosinusna sličnost vektora*. U nastavku je dan matematički izraz takve mjere sličnosti:

$$\frac{\mathbf{a} \cdot \mathbf{b}}{\| \mathbf{a} \| \| \mathbf{b} \|} = \frac{\sum_i a_i b_i}{(\sum_i a_i^2)(\sum_i b_i^2)} \tag{5.1}$$

Kako je cilj pronaći najsličnije piksele koristi se operacija $argmax$ po trećoj dimenziji. Funkcija $argmax$ će vratiti indeks najsličnijeg piksela, odnosno čija je mjera sličnosti najveća. Provedenim operacijama je nastala tzv. mapa dispariteta. Kako se u postupku ne uzima u obzir susjedstvo piksela, ovakav pristup se naziva i *Winner takes all* zato što se razmatraju samo najsličniji pikseli. Na slici 5.1. prikazan je postupak izračunavanje mape dispariteta.

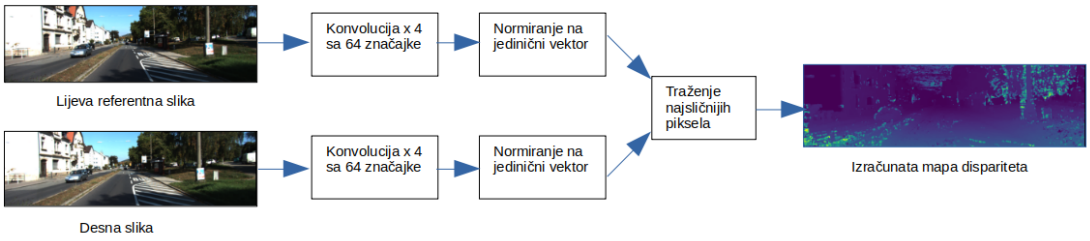

Slika 5.1: Postupak računanja mape dispariteta. Stereo par slika iz konkurentnih kamera ide na ulaz, prolazi kroz 4 konvolucijska sloja, te se na kraju izlaz normira na jedinični vektor. U zadnjem koraku se pronalaze najsličniji pikseli metodom *Winner takes all*.

5.2. Učenje modela za ostvarivanje korespondencije

Prije no što se krene s učenjem potrebno je svesti piksele slika na normalnu jediničnu razdiobu. Za takvo što je potrebno izračunati srednju vrijednost μ i standardnu devijaciju σ, te je konačan izraz za piksele $I(x, y)$:

$$I'(x, y) = \frac{I(x, y) - \mu}{\sigma} \tag{5.2}$$

Nakon što je izvršena normalizacija izdvajaju se okna nad kojima će spomenuti duboki model učiti. Ukupan skup sastoji se od oko 16 milijuna primjera, a za svaki od njih poznat je disparitet. Primjer za učenje sastoji od tri okna, a to su referentno okno R, pozitivno okno P i negativno okno N. Referentno i pozitivno okno čine međusobno sličan par, dok referentno i negativno čine manje sličan par. U nastavku je objašnjena uzorkovanje okna:

- $R = I_L^{PxP}(x, y)$ predstavlja referentno okno, nastalo uzorkovanjem u lijevoj slici bez primjene posmaka
- $P = I_D^{PxP}(x - d, y)$ je pozitivno okno, a dobiva se horizontalnim posmakom za poznati disparitet d (ovdje je riječ o čvrstom pozitivu dok će se u okviru rada još razmatrati rastreseni pozitivi, što je objašnjeno kasnije)
- $P = I_D^{PxP}(x-d-o, y)$ je negativno okno, a dobiva se horizontalnim posmakom središta za disparitet d te dodatnim nasumičnim odmakom o. Odmak se odabire iz intervala $[-14, -4] \cup [4, 14]$.

Na slici 6.2. prikazano je nekoliko primjera za učenje.

