SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

ZAVRŠNI RAD br. 6346

Konvolucijski modeli za jednooku predikciju dubine scene

Filip Oreč

Zagreb, srpanj 2019.

Zahvaljujem mentoru prof. dr. sc. Siniši Šegviću na ukazanom povjerenju i stručnim savjetima.

Zahvaljujem svojoj obitelji na bezuvjetnoj podršci i potpori tijekom cijelog školovanja.

SADRŽAJ

1. Uvod

Predikcija dubine scene je odavno poznati problem. Konvencionalni prikazi kao što su slika ili video prikazuju trodimenzionalni svijet u dvije dimenzije. Time gubimo informaciju o trećoj dimenziji koja sadrži informaciju o dubini scene. Iako je dvodimenzionalna reprezentacija dovoljna u većini primjena, nekad nam je potrebna trodimenzionalna reprezentacija. Percepcija dubine proizlazi iz raznih indicija ili naznaka o dubini. Obično se dijele na binokularne indicije koji sadrže informacije u tri dimenzije i mogu se vidjeti s dva oka i monokularne indicije koji sadrže informacije u dvije dimenzije i mogu se vidjeti s jednim okom.

Tijekom godina razvile su se razne tehnike za predikciju dubine scene poput stereoskopije koja se oslanja na binokularne indicije. Korištenjem dvije slike iste scene koje su dobivene iz malo drugačijih kuteva, moguće je izračunati udaljenost od objekta. Aplikacijama koje uključuju razumijevanje scene, 3D modeliranje i slično jako je bitna informacija o dubini kad gore navedena organizacija podataka i tehnike nisu dostupni. U tom slučaju koristi se jednooka predikcija dubine scene koja predstavlja loše postavljen (engl. *ill-posed*) problem, jer iz jedne dvodimenzionalne slike može nastati beskonačno mnogo različitih trodimenzionalnih scena. Za ljude ovo ne predstavlja veliki problem, jer možemo jako dobro iskoristiti monokularne indicije, ali za računala predstavlja ogroman problem za riješiti s velikom preciznosti i malom uporabom resursa. Zbog navedenog razloga te jednostavnosti primjene, u zadnje vrijeme se sve češće upotrebljavaju konvolucijske neuronske mreže koji uče odnos između lokalnog izgleda i dubine, što je i predmet ovog rada. Detaljnije ću obraditi konvolucijsku neuronsku mrežu predloženu u [5], te ju implementirati i primijeniti na problem jednooke predikcije dubine scene.

U drugom poglavlju objašnjeni su osnovni pojmovi vezani uz umjetne neuronske mreže, te osnovni algoritmi koji se koriste prilikom njihovog učenja. Treće poglavlje opisuje konvolucijske neuronske mreže te zašto su one bitne. U sklopu trećeg poglavlja još se opisuju rezidualne neuronske mreže i koje probleme one rješavaju. Četvrto poglavlje bavi se detaljima implementacije predložene arhitekture, te se ukratko opi-

suje korišteni programski okvir PyTorch. U petom poglavlju su opisani rezultati koje je model ostvario.

2. Umjetna neuronska mreža

Nastanak umjetnih neuronskih mreža u početku je bio inspiriran biološkim neuronima i neuronskim mrežama, ali daljnjim razvojem su se odvojile od biološke povezanosti i postale stvar inženjerstva. Definiraju se procesne jedinice zvane umjetni neuroni koji se međusobno povezuju te grade umjetne neuronske mreže.

2.1. Umjetni neuron

Warren McCulloch i Walter Pitts 1943. godine konstruirali su matematički model neurona kakav je prikazan na slici 2.1.

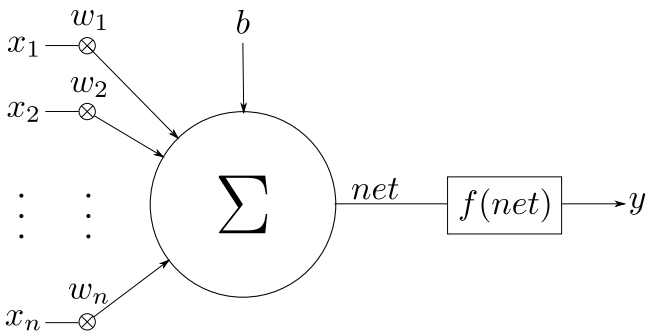

Slika 2.1: Umjetni neuron

Umjetni neuron prima više ulaza $x_1, x_2, ..., x_n$ koji tvore ulazni vektor $\mathbf{x}$. Taj ulazni vektor može biti stvarni ulaz ili izlaz iz nekog prethodnog neurona. Za svaku vrijednost x_i ulaznog vektora $\mathbf{x}$ postoji vrijednost w_i koju nazivamo težina (eng. *weight*). To je vrijednost koja predstavlja utjecaj ulaza x_i na neuron. Svaki ulaz x_i množi se s odgovarajućom težinom w_i što daje umnožak $x_i \cdot w_i$. Vrijednosti $w_1, w_2, ..., w_n$ tvore vektor težina $\mathbf{w}$. Još se definira i vrijednost b koja označava pomak (engl. *bias*). Sve

primljene vrijednosti se sumiraju prema izrazu 2.1.

$$net = \sum_{i=1}^{n} x_i \cdot w_i + b \tag{2.1}$$

Izraz 2.1 može se zapisati u matričnom obliku:

$$net = \mathbf{w}^\top \cdot \mathbf{x} + b \tag{2.2}$$

Pri tome ulazni vektor $\mathbf{x}$ i vektor težina $\mathbf{w}$ imaju dimenzije N$\times$1, gdje N predstavlja broj ulaza u neuron, dok je pomak b skalar. Rezultat sumiranja net dalje se predaje kao ulaz prijenosnoj funkciji koja određuje konačni izlaz o neurona prema izrazu 2.3.

$$y = f(net) = f(\mathbf{w}^\top \cdot \mathbf{x} + b) \tag{2.3}$$

Gdje f predstavlja prijenosnu funkciju.

2.1.1. Prijenosne funkcije

Glavna zadaća prijenosne funkcije je pretvorba ulaznih vrijednosti u izlaznu vrijednost. Pri tome se mogu koristiti različite vrste funkcija ovisno o arhitekturi mreže. Danas postoji više prijenosnih funkcija koje se češće koriste.

Prva od njih je funkcija skoka koja se koristila u ranijim modelima, dok se danas ne koristi često. Definirana je izrazom 2.4.

$$u(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \tag{2.4}$$

Bitno svojstvo ove funkcije je prekid u točki $x = 0$, te zbog toga nije diferencijabilna u toj točki. Naime, to svojstvo onemogućava korištenje algoritama učenja koji se temelje na gradijentu. Izgled funkcije prikazan je na slici 2.2.

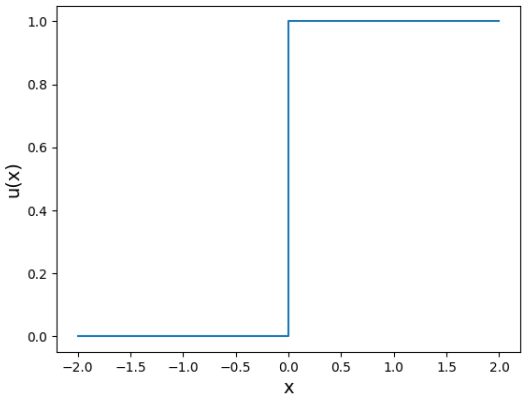

Slika 2.2: Funkcija skoka

Sigmoidalna funkcija ima jako dobra svojstva te se zbog toga često primjenjuje. Ta funkcija spljošćuje (ili zbija) skup realnih brojeva na interval $[0, 1]$. Definirana je izrazom 2.5.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \tag{2.5}$$

Ova funkcija ima dosta sličnosti s funkcijom skoka. Naime, ako je x neki veliki pozitivan broj onda je $e^{-x} \approx 0$, i izlaz iz neurona je blizu 1. S druge strane ako je x neki veliki negativni broj onda $e^{-x} \to \infty$, i izlaz iz neurona je blizu 0. To se jako dobro može primijetiti na grafu funkcije prikazanom na slici 2.3.

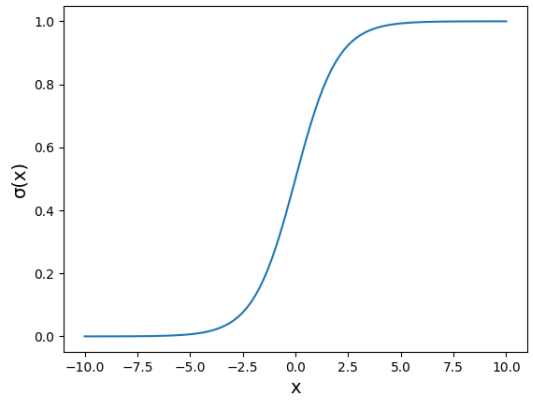

Slika 2.3: Sigmoidalna funkcija

Velika prednost sigmoidalne funkcije u odnosu na funkciju skoka je činjenica da je derivabilna, što omogućava korištenje algoritama učenja koji se temelje na gradijentu. Derivacija ove funkcije dana je izrazom 2.6.

$$\frac{d\sigma(x)}{dx} = \sigma(x) \cdot (1 - \sigma(x)) \tag{2.6}$$

Na krajevima funkcija jako slabo reagira na promjene i zato će gradijent u tim dijelovima imati male vrijednosti. Ako mreža uči pomoću lokalnih gradijenata, u tom slučaju učenje staje, jer gradijenti ne mogu napraviti značajne promjene.