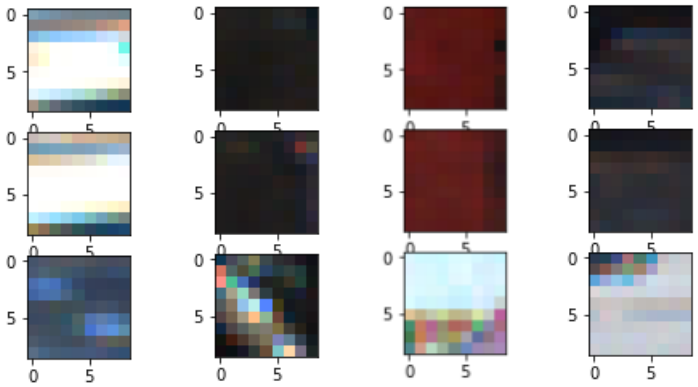

Slika 5.2: Prikaz 4 primjera za učenje. Prvi redak predstavlja referentno lijevo okno, redak ispod prikazuje čvrsti pozitiv (pozitivno okno bez nasumičnog pomaka), te zadnji redak prikazuje negativno okno.

Tijekom postupka optimizacije minimizira se trojni gubitak $L(R, P, N)$:

$$L(R, P, N) = max(0, m + \mathbf{h}(\mathbf{R}|\theta) \cdot \mathbf{h}(\mathbf{N}|\theta) - \mathbf{h}(\mathbf{R}|\theta) \cdot \mathbf{h}(\mathbf{P}|\theta)) \tag{5.3}$$

Pri čemu h predstavlja izlaz modela s parametrima θ. U funkciji gubitka zahtijevamo da ugrađivanje referentnog okna bude sličnije ugrađivanju pozitivnog okna u odnosu na ugrađivanje negativnog okna za najmanje m. Pojednostavljeno rečeno, model će učiti samo na primjerima na kojima je sličnost R i P manja od sličnosti između R i N za više od m [10].

6. Eksperimentalni rezultati

Kvaliteta rekonstrukcijske točnosti ocjenjuje se na slikama za koje su poznati dispariteti. Svi eksperimenti provedeni su na predstavljenom skupu KITTI. Za točno rekonstruirani piksel smatrat će se ako je odstupanje od točnog manje od 3 piksela. U tu svrhu koristit će se skup za testiranje koji se sastoji od 20% slika početnog skupa od 200 slika. Učenje traje 14 epoha, algoritam učenja je ADAM uz stopu učenja koja iznosi $1e^{-3}$ do 10. epohe, a nakon nje je $1e^{-4}$. Veličina mini-grupe (engl. batch-size) je 128. Svi eksperimenti izvodili su se na platformi Colab pro, a učenje je trajalo 9 sati.
Provedena su sljedeća 3 eksperimenta:

- ulazne slike u boji (RGB) s čvrstim pozitivima, odnosno bez posmaka
- ulazne slike u boji (RGB) s rastresenim pozitivima, odnosno nasumično posmaknutim brojem iz skupa {-1, 0, 1}
- sive ulazne slike s čvrstim pozitivima

Tablica 6.1: Rekonstrukcijske točnosti razmatranih modela

Model	Treniranje	Testiranje
Ulazne slike u boji (RGB) s čvrstim pozitivima	82.90%	81.24%
Ulazne slike u boji (RGB) s rastresenim pozitivima	82.43%	80.81%
Sive ulazne slike s čvrstim pozitivima	81.41%	80.07%

U tablici 6.1. prikazane su rekonstrukcijske točnosti razmatranih eksperimenata. Najbolji od 3 razmatrana modela je onaj koji koristi ulazne slike u boji s čvrstim pozitivima.

Na slikama 6.1, 6.2 i 6.3 prikazano je kretanje prosječnih gubitaka po epohama i to na skupovima za treniranje i validaciju. Slike prikazuju grafove za model s čvrstim i rastresenim pozitivima za RGB, te model s čvrstim pozitivima za sive ulazne slike. Vidljivo je kako model koji koristi čvrste pozitive brže minimizira pogrešku. Što se tiče sivih slika s čvrstim pozitivima u odnosu na RGB slike s čvrstim pozitivima, model s RGB slikama je bolji, razlog leži u tome što RGB slike imaju 3 kanala te posljedično nose više informacija.

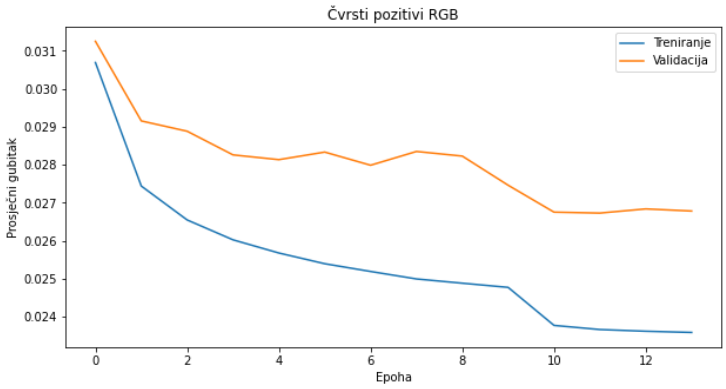

Slika 6.1: Graf prikazuje kretanje prosječnog gubitka tijekom epoha treniranja i validacije. Za učenje modela se koriste čvrsti pozitivi RGB slika, odnosno bez posmaka.

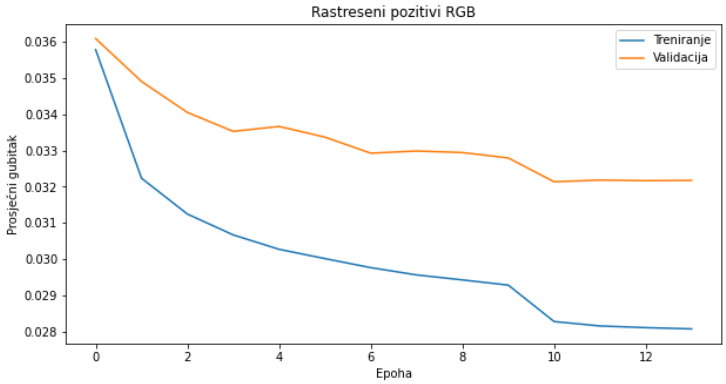

Slika 6.2: Graf prikazuje kretanje prosječnog gubitka tijekom epoha treniranja i validacije. Za učenje modela se koriste rastreseni pozitivi RGB slika (posmaknuti za nasumičan broj u skupu {-1, 0, 1}).

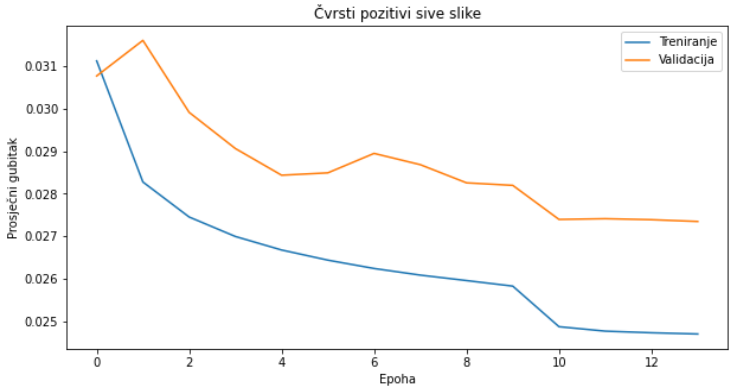

Slika 6.3: Graf prikazuje kretanje prosječnog gubitka tijekom epoha treniranja i validacije. Za učenje modela se koriste čvrsti pozitivi sivih slika.

Na slici 6.4. prikazane su rekonstrukcije za 4 slike nasumično odabrane iz skupa. Na mapama dispariteta je vidljiva velika razlika u susjednim pikselima, što je posljedica nekorištenja nekog od filtera zaglađivanja. Razmatrana metoda griješi na mjestima slike na kojima se nalaze refleksivne površine automobila. Na takvim područjima se svjetlost odbija, te okna iz tih područja predstavljaju problem modelu u procesu učenja. Sljedeća pojava koja predstavlja problem modelu su područja koja se na slikama jedne kamere vide, a na slikama druge kamere ne. Ta pojava naziva se stereoskopskom sjenom. [5]