Funkciju tangens hiperbolni moguće je dobiti izravno iz sigmoidalne funkcije. Definicija je dana izrazom 2.7.

$$tanh(x) = 2\sigma(2x) - 1 \tag{2.7}$$

Ova prijenosna funkcija smješta bilo koji realni broj na interval $[-1, 1]$. Prednost je što je derivabilna, ali kao i sigmoidalna funkcija na krajevima jako slabo reagira na promjene, te ako je vrijednost ulaza u funkciju u tom području, učenje staje, što se može vidjeti na grafu funkcije 2.4. Derivacija funkcije dana je izrazom 2.8.

$$\frac{dtanh(x)}{dx} = 1 - tanh^2(x) \tag{2.8}$$

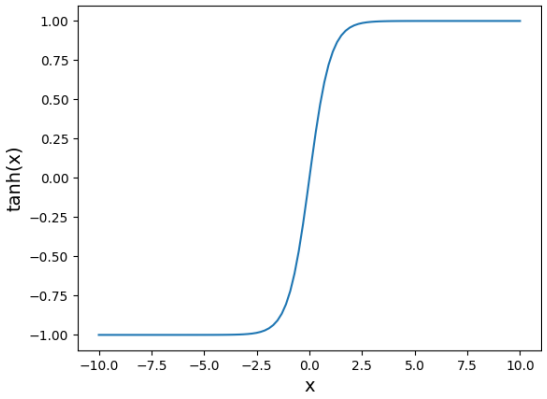

Slika 2.4: Tangens hiperbolni

Zadnjih nekoliko godina sve se češće koristi zglobnica (engl. *Recitified Linear Unit*). Određena je izrazom 2.9.

$$relu(x) = max(0, x) \tag{2.9}$$

Ova prijenosna funkcija sve vrijednosti veće od 0 propušta, dok vrijednosti manje od 0 uopće ne propušta, što se može vidjeti na grafu funkcije 2.9.
Derivacije ove funkcije dana je izrazom 2.10.

$$\frac{drelu(x)}{dx} = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases} \tag{2.10}$$

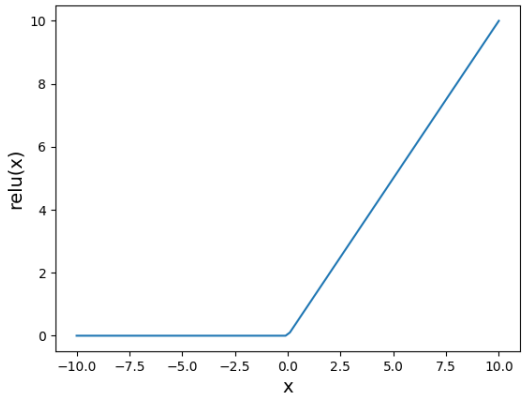

Slika 2.5: ReLU

Razlog zbog kojeg se sve češće primjenjuje je brzina računanja. Ali i ova prijenosna funkcija ima nedostatak. Iz izraza 2.10 se vidi da je za sve negativne brojeve derivacija jednaka 0, što predstavlja problem za algoritme učenja temeljene na gradijentu. Neuron kojemu je suma ulaza, odnosno net negativan, se zbog toga neće moći prilagođavati.

2.2. Arhitektura umjetne neuronske mreže

Umjetna neuronska mreža sastoji se od više umjetnih neurona koji su međusobno povezani i grupirani u slojeve. Na slici 2.6 je prikazana neuronska mreža koja ima četiri sloja. Prvi sloj je ulazni i sastoji se od tri neurona, a zadnji sloj je izlazni i sastoji se od dva neurona. Svaki sloj koji se nalazi između ulaznog i izlaznog zove se skriveni sloj.

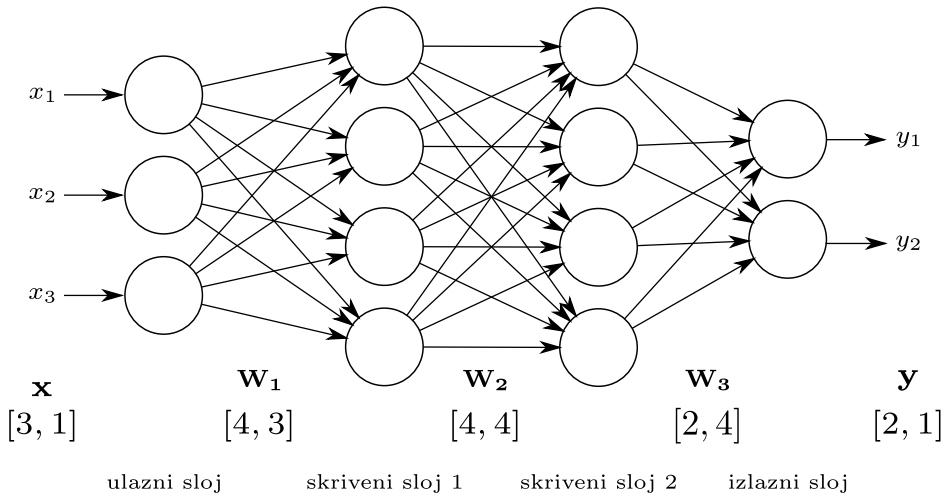

Slika 2.6: Umjetna neuronska mreža

Ovakva mreža zove se još i potpuno povezana mreža, jer je izlaz iz svakog neurona u jednom sloju povezan sa svim neuronima u idućem sloju. Arhitektura neuronske mreže opisuje kompoziciju funkcija. Na primjer, mrežu sa slike 2.6 možemo opisati kompozicijom funkcija $f(\mathbf{x}) = f^{(3)}(f^{(2)}(f^{(1)}(\mathbf{x})))$, gdje $f^{(1)}$ predstavlja prvi skriveni sloj, $f^{(2)}$ drugi skriveni sloj, a $f^{(3)}$ izlazni sloj. Pri tome su funkcije $f^{(1)}$, $f^{(2)}$, $f^{(3)}$ definirane izrazima:

$$\mathbf{h_1} = f^{(1)}(\mathbf{x}; \mathbf{W_1}, \mathbf{b_1}) = g_1(\mathbf{W_1} \cdot \mathbf{x} + \mathbf{b_1}) \tag{2.11}$$

$$\mathbf{h_2} = f^{(2)}(\mathbf{h_1}; \mathbf{W_2}, \mathbf{b_2}) = g_2(\mathbf{W_2} \cdot \mathbf{h_1} + \mathbf{b_2}) \tag{2.12}$$

$$\mathbf{y} = f^{(3)}(\mathbf{h_2}; \mathbf{W_3}, \mathbf{b_3}) = g_3(\mathbf{W_3} \cdot \mathbf{h_2} + \mathbf{b_3}) \tag{2.13}$$

Gdje g_1, g_2 i g_3 predstavljaju prijenosne funkcije u pojedinim slojevima, a matrice $\mathbf{W_1}$, $\mathbf{W_2}$ i $\mathbf{W_3}$ predstavljaju matrice težina pojedinih slojeva. Vektori $\mathbf{b_1}$, $\mathbf{b_2}$ i $\mathbf{b_3}$ predstavljaju pomak za svaki sloj.

2.3. Učenje umjetne neuronske mreže

Učenje neuronske mreže je proces nalaženja optimalnih parametara $\boldsymbol{\theta}$, kako bi neuronska mreža što bolje aproksimirala ciljnu funkciju. Ciljna funkcija se zaključuje na osnovu uzoraka iz skupa za učenje koji se predočavaju neuronskoj mreži. Svaki uzorak je par koji se sastoji od ulaza u mrežu i željenog izlaza. Ovakav način učenja se zove nadzirano učenje (engl. *supervised learning*).

Kako bi odredili koliko dobro mreža aproksimira ciljnu funkciju koristimo funkciju gubitka. Optimiziranjem funkcije gubitka neuronska mreža se uči.

2.3.1. Funkcija gubitka

Kako bi se moglo ostvariti učenje, potrebno je definirati funkciju gubitka, koja ovisi o parametrima $\boldsymbol{\theta}$, tj. o težinama $\mathbf{W}$ i pomacima $\mathbf{b}$. Kao i prijenosna funkcija, funkcija gubitka se može definirati na više načina.

Najčešće funkcije gubitka za regresijske probleme su $\mathcal{L}_1$ i $\mathcal{L}_2$ funkcije gubitka. Definirane su sljedećim izrazima:

$$\mathcal{L}_1 = \sum_{i=0}^{n} |y_i - \hat{y}_i| \tag{2.14}$$

$$\mathcal{L}_2 = \sum_{i=0}^{n} (y_i - \hat{y}_i)^2 \tag{2.15}$$

gdje y_i predstavlja ispravnu vrijednost, $\hat{y}_i = f(\mathbf{x})$ procijenjenu vrijednost, a n broj podataka.

Za probleme klasifikacije se $\mathcal{L}_1$ i $\mathcal{L}_2$ funkcije gubitka ne koriste toliko često. Za ovaj problem se pretežito koristi unakrsna entropija (engl. *cross- entropy loss*). Definirana je izrazom 2.16.

$$\mathcal{L}_{CE} = -\sum_{i=0}^{n} y_i \cdot log(\hat{y}_i) \tag{2.16}$$

2.3.2. Gradijentni spust

Optimiziranjem funkcije gubitka parametri neuronske mreže se "štimaju" i mreža uči. Za optimiziranje funkcije gubitka koristi se gradijentni spust. To je iterativni optimizacijski algoritam za pronalaženje minimuma funkcije.

Ako je funkcija $y = f(x)$, gdje su x i y realni brojevi, funkcija koja se optimizira, onda je derivacija te funkcije $f'(x) = \frac{dy}{dx}$. Tada je aproksimacija funkcije $f(x)$ Taylorovim razvojem prvog reda:

$$f(x + \Delta x) \approx f(x) + f'(x) \cdot \Delta x \tag{2.17}$$

Ako se u tu aproksimaciju uvrsti pomak u smjeru gdje funkcija pada, odnosno u smjeru negativne derivacije dobiva se:

$$f(x - \epsilon \cdot sign(f'(x))) \approx f(x) - f'(x) \cdot \epsilon \cdot sign(f'(x)) \tag{2.18}$$

Vidi se da je $f(x - \epsilon \cdot sign(f'(x)))$ manje od $f(x)$ za dovoljno mali ϵ. Dakle, ako se x iterativno pomiče malim koracima sa suprotnim predznakom derivacije, može se doći do minimuma funkcije.

Za funkcije više varijabli koriste se parcijalne derivacije i gradijent funkcije. Parcijalna derivacija $\frac{\partial}{\partial x_i} f(\mathbf{x})$ određuje koliko se f promijeni ako se jedino x_i poveća u točki $\mathbf{x}$. Gradijent funkcije $\nabla f(\mathbf{x})$ je vektor koji sadrži sve parcijalne derivacije funkcije:

$$\nabla f(\mathbf{x}) = \left[\frac{\partial f}{\partial x_1}, \frac{\partial f}{\partial x_2}, \cdots, \frac{\partial f}{\partial x_n} \right] \tag{2.19}$$

Određivanje gradijenata gubitka s obzirom na parametre modela je opisano u odjeljku 2.3.5. Aproksimacija funkcije više varijabli Taylorovim razvojem prvog reda je dana sljedećim izrazom:

$$f(\mathbf{x} + \Delta \mathbf{x}) \approx f(\mathbf{x}) + \nabla f(\mathbf{x})^\top \Delta \mathbf{x} \tag{2.20}$$

Ako se u danu aproksimaciju uvrsti pomak u smjeru najbržeg pada funkcije, odnosno u smjeru negativnog gradijenta funkcije dobiva se:

$$f(\mathbf{x} - \epsilon \cdot \nabla f(\mathbf{x})) \approx f(\mathbf{x}) - \epsilon \cdot \nabla f(\mathbf{x})^\top \nabla f(\mathbf{x}) \tag{2.21}$$

gdje ϵ predstavlja mali pozitivan parametar koji se češće zove korak učenja. Kako je $\nabla f(\mathbf{x})^\top \nabla f(\mathbf{x}) \geq 0$, funkcija $f(\mathbf{x})$ će se smanjivati sve dok ne dođe do minimuma gdje je $\nabla f(\mathbf{x}) = \mathbf{0}$. Za sljedeću iteraciju $\mathbf{x}$ se ažurira izrazom 2.22 i postupak se ponavlja za točku $\mathbf{x}'$.

$$\mathbf{x}' = \mathbf{x} - \epsilon \cdot \nabla f(\mathbf{x}) \tag{2.22}$$

Ako funkcija f predstavlja funkciju gubitka $\mathcal{L}$ onda se svakim korakom gradijentnog spusta ažuriraju se parametri neuronske mreže izrazima:

$$\mathbf{w}' = \mathbf{w} - \epsilon \cdot \nabla_{\mathbf{w}} \mathcal{L}(\mathbf{w}, \mathbf{b}) \tag{2.23}$$

$$\mathbf{b}' = \mathbf{b} - \epsilon \cdot \nabla_{\mathbf{b}} \mathcal{L}(\mathbf{w}, \mathbf{b}) \tag{2.24}$$

Ako je skup podataka za učenje velik, računanje gradijenta za sve podatke odjednom može biti sporo. Postupak se može ubrzati korištenjem stohastičkog gradijentnog spusta. Korak gradijentnog spusta se računa samo za dio skupa za učenje (engl. *batch*). Prolazak kroz cijeli skup za učenje naziva se epoha. Ovaj način također omogućava i bolje izbjegavanje lokalnih minimuma.

2.3.3. Optimizacija

Učenje neuronske mreže gradijentnim spustom može se ubrzati raznim optimizacijskim metodama.

Jedna od tih metoda je momentum. Definira se novi vektor $\mathbf{v}$, te se mijenja jednadžba za ažuriranje parametara gradijentnog spusta na sljedeći način:

$$\begin{aligned} \mathbf{v}' &= \alpha \mathbf{v} - \epsilon \nabla \mathcal{L} \\ \mathbf{w}' &= \mathbf{w} + \mathbf{v}' \end{aligned} \tag{2.25}$$

gdje je $\alpha \in [0, 1)$ hiperparametar koji modelira prigušenje koje omogućuje zaustavljanje u minimumu. Najčešće se inicijalizira na 0.9. Vektor $\mathbf{v}$ predstavlja brzinu kretanja prema minimumu, što je gradijent veći, brzina će se sve više povećavati.

2.3.4. Regularizacija

Neuronska mreža mora imati dobre rezultate izvođenja ne samo na skupu podataka za učenje, nego i na novim podatcima. Razvijene su razne metode kako bi se smanjila pogreška na novim podatcima, pa čak i ako se poveća pogreška na skupu za učenje. Ove metode poznate su kao regularizacija.

Jedna od metoda je dodavanje funkciji gubitka dodatni član:

$$\mathcal{L}_r = \mathcal{L} + \lambda N(w) \tag{2.26}$$

gdje je $\mathcal{L}$ gubitak, a λ je hiperparametar koji određuje utjecaj regularizacijskog člana. Ako regularizacijski član odgovara L^1-normi ili L^2-normi, onda se ova metoda zove L^1-regularizacija, odnosno L^2-regularizacija. U tom slučaju funkcija gubitka se može ovako napisati:

$$\mathcal{L}_r = \mathcal{L} + \lambda \sum_i |w_i| \tag{2.27}$$

$$\mathcal{L}_r = \mathcal{L} + \lambda \sum_i w_i^2 \tag{2.28}$$

gdje se jednadžba 2.27 odnosi na L^1-regularizaciju, a 2.28 na L^2 regularizaciju. Posljedica dodavanja regularizacijskog člana je preferiranje učenja manjih težina.

Sljedeća metoda je dropout, koja se dosta razlikuje od L^1 i L^2 regularizacije. Ova metoda se ne oslanja na izmjenjivanje funkcije gubitka nego na izmjenjivanje same mreže. Svaki neuron u skrivenom sloju s određenom vjerojatnošću privremeno postaje isključen tijekom učenja. Tako se sprječava da utjecaj nekih neurona postane prevelik i tako uzrokuje prenaučenost.

Povećavanje skupa za učenje je još jedan način kako smanjiti prenaučenost. Dobivanje novih podataka za učenje može biti skupo i nije uvijek moguće. Zato se postojeći skup podataka za učenje može proširiti raznim transformacijama. To mogu biti razne transformacije poput rotacije, zrcaljenja, skaliranja, izmjene svjetline i kontrasta.

Još jedan oblik regularizacije je normalizacija nad grupama (engl. *batch-normalization*). Izlaz iz svakog sloja se normalizira. Ako je μ_B aritmetička sredina, a σ_B^2 varijanca podataka mini grupe B, tada za sloj s ulazom $x = (x^{(1)}, ..., x^{(d)})$ se primjenjuje normalizacija:

$$\hat{x}^{(k)} = \frac{x^{(k)} - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \tag{2.29}$$

Bez normalizacije male promjene u prvim slojevima će se povećati kako se propagiraju kroz mrežu, što rezultira velikim promjenama u dubljim slojevima. Metoda normalizacije nad grupama smanjiva ovakve neželjene promjene i tako ubrzava proces treniranja. Kako ova metoda koristi srednju vrijednost i varijancu grupe koje su svaku epohu različite, model ne trenira na istim podatcima i tako se postiže regularizacija.

2.3.5. Propagacija pogreške unatrag

Propagacija pogreške unatrag (engl. *back-propagation*) je algoritam za učinkovito računanje gradijenata funkcije putem rekurzivne primjene pravila ulančavanja. Dakle, za neku funkciju $f(\mathbf{x})$ gdje je $\mathbf{x}$ ulazni vektor, algoritam propagacije pogreške unatrag

računa gradijent funkcije f u točki $\mathbf{x}$, tj. $\nabla f(\mathbf{x})$. Za slučaj učenja neuronske mreže gradijentnim spustom, funkcija f će odgovarati funkciji gubitka $\mathcal{L}$, a ulazni vektor $\mathbf{x}$ će se sastojati od podataka za učenje, težina $\mathbf{W}$ i pomaka $\mathbf{b}$ neuronske mreže.

U konačnici, to znači računanje parcijalnih derivacija $\partial\mathcal{L}/\partial w_{jk}^l$ i $\partial\mathcal{L}/\partial b_j^l$, gdje w_{jk}^l označava težinu koja povezuje k-ti neuron u $(l-1)$-om sloju s j-tim neuronom u l-tom sloju. Slično, b_j^l označava pomak j-tog neurona u l-tom sloju. Za računanje ovih parcijalnih derivacija uvodi se pogreška δ_j^l neurona j u sloju l:

$$\delta_j^l = \frac{\partial\mathcal{L}}{\partial net_j^l} \tag{2.30}$$

gdje net_j^l predstavlja izlaz iz neurona prije primjene aktivacijske funkcije definiran jednadžbom 2.1. Za pogrešku neurona δ_j^L u izlaznom sloju vrijedi:

$$\delta_j^L = \frac{\partial\mathcal{L}}{\partial y_j^L}\frac{\partial y_j^L}{\partial net_j^L} = \frac{\partial\mathcal{L}}{\partial y_j^L}f'(net_j^L) \tag{2.31}$$

gdje y_j^L predstavlja izlaz iz neurona, a f prijenosnu funkciju definirane jednadžbom 2.3. Jednadžba 2.31 može se zapisati u matričnom obliku:

$$\delta^L = \nabla_y\mathcal{L} \odot f'(net^L) \tag{2.32}$$

gdje $\odot$ predstavlja umnožak matrica gdje se elementi na istim mjestima množe. Primjenom ove jednadžbe mogu se dobiti pogreške samo za neurone izlaznog sloja, ali poznavanjem pogrešaka nekog sloja mogu se dobiti pogreške prethodnog sloja. Pogreške skrivenih slojeva se izračunavaju prema izrazu:

$$\delta^l = ((w^{l+1})^\top\delta^{l+1}) \odot f'(net^l) \tag{2.33}$$

gdje w^{l+1} predstavlja matricu težina u $(l+1)$-om sloju. Jednadžbama 2.32 i 2.33 može se izračunati pogreška δ^l za svaki sloj mreže. Prvo se izračuna pogreška izlaznog sloja δ^L pomoću jednadžbe 2.32, zatim se pomoću jednadžbe 2.33 izračuna pogreška δ^{L-1}, zatim pogreška δ^{L-2} i sve tako do ulaznog sloja mreže.