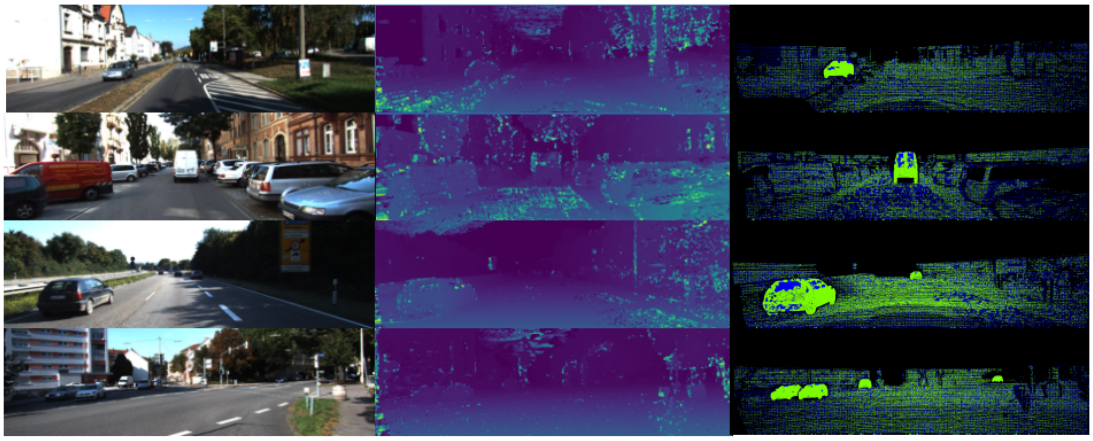

Slika 6.4: Prikaz rekonstrukcijske točnosti modela za ugrađivanje okana u visokodimenzionalan prostor. Lijeve slike prikazuju slike iz lijeve referentne kamere. U sredini se nalaze procijenjene mape dispariteta. Na mapi dispariteta što je svjetliji piksel to je veći disparitet, a tamniji što je manji. Zdesna se nalaze rekonstrukcijske točnosti, pri čemu su crnom bojom označeni pikseli uz nepoznat disparitet, plavom bojom pogrešno rekonstruirani pikseli, te zelenom bojom točno rekonstruirani pikseli.

7. Programska izvedba i vanjske biblioteke

Za izradu ovog rada korišten je programski jezik Python. Za izgradnju i učenje modela korišteno je radno okruženje PyTorch. Ovo okruženje nudi velik spektar alata i podrške, a jedan od njih je automatska diferencijacija, što uvelike ubrzava proces izgradnje i učenja modela. Torch kao osnovna jedinica PyTorcha omogućava izračune tenzorima na velikoj paleti grafičkih kartica kompanije Nvidia.

Za pripremu podataka i računanje tenzorima korištena je biblioteka Numpy. Ova biblioteka pisana je u jeziku niske razine C,te koristi biblioteke poput OpenBLAS čiji su ključni dijelovi izravno pisani u strojnom kodu za različite arhitekture modernih računala. Takva implementacija čini operacije vrlo brzim.

Za proces učenja, validacije i testiranja korištena je platforma Colab Pro u kombinaciji s Google Drive. Platforma u pretplati Pro nudi tri grafičke kartice koje se dodjeljuju ovisno o raspoloživosti. Tipovi grafičkih kartica su sljedeći: K80, T4 i P100.

Podatkovni skup KITTI 2015 uzet je s javno dostupne stranice u vlasništvu kolaboracije Karlsruhe Institute of Technology i Toyota Technological Institute.

8. Zaključak

Računalni vid se ubrzano razvija, te kao takav nudi mnogo zanimljivih koncepata koji se mogu riješiti njegovom primjenom. U okviru ovog rada razmatrana je stereoskopska rekonstrukcija uz korištenje korespondencijske metrike slikovnih okana. Metoda je koncipirana na način da se slikovna okna ugrađuju u visokodimenzionalan metrički prostor.

U okviru rada predstavljeni su glavni koncepti korišteni u stereoskopskoj rekonstrukciji, što uključuje epipolarnu geometriju, disparitet i algoritme stereoskopske rekonstrukcije. Nastavno na to predstavljena je arhitektura modela, te učenje dubokog modela za ugrađivanje slikovnih okana i vrednovanja rezultata.