Parcijalna derivacija s obzirom na pomak odgovara upravo pogrešci neurona:

$$\frac{\partial\mathcal{L}}{\partial b_j^l} = \delta_j^l \tag{2.34}$$

dok je parcijalna derivacija s obzirom na težinu neurona:

$$\frac{\partial\mathcal{L}}{\partial w_{jk}^l} = y_k^{l-1}\delta_j^l \tag{2.35}$$

Jednadžbama 2.34 i 2.35 izračunava se ovisnost funkcije gubitka o pojedinim parametrima, što je i cilj algoritma propagacije pogreške unatrag.

3. Konvolucijska neuronska mreža

Konvolucijske neuronske mreže (engl. *convolutional neural networks*) su posebna vrsta neuronskih mreža za obradu podataka koji imaju rešetkastu (engl. *grid-like*) topologiju. Najbolji primjer su slikovni podatci, koji se mogu smatrati kao 2D rešetka piksela.

Kod potpuno povezanih neuronskih mreža izlaz iz svakog neurona u jednom sloju je povezan sa svakim neuronom u sljedećem sloju. Za slike dimenzija HxWxC ulaz u mrežu je dimenzija $H \cdot W \cdot C$ što znači da će samo jedan neuron u prvom skrivenom sloju imati $H \cdot W \cdot C$ težina. Kako je svaki neuron jednog sloja povezan sa svim neuronima idučeg sloja za podatke ovih dimenzija doći će do pojave previše parametara.

Konvolucijske neuronske mreže imaju prorijeđenu interakciju između neurona i dijeljenje težina, što znači da je potrebno pohraniti manje parametara i da izračunavanje izlaza zahtjeva manje operacija. Na slici 3.1 je označen neuron x_3 i izlazni neuroni s koji su povezani s tim neuronom. Lijevo je prikazana prorijeđena interakcija, a desno potpuno povezana.

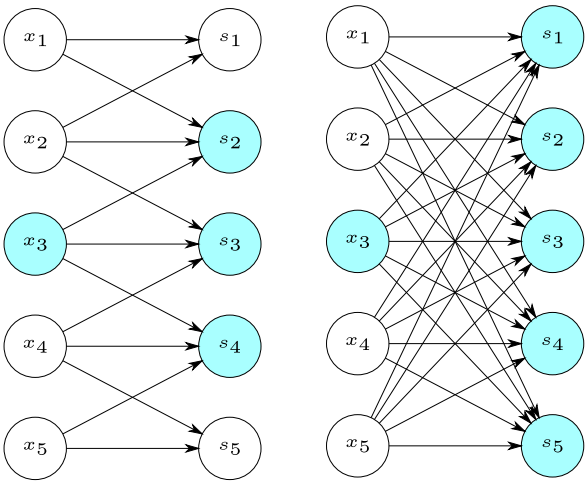

Slika 3.1: Primjer prorijeđene interakcije neurona u jednodimenzionalnom konvolucijskom sloju s filterom veličine 3.

Dvodimenzionalni konvolucijski slojevi konvolucijske neuronske mreže su organi-

zirani u tri dimenzije: visina, dužina i dubina. Neuroni u pojedinom sloju su povezani samo s malim dijelom neurona u prethodnom sloju, a ne sa svim neuronima kao kod potpuno povezanih slojeva. Konvolucijske neuronske mreže grade se od tri osnovna sloja: konvolucijski sloj, sloj sažimanja i potpuno povezani sloj.

Konvolucijski sloj je temeljni sloj konvolucijske neuronske mreže. Parametri ovog sloja sastoje se od skupa filtera koji se mogu naučiti. Filteri su prostorno dosta manjih dimenzija od ulaza u sloj. Izlazi se izračunavaju tako da se primjenjuje dvodimenzionalna konvolucija ulaza s filterom čime se dobiva dvodimenzijska mapa značajki. Na slici 3.2 filter je dimenzija 2x2, dok je ulaz dimenzija 3x4. Filter se pomjera po dužini i visini ulaza i izračunava se skalarni produkt između članova filtera s članovima ulaza na odgovarajućim pozicijama. Na kraju se dobiva mapa značajki s dimenzijama 2x3. Konvolucijski slojevi obično imaju više filtera, i svaki od njih će izračunati zasebnu

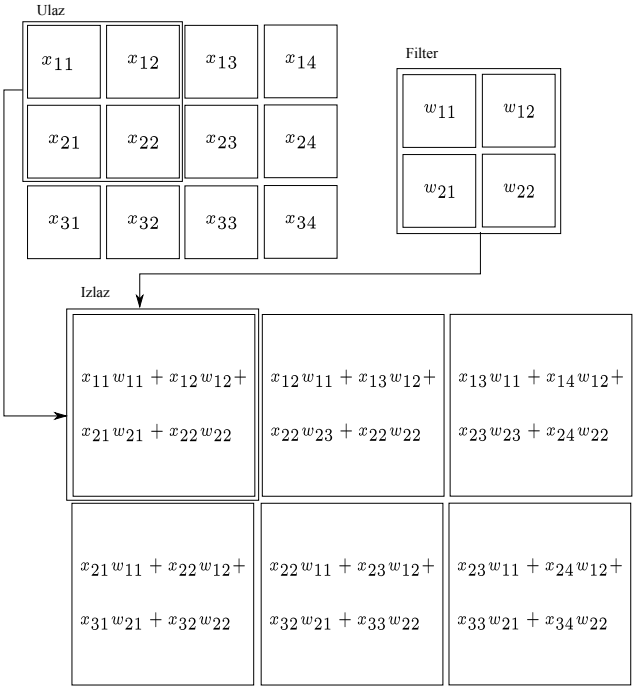

Slika 3.2: Primjer dvodimenzionalne konvolucije ulaza s filterom. Izlaz se ograničava samo na pozicije gdje filter leži potpuno unutar granica ulaza. Nacrtani su kvadrati sa strelicama kako bi se ukazalo kako nastaje gornji lijevi element izlaza primjenom filtera na odgovarajući gornji lijevi predio ulaza [3].

mapu značajki koje se slažu po dubini i tako stvaraju izlaz. Na dobivene izlaze još se primjenjuje prijenosna funkcija. Broj neurona koji su povezani s neuronom u sljedećem sloju zove se receptivno polje neurona i odgovara upravo veličini filtera.

Kako bi izlazne mape značajki imale istu visinu i dužinu kao i ulaz ponekad je potrebno nadopuniti ulaz kako filter prilikom konvolucije ne bi prelazio rubove ulaza.

Najčešće se koristi nadopunjavanje nulama. Filter se ne mora uvijek micati samo po jedan neuron, ali ako se miće po više neurona odjednom dimenzija izlaza će se smanjiti. Broj za koji se filter miće zove se korak (engl. *stride*).

Sloj sažimanja je sloj koji smanjuje prostorne dimenzije (visinu i dužinu) ulaza kako bi se smanjio broj parametara neuronske mreže i time smanjio memorijski otisak modela tijekom učenja. Primjenjuje se nezavisno na svakoj od mapi značajki. Sažimanje se može ostvariti na više načina, ali se najčešće koristi sažimanje maksimalnom vrijednošću (engl. *max-pooling*). Odabire se veličina i korak filtera, te se primjenjuje funkcija sažimanja na područje koje odgovara trenutnoj poziciji filtera. Na slici 3.3 je prikazano sažimanje maksimalnom vrijednošću s veličinom filtera 2x2 i korakom 2. Ovaj sloj ne uvodi dodatne parametre u mrežu.

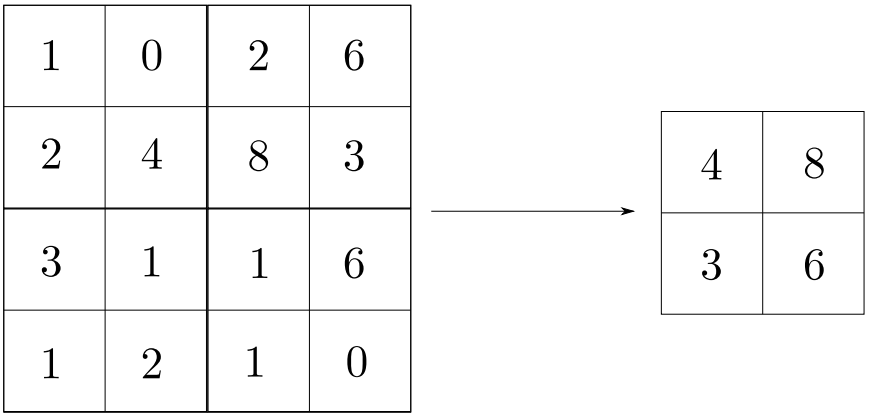

Slika 3.3: Sažimanje maksimalnom vrijednošću s filterom veličine 2x2 i korakom 2.

3.1. Rezidualna neuronska mreža

Duboke konvolucijske neuronske mreže su se pokazale jako učinkovite pri rješavanju problema iz područja računalnog vida. Također se pokazalo da je dubina neuronske mreže jako važna. Ali nakon određenog broja slojeva dolazi do problema nestajućih i eksplodirajućih gradijenata što sprječava učenje od početka [4]. Ovaj problem se u velikoj mjeri rješava normaliziranim inicijaliziranjem i normalizacijskim slojevima, što omogućava mrežama s desetak slojeva konvergirati. Međutim, pojavio se problem degradacije: kako se dubina mreže povećava točnost mreže počinje naglo opadati.