Duboki model bio je učen na velikom skupu podataka, što je nužno za dostizanje velike rekonstrukcijske točnosti. Provođenjem eksperimenata došlo se do zaključaka da korespondencijka metrika slikovnih okana daje dobre rezultate na mjestima postojanih tekstura dok se loše ponaša na područjima slika bez teksture, te područjima s releksivnim površinama. Najbolji rezultati dobiveni su korištenjem čvrstih pozitiva slika u boji (RGB).

Nastavno na ovaj rad, predlaže se korištenje samonadziranog učenja, što bi omogućilo korištenje neoznačenih podataka i dubljih modela.

LITERATURA

[1] Akash Ajagekar. Adam. URL https://optimization.cbe.cornell.edu/index.php?title=Adam.

[2] Nikola Bunjevac. Gusta stereoskopska rekonstrukcija poluglobalnim podudaranjem. 2017. URL http://www.zemris.fer.hr/~ssegvic/project/pubs/bunjevac17bs.pdf.

[3] Richard Szeliski Daniel Scharstein. A taxonomy and evaluation of dense two-frame stereo correspondence algorithms. URL https://vision.middlebury.edu/stereo/taxonomy-IJCV.pdf.

[4] Siniša Šegvić. Neslužbene stranice predmeta duboko učenje 1. URL http://www.zemris.fer.hr/~ssegvic/du/.

[5] Antonio Ilinović. Učenje korespodencijskg ugrađivanja za stereoskopsku rekonstrukciju. 2022. URL http://www.zemris.fer.hr/~ssegvic/project/pubs/ilinovic22bs.pdf.

[6] Alfred Wong Jonathon Price. Stochastic gradient descent. URL https://optimization.cbe.cornell.edu/index.php?title=Stochastic_gradient_descent.

[7] Yann LeCun Jure Žbontar. Computing the stereo matching cost with a convolutional neural network. 2015. URL https://ieeexplore.ieee.org/document/7298767/.

[8] Yann LeCun Jure Žbontar. Stereo matching by training a convolutional neural network to compare image patches. 2016. URL https://arxiv.org/abs/1510.05970/.

[9] Dino Kovač. Gusta stereoskopska rekonstrukcija scene predstavljene ravninskim

odsječcima. 2015. URL http://www.zemris.fer.hr/~ssegvic/project/pubs/kovac15ms.pdf.

[10] Marin Oršić. Učenje korespondencijske metrike za gustu stereoskopsku rekonstrukciju. 2017. URL http://www.zemris.fer.hr/~ssegvic/project/pubs/orsic17ms.pdf.

Korespondencijska ugrađivanja za stereoskopsku rekonstrukciju

Sažetak

Korespodencijska metrika slikovnih okana jedna je od metoda korištenih u stereoskopskoj rekonstrukciji. Stereoskopska rekonstrukcija je postupak analize slika iz dviju ili više konkurentnih kamera kojim se dobiva rekonstrukcija scene u 3D formatu iz nativnog 2D formata. Korespondencijska metrika slikovnih okana zasniva se na ugrađivanju okana u visokodimenzionalan prostor. Nakon ugrađivanja okana slijedi pronalaženje korespondentnih piksela te se kao izlaz dobiva mapa dispariteta. U okviru rada korišten je duboki model učen i testiran na javno dostupnom podatkovnom skupu. Rezultati eksperimenata vrednovani su izračunom rekonstrukcijske točnosti.

Ključne riječi: korespondencijska ugrađivanja, stereoskopska rekonstrukcija, duboko učenje, računalni vid

Correspondence embeddings for stereoscopic reconstruction

Abstract

The correspondence metric of image patches is one of the methods used in stereoscopic reconstruction. Stereoscopic reconstruction is the process of analyzing images from two or more concurrent cameras to obtain a reconstruction of a scene in 3D format from the native 2D format. The correspondence metric is based on the embedding image patch to a high-dimensional metric space. After such embedding, the next phase is finding correspondent pixels. Disparity map is obtained as an output of calculation the most similar pixels. In the paper there is a explanation of a deep model, which is learned and tested on a publicly available data set. The results of the experiments were evaluated by the calculation of reconstructive accuracy.

Keywords: correspondence embeddings, stereoscopic reconstruction, deep learning, computer vision