Kao rješenje navedenog problema razvile su se rezidualne neuronske mreže koje koriste rezidualne blokove definirane u [4]. Ovi blokovi uvode nove veze u slojevima zvane prečice koje preskaču jedan ili više slojeva i zbrajaju se s izlazom zadnjeg

preskočenog sloja. Kako se izlaz iz prečice zbraja sa izlazom preskočenih slojeva dimenzije im se moraju podudarati.

Rezidualni blokovi rješavaju prethodno opisani problem opadanja točnosti s povećavanjem dubine mreže, tj. problem degradacije. Uporabom ovih blokova dodavanjem novih slojeva pospješuju se rezultati, ali se povećava broj parametara. Za mreže s 50 slojeva i više koriste se rezidualni blokovi s uskim grlom, kako bi smanjili broj parametara i broj operacija. Kod običnih rezidualnih blokova koriste se dva konvolucijska sloja s filterima veličine 3x3, dok blok s uskim grlom koristi jednu takvu konvoluciju i dvije konvolucije s filterima veličine 1x1 ispred i iza nje. Prva konvolucija smanjuje broj filtera, dok zadnja povećava na početni broj kako bi se omogućilo zbrajanje s izlazom iz prečice.

4. Implementacija

Programska implementacija konvolucijskog modela za jednooku predikciju dubine scene ostvarena je po uzoru na rad [5] uz manje promjene.

4.1. Korišteni alati i tehnologije

Za izradu rada korišten je programski jezik Python[1], radno okruženje PyTorch[2], te biblioteke Numpy[3], h5py[4], matplotlib[5], sckit-image [6]. Biblioteka Numpy je korištena za efikasno izvršavanje različitih operacija nad matricama, dok je biblioteka sckit-image korištena za učitavanje slika. Biblioteka h5py korištena je za jednostavno spremanje i učitavanje slika. Za vizualizaciju podataka i rezultata korištena je biblioteka matplotlib.

Veći dio programske implementacije napisan je koristeći radno okruženje PyTorch. Verzija PyTorcha u kojoj je pisana programska implementacija je 1.0.1. Jedna od bitnijih karakteristika ovog radnog okruženja je njegov tensor koji je jako sličan Numpyovom polju s dodatkom da se može izvoditi na GPU koji podržava CUDA što omogućava veću brzinu izvođenja. Još jedno bitno svojstvo PyTorcha je to što omogućava jednostavnu implementaciju propagacije pogreške unatrag. Prilikom izvršavanja matematičkih operacija nad tensorima PyTorch sprema koje su se operacije izvodile i pomoću toga izračunava gradijente. Ova metoda zove se automatska diferencijacija i implementirana je u modulu *Autograd*.

Jednostavan primjer automatske diferencijacije u PyTorchu:

```
1 import torch
2
```

[1] https:// www.python.org
[2] https://pytorch.org
[3] https://www.numpy.org
[4] https:// www.h5py.org
[5] https://matplotlib.org
[6] https://scikit-image.org/

```
3 x = torch.ones(1, requires_grad=True) #tensor([1.])
4 y = x + 2 #tensor([3.])
5 z = y * y * 3 #tensor([27.])
6
7 z.backward() #racunanje gradijenata unatrag
8
9 print(x.grad) #dz/dx = 18
```

4.2. NYU Depth podaci

Neuronska mreža je trenirana na *NYU Depth v2* [7] skupu podataka. Skup se sastoji od slijeda videa iz raznih scena iz zatvorenih prostora koje su snimane s RGB i dubinskom kamerom Microsoft Kinect. Najveća moguća dubina iznosi 10 metara. Ukupno ima 464 scene iz 3 različita grada, 1449 gusto označenih usklađenih parova RGB slika i dubinskih slika, te 407024 neusklađenih slika. Označeni podatci su prethodno obrađeni da popune nedostajuće dubinske oznake, dok su ostali podatci neobrađeni.

Slika 4.1: Primjer prethodno obrađenih podataka

[7] https://cs.nyu.edu/~silberman/datasets/nyu_depth_v2.html

Slika 4.2: Primjer neobrađenih podataka

4.2.1. Priprema podataka

Treniranje neuronske mreže se provodi nadziranim učenjem nad neobrađenim podatcima. Neobrađeni podatci se sastoje od 464 scene s podjelom na 249 scene za treniranje i 215 za testiranje. Za treniranje se međutim koristi mali podskup slika iz 240 scene za treniranje. Iz svake scene uzorkovano je 50 jednako udaljenih slika i odgovarajućih dubinskih slika, što je rezultiralo od ukupno 12000 parova RGB-D slika. Uzorkovane dubinske slike su obrađene pomoću funkcija koje su dostupne uz *NYU Depth v2* skup podataka. Projiciranje su na odgovarajuće RGB slike i pogrešni pikseli su postavljeni na 0. Prilikom treniranja provodi se umjetno proširivanje skupa za učenje čime se dobiva blizu 95000 RGB-D parova.

Ulazne RGB slike imaju dimenzije 640x480, te se moraju svesti na dimenzije ulaza u neuronsku mrežu. Prvo se uzorkuju (engl. *down-sample*) na pola veličine, zatim se odrežu u sredini na dimenzije 304x228.

Nad tim ulaznim RGB slikama se primjenjuju transformacija za umjetno proširivanje skupa podataka. Transformacije koje se primjenjuju:

- Skaliranje: ulazne slike i dubinske mape se skaliraju sa $s \in [1, 1.5]$ i dubinske mape se dijele sa s.
- Rotacija: ulazne slike i dubinske mape se rotiriaju za $r \in [-5, 5]$ stupnjeva.
- Translacija: ulazne slike i dubinske mape su odrezane na nasumično odabranim mjestima kako bi im dimenzije odgovarale dimenzijama ulaza u mrežu.
- Boja: ulazne slike se množe s nasumičnom RGB vrijednosti $c \in [0.8, 1.2]^3$.
- Zrcaljenje: ulazne slike i dubinske mape su vodoravno preokrenute s vjerojatnošću od 0.5.

Ovaj postupak se ponavlja 8 puta za svaki RGB-D par.

Podaci skupa za testiranje dobivaju se na sličan način kao i za skup za treniranje. Iz svake od 215 scena za testiranje uzorkovano je 50 jednako udaljenih slika i odgovarajućih dubinskih slika i time se dobije 10750 parova RGB-D slika.

Skup za validaciju sastoji se od 654 slike preuzetih iz prethodno obrađenih 1449 slika. Slike iz skupa za validaciju su preuzete iz scena za testiranje.

4.3. Stanford Background podaci

Model ResNet-50, koji je prvi dio predložene arhitekture u [5], je testiran na *stanford background dataset*-u [8] na problemu semantičke segmentacije. Skup se sastoji od 715 slika i pripadnih oznaka iz više javno dostupnih izvora. Slike prikazuje vanjske scene i sadrže barem jedan objekt u prvom planu. Svaki piksel je klasificiran u jednu od 9 mogućih klasa: nebo, stablo, cesta, trava, voda, gradevina, planina, objekt u prednjem planu i nedefinirano. Slike nisu jednakih veličina, ali imaju maksimalnu visinu i širinu od 320 piksela.

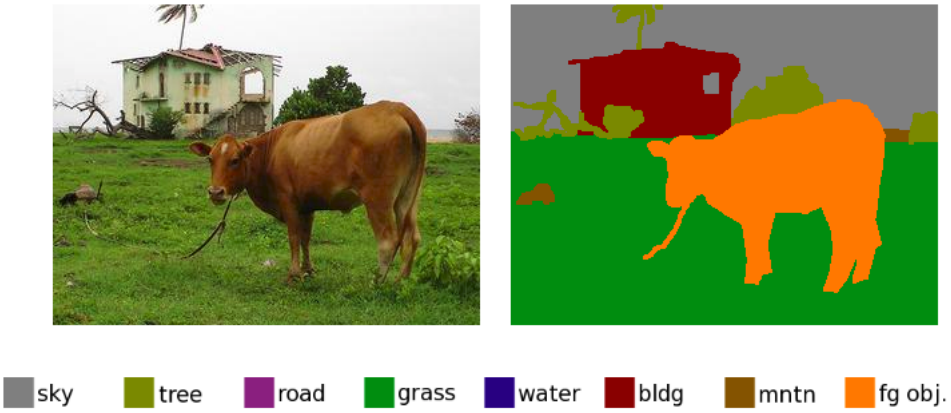

Slika 4.3: Primjer ulazne slike i semantičkih oznaka iz stanford background dataset-a

4.3.1. Priprema podataka

Priprema stanford background podataka određna je prema radu [1]. Podatci su podjeljeni u tri skupa. Slučajnim odabirom 64% podataka pripalo je skupu za učenje, 16% skupu za validaciju i 20% skupu za testiranje. Kao i kod *NYU Depth v2* skupa poda-

[8] `http://dags.stanford.edu/projects/scenedataset.html`

taka primjenjuje se umjetno proširivanje skupa podataka. Nad skupom za treniranje primjenjuju se sljedeće transformacije:

- Translacija: ulazne slike i odgovrajuće oznake su izrezane na nasumično odabranim mjestima.
- Zrcaljenje: ulazne slike i odgovarajuće oznake su vertikalno i horizontalno preokrenute s vjerojatnošću od 0.5.
- Boja: svjetlina je promjenjena za $c \in [-0.2, 0.2]$.

Na svaku sliku su primjenje transformacije redom kako su navedene 9 puta nakon čega se dobiva 4113 novih slika. Kako bi se omogućilo grupno učenje sve slike i odgovarajuće oznake su nadopunjene do maksimalnih dimenzija. Prilikom računanja gubitka ignoriraju se nadopunjeni pikseli.

4.4. Arhitektura modela za semantičku segmentaciju

Korišteni model je ResNet-50 s nekoliko manjih izmjena. Većina modela je implementirana prema radu [4], te je samo zadnji dio modela izmjenjen. Umjesto zadnjeg globalnog sloja sažimanja i zadnjeg potpuno povezanog sloja dodan je konvolucijski sloj s filterom i korakom veličine 1, a broj filtera odgovara broju klasa.

Na kraju se na izlaz primjenjuje bilinearno naduzorkovanje kako bi dimenzije izlaza odgovarale dimenzijama ulaznih slika.

4.5. Arhitektura modela za jednooku predikciju dubine scene

Arhitektura neuronske mreže se nadograđuje na ResNet-50 model. Zamjenjuje se zadnji potpuno povezani sloj, koji je dio izvorne arhitekture, s novim blokovima za naduzorkovanje, čime se dobiva izlaz koji približno duplo manje dimenzije od ulaza. Zadnji konvolucijski sloj ResNet-50 modela proizvodi izlaz s 2048 mapi značajki s dimenzijama 10x8, zatim se blokovima za naduzorkovanje postiže izlaz dimenzija 160x128 piksela. Arhitektura modela je prikazana na slici 4.4.

Kako bi se povećala rezolucija izlaza uvode se novi blokovi za naduzorkovanja zvani up-convolution blokovi. Na slici 4.4 su ovi blokovi prikazani strelicom prema gore. Cilj ovih blokova je povećati za duplo dimenzije ulaza, tako da preslikavaju svaki ulaz u gornji lijevi kut filtera veličine 2x2, a ostatak filtera se puni nulama. Nakon

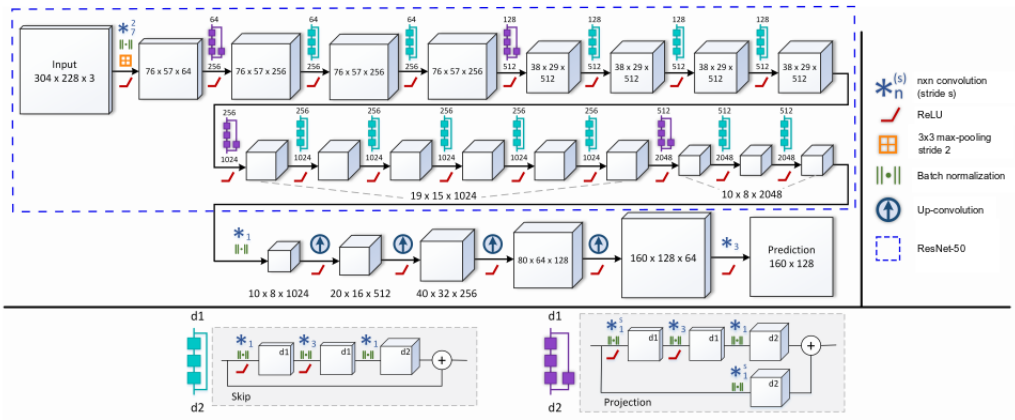

Slika 4.4: Arhitektura mreže predložena u [5]. Prvi dio mreže, označen isprekidanim crticama, predstavlja ResNet-50 model. Zadnji potpuno povezani sloj, koji je dio izvorne arhitekture, je izbačen kako bi se dodala četiri nova up-convolution bloka, označeni sa strelicama prema gore. Za strukturu up-convolution bloka pogledati sliku 4.5. Dole su prikazani rezidualni blokovi od kojih je građen ResNet-50.

svakog takvog sloja slijedi konvolucijski sloj s filterom veličine 5x5 i zatim ReLU sloj. Up-convolution blok vidljiv je na slici 4.5.

Ovaj blok se dalje proširuje kako bi se stvorio up-projection blok. Nakon up-convolution bloka dodaje se 3x3 konvolucija i rezultatu se dodaje projekcijska veza iz mape značajki s manjom rezolucijom kako je prikazano na slici 4.6. Zbog razlike u dimenzijama, manje mape značajki trebaju se naduzorkovati s još jednim up-convolution blokom. Prva operacija up-convolution bloka se primjenjuje za obje grane zajedno, a zatim se 5x5 konvolucija primjenjuje odvojeno.

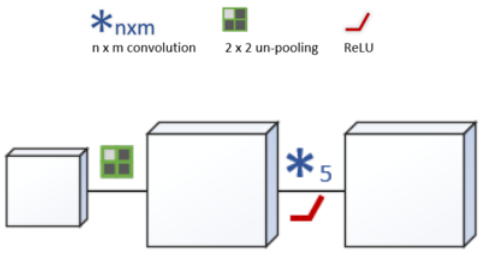

Slika 4.5: Up-convolution blok. Ulaz u blok se prvo puni nulama, čime se dimenzije duplo povećavaju, zatim se primjenjuje konvolucija pa ReLU. Ovakvi blokovi mogu naučiti naduzorkovanje, za razliku od bilinearnog naduzorkovanja koje je fiksno određeno. Više ovakvih blokova poredanih uzastopno mogu naučiti nelinearno naduzorkovati.

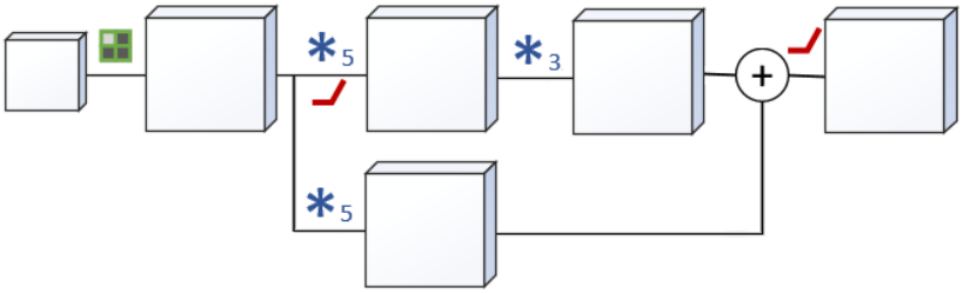

Slika 4.6: Up-projection blok koji slijedi ideju rezidualnih blokova. Uvode se nova 3x3 konvolucija nakon up-convolution bloka i prečica koja preskače tu konvoluciju, te im se izlazi zbrajaju. Ovi blokovi mogu zamijeniti obične up-convolution blokove prikazane na slici 4.5

Kako bi se povećala učinkovitost up-convolution bloka uvodi se novi brzi up-convolution blok. Nakon primjene prve operacije u up-convolution bloku 75% brojeva u izlaznim mapama značajki su nule, prema tome 5x5 konvolucija većinom djeluje na nulama, što se može izbjeći. Ovo se može vidjeti na slici 4.7.

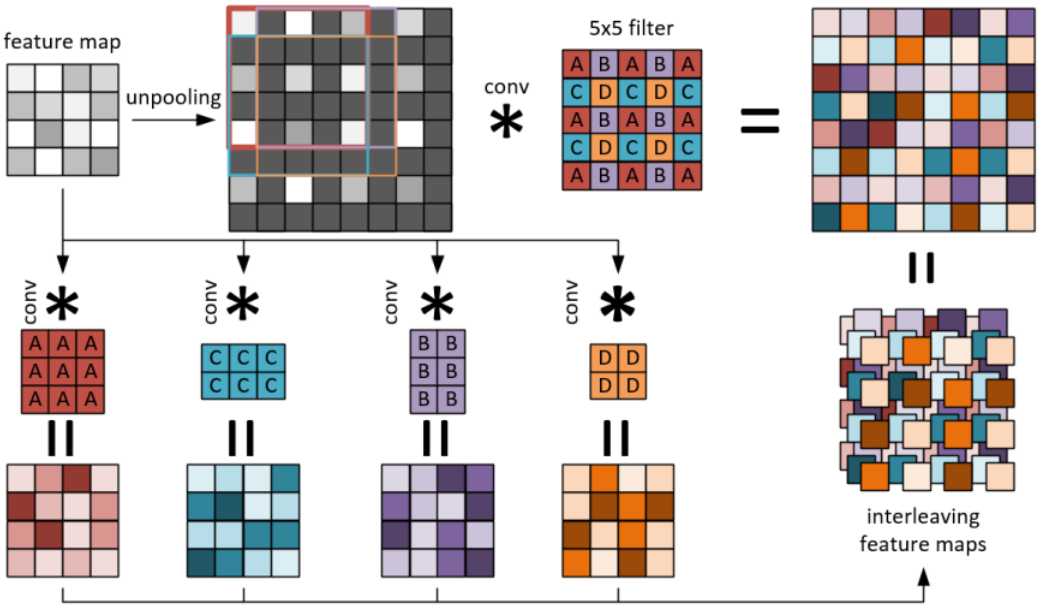

Slika 4.7: Način rada brzog up-convolution bloka

Nakon povećavanja dimenzije mapi značajki, te primjene 5x5 konvolucije, samo se određene težine množe s vrijednostima koje nisu nula. Te težine se dijele na četiri grupe koje se ne preklapaju, prikazane oznakama A,B,C,D i različitim bojama. Na temelju te četiri grupe izvorna 5x5 konvolucija se zamjenjuje s četiri nova filtera dimenzija 3x3 (A), 3x2 (B), 2x3 (C), 2x2 (D). Isti izlaz se sad može ostvariti kao i kod

izvornih operacija umetanjem elemenata iz četiri nove mape značajki kao što je prikazano na slici 4.7. Brzi up-convolution blok koji koristi ovu metodu prikazan je na slici 4.8.

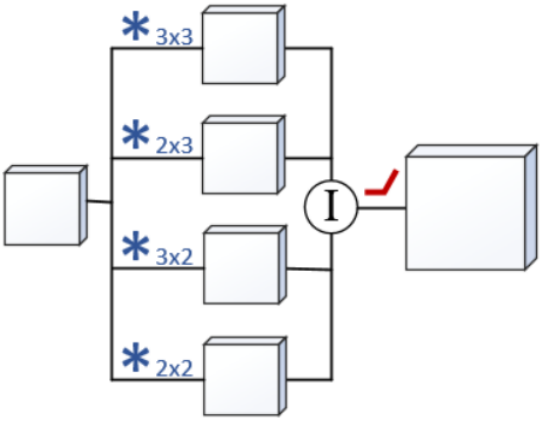

Slika 4.8: Brzi up-convolution blok

Kako se kod običnog up-convolution bloka uvodi novi up-projection blok, tako se i za brzi up-convolution blok uvodi novi brzi up-projection blok. Njegova arhitektura prikazana je na slici 4.9.

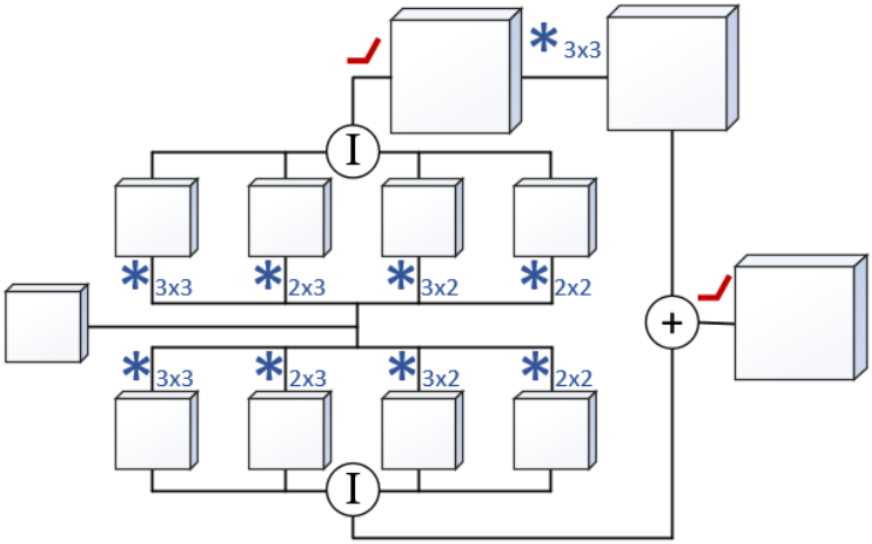

Slika 4.9: Brzi up-projection blok

5. Rezultati

5.1. Rezultati semantičke segmentacije

Model ResNet-50 je evaluiran na *Stanford Background* skupu podataka i rezultati su uspoređeni s rezultatima prijašnjih radova, a među njima su prisutni radovi kolega Ivana Grubišića (Grubišić, 2016) i Ivana Borka (Borko, 2015.). Kao mjera točnosti korišten je omjer točno kalsificiranih piksela kroz ukupan broj piksela.

$$\text{točnost} = \frac{\text{točno klasificirani pikseli}}{\text{ukupan broj piksela}} \tag{5.1}$$

Početna stopa učenja je 10^{-3} i nakon 25 epoha umanjena je 10 puta. Treniranje je provedeno kroz ukupno 50 epoha nad skupom za treniranje s dodatno generiranim slikama. Veličina grupe za učenje (engl. *batch*) je 15. Tijekom treniranja pikseli koji predstavljaju nadopunu nisu uzimani u obzir prilikom računanja gubitka. Dobivena točnost na skupu za validaciju je 74.4%.

Sustav	Točnost
Farbet et al. 2013.	0.788
Farbet et al. + superpikseli 2013.	0.804
Mohan 2014.	0.842
Borko 2015.	0.742
Grubišić 2016., konv. mreža s 3 razine	0.743
Grubišić 2016., konv. mreža s 3 razine + dropout	0.757
Grubišić 2016., konv. mreža s 3 razine + dropout + SLIC	0.756
Anđelić 2018., ResNet-50 + umjetno proširivanje	0.745
Anđelić 2018., ResNet-50 + spojeni skupovi	0.755
ResNet-50 + umjetno proširivanje	0.744

Na slici 5.1 grafički su prikazani rezultati dobiveni na skupu podataka za validaciju.

U lijevom stupcu prikazane su ulazne slike, a u srednjem stupcu prikazani su izlazi iz neuronske mreže. Desni stupac prikazuje projekciju izlaza na ulazne slike.

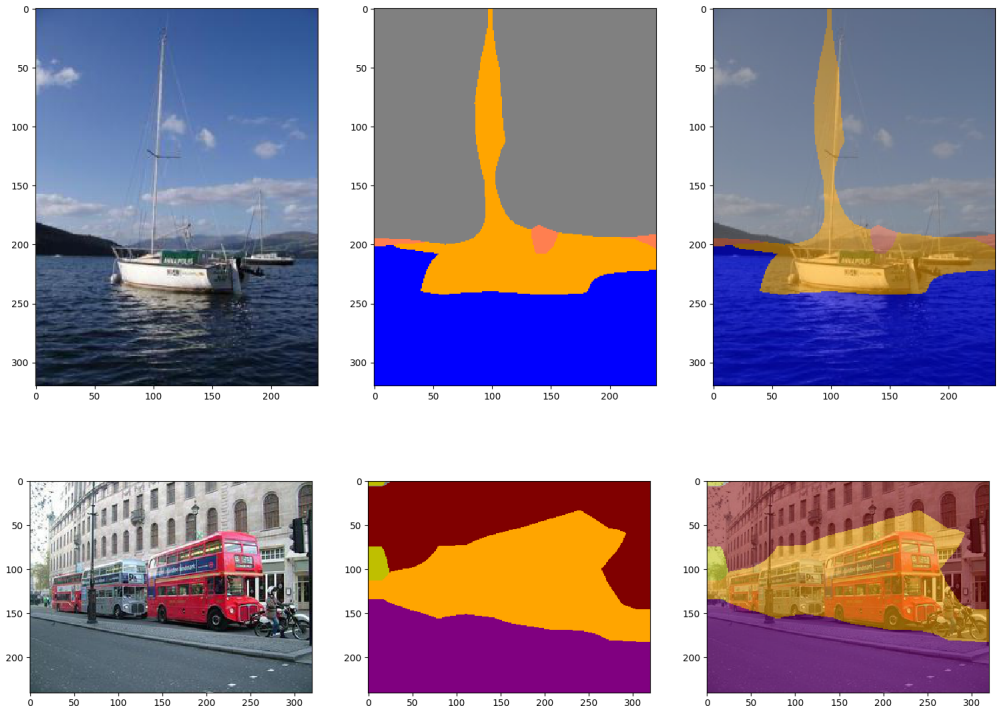

Slika 5.1: Grafički prikaz rezulatata

5.2. Rezultati jednooke predikcije dubine scene

Model je evaluiran na *NYU Depth v2* skupu podataka i rezultati su uspoređeni s rezultatima drugih autora. Kao mjera točnosti korištena je srednja apsolutna relativna pogreška i srednja kvadratna pogreška. Srednja apsolutna relativna pogreška računa se prema izrazu:

$$\eta = \frac{1}{n}\sum_{i=1}^{n}\frac{|x-\hat{x}|}{x} \tag{5.2}$$

gdje n predstavlja ukupan broj piksela, x predstavlja ispravnu vrijednost, a $\hat{x}$ predstavlja predikciju. Srednja kvadratna pogreška računa se prema sljedećem izrazu:

$$\eta = \frac{1}{n}\sum_{i=1}^{n}(x-\hat{x})^2. \tag{5.3}$$

.

Prilikom treniranja korištena je obrnuta Huber (berHu) funkcija pogreške [5]. Definirana je izrazom :

$$\mathcal{B}(x) = \begin{cases} |x| & |x| \leq c, \\ \frac{x^2+c^2}{2c} & |x| > c. \end{cases} \tag{5.4}$$

Berhu funkcija gubitka jednaka je $\mathcal{L}_1$ funkciji kad je $x \in [-c, c]$ i $\mathcal{L}_2$ funkciji kad je x izvan danog intervala. Verzija koja se ovdje koristi je kontinuirana na prijelazu između $\mathcal{L}_1$ i $\mathcal{L}_2$. U svakom koraku gradijentnog spusta izračunava se $\mathcal{B}(\hat{y} - y)$, gdje y predstavlja ispravne vrijednosti piksela, a $\hat{y}$ predikciju, te se postavlja $c = \frac{1}{5} max_i(|\hat{y}_i - y_i|)$ gdje i indeksira sve piksele slika u trenutnoj grupi za učenje.

Skup za treniranje sastoji se od ukupno 96800 slika dobivenih umjetnim proširivanjem originalnog skupa za učenje koji se sastoji od 12100 slika.

Treniranje se provodi stohastičkim gradijentnim spustom s zaletom gdje se momentum postavlja na 0.9. Početna stopa učenja je s berHu funkcijom gubitka je 10^{-2}, a s $\mathcal{L}_2$ je 10^{-4} i umanjuje se 10 puta svakih 6 epoha. Treniranje je provedeno kroz ukupno 20 epoha. Koriste se mini-grupe za učenje veličine 16 slika, gdje je svaka ulazna slika dimenzija 304x228x3. Pri tome učenje zahtjeva 6GB memorije.

Kako su dimenzije slika s ispravnim vrijednostima veće od dimenzija izlaza, te slike se prilikom treniranja naduzorkuju na dimenzije slika s ispravnim vrijednostima. Prilikom treniranja pogrešni pikseli (s vrijednošću 0) se ne uzimaju u obzir pri izračunavanju gubitka. Prilikom računanja srednje apsolutne relativne i srednje kvadratne pogreške izlazi iz mreže se naduzorkuju (engl. *up-sample*) na dimenzije slika s ispravnim vrijednostima.

Dobivena srednja apsolutna relativna pogreška na skupu za treniranje je 0.059, dok je srednja kvadratna pogreška 0.284. Na skupu za validaciju dobivena srednja apsolutna relativna pogreška je 0.147, dok je srednja kvadratna pogreška 0.622. Prilikom treniranja s $\mathcal{L}_2$ funkcijom gubitka početna stopa učenja je 10^{-4}, te so dobiju nešto lošiji rezultati. Proveden je i eksperiment u kojem se mreža uči na samo 10 slika kroz 1000 epoha. Mreža te slike nauči gotovo savršeno uz jako male pogreške.

Sustav	rel	rms
Laina et al. 2016	0.127	0.573
Eigen et al. 2014	0.215	0.907
ResNet-50 + Up-projection, 10 slika	0.067	0.246
ResNet-50 + Up-projection + $\mathcal{L}_2$	0.161	0.661
ResNet-50 + Up-projection + berHu	0.147	0.622

Slika 5.2 prikazuje gubitak prilikom treniranja modela. Zbog korištenja stohastičkog gradijentnog spusta funkcija gubitka dosta oscilira. Nakon sedme epohe prosječan gubitak se ne mijenja puno. U šestoj epohi stopa učenja umanjena je 10 puta, što se

vidi na slici kao mali skok između šeste i sedme epoha.

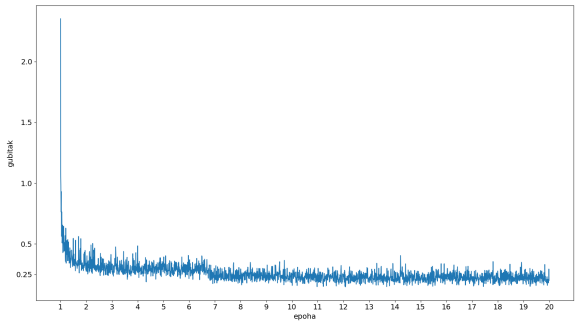

Slika 5.2: Prikaz obrnute huber funkcije gubitka prilikom treniranja kroz 20 epoha nad svakom od mini-grupa za učenje.

Na slici 5.3 grafički su prikazani rezultati dobiveni na skupu podataka za validaciju. U lijevom stupcu prikazane su ulazne slike, u srednjem stupcu prikazane su ispravne vrijednosti, dok su u desnom stupcu prikazani izlazi iz neuronske mreže.

Izlazne dubinske mape imaju jako veliku vizualnu kvalitetu bez daljnjih obrađivanja. Mreža jako dobro prepozna općeniti izgled scene. Rubovi objekata su jako dobro vidljivi, što se najbolje vidi na prvoj slici. Općeniti izgled objekata je također jako kvalitetan, što se vidi na petoj i šestoj slici. Iz prve i druge slike može se primijetiti kako na udaljenijim i visoko teksturiranim predjelima mreža ne daje toliko kvalitetne vizualne rezultate.

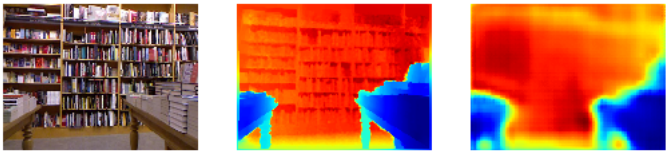

Srednja kvadratna pogreška: 0.432. Srednja apsolutna relativna pogreška: 0.137.

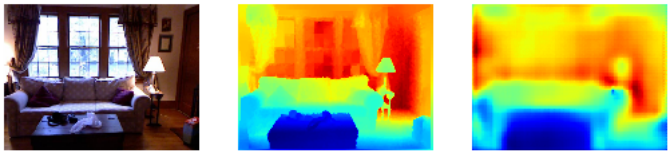

Srednja kvadratna pogreška: 0.228. Srednja apsolutna relativna pogreška: 0.059.

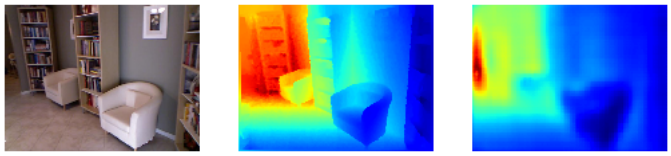

Srednja kvadratna pogreška: 0.363. Srednja apsolutna relativna pogreška: 0.104.

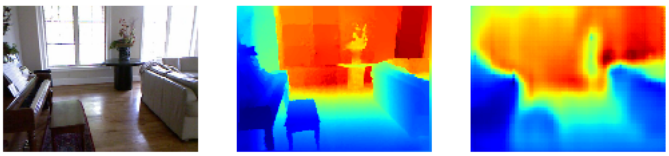

Srednja kvadratna pogreška: 0.536. Srednja apsolutna relativna pogreška: 0.129.

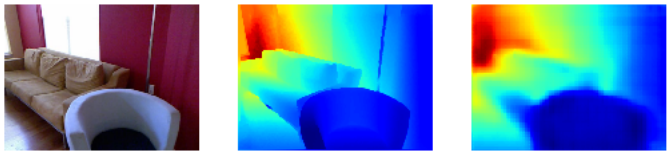

Srednja kvadratna pogreška: 0.228. Srednja apsolutna relativna pogreška: 0.093.

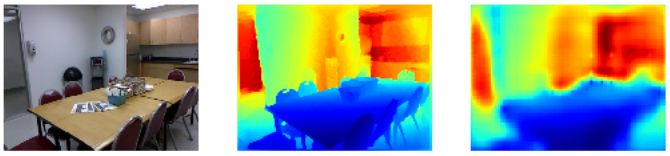

Srednja kvadratna pogreška: 0.448. Srednja apsolutna relativna pogreška: 0.097.

Slika 5.3: Grafički prikaz rezultata predikcije dubine scene na validacijskom skupu podataka. U prvom stupcu su ulazne RGB slike, u drugom su ispravne vrijednosti dubina, a u trećem su predikcije.

6. Zaključak

U radu su opisana osnovna svojstva neuronskih mreža te njihov rad. Opisani su algoritmi gradijentnog spusta i propagacije pogreške unatrag pomoću kojih mreža uči. Objašnjeni su motivi za nastanak konvolucijskih neuronskih mreža, njihov rad i glavne razlike u odnosu na tradicionalne potpuno povezane neuronske mreže. Implementirana je konvolucijska neuronska mreža po uzoru na [5] korištenjem programskog okvira PyTorch.

Zbog jednostavnosti primjene, jednooka predikcija dubine scene je važna alternativa metodama koje iskorištavaju binokularno uparivanje. Nastanak rezidualnih neuronskih mreža omogućio je stvaranje jako dubokih modela koji ostvaruju vrlo zanimljive rezultate u ovom području. No i dalje je ovo jako zahtjevan zadatak za riješiti s velikom preciznošću.

Implementacija modela evaluirana je na *NYU Depth v2* skupu podataka. Model je naučio jako dobro iskorištavati monokularne indicije i postignuti su zadovoljavajući rezultati. Velika prednost je njegova jednostavnost u odnosu na postojeće metode za jednooku predikciju dubine scene, ali i postizanje visoko kvalitetnih rezultata.

Iako model zahtjeva manje podataka za učenje nego [2] i dalje zahtjeva ogromnu količinu podataka. Rezultati i dalje ovise dosta o podacima, pogotovo o broju podataka.

LITERATURA

[1] Antonio Anđelić. Semantička segmentacija slika dubokim konvolucijskim mrežama. Završni rad, 2018.

[2] David Eigen, Christian Puhrsch, i Rob Fergus. Depth map prediction from a single image using a multi-scale deep network. U Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence, i K. Q. Weinberger, urednici, *Advances in Neural Information Processing Systems 27*, stranice 2366–2374. Curran Associates, Inc., 2014. URL http://papers.nips.cc/paper/5539-depth-map-prediction-from-a-single-image-using-a-multi-scale-deep-network.pdf.

[3] Ian Goodfellow, Yoshua Bengio, i Aaron Courville. *Deep Learning*. MIT Press, 2016. http://www.deeplearningbook.org.

[4] Kaiming He, Xiangyu Zhang, Shaoqing Ren, i Jian Sun. Deep residual learning for image recognition. *CoRR*, abs/1512.03385, 2015. URL http://arxiv.org/abs/1512.03385.

[5] Iro Laina, Christian Rupprecht, Vasileios Belagiannis, Federico Tombari, i Nassir Navab. Deeper depth prediction with fully convolutional residual networks. *CoRR*, abs/1606.00373, 2016. URL http://arxiv.org/abs/1606.00373.

[6] Michael Nielsen. Neural networks and deep learning, 2015.

[7] Marko Čupić. Umjetna inteligencija, umjetne neuronske mreže. http://java.zemris.fer.hr/nastava/ui/ann/ann-20180604.pdf.

Konvolucijski modeli za jednooku predikciju dubine scene

Sažetak

Rad opisuje općenito neuronske mreže, a posebno konvolucijske neuronske mreže. Opisan je način učenja neuronske mreže algoritmom gradijentnog spusta. U radu se također opisuju rezidualne neuronske mreže. Programski je implementiran i evaluiran konvolucijski model za jednooku predikciju dubine scene koji se temelji na konkretnoj implementaciji rezidualnih neuronskih mreža, ResNet50. Na kraju su prikazani rezultati.

Ključne riječi: neuronske mreže, konvolucijske neuronske mreže, rezidualne neuronske mreže, ResNet, jednooka predikcija dubine scene

Convolutional Models for Monocular Depth Prediction

Abstract

Paper desribes generally neural networks, especially the convolutional neural networks. The neural network learning method by gradient descent algorithm is described. This paper also also describes residual neuronal networks. Convolutional model for monocular depth prediction that is based on concrete implementation of resiudal neural network, ResNet50, is implemented and evaluated. Lastly, the results are presented.

Keywords: neural networks, convolutional neural networks, residual neural networks, ResNet, monocular depth estimation