

Regresivna nevronska mreža za ocenjevanje vlažnosti tal

Blaž Pongrac¹, Dušan Gleich¹, Peter Planinšič¹

¹Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Slomškovo trg 15, Maribor, Slovenija
E-pošta: blaz.pongrac1@um.si

Regression Neural Network for Soil Moisture Estimation

Over the past few years image categorization using deep learning became very popular, because it can handle large databases and has shown good recognition results. This paper presents the complex valued convolutional network (CV-CNN) for Synthetic Aperture Radar (SAR) soil moisture estimation. The CV-CNN consist in general of a real or complex valued input layer, output layer and one or more hidden layers. Hidden layers represent any combination of convolutional layers, pooling layers, activation functions, and are fully defined within complex valued domain. This paper proposes a deep Convolutional Neural Network (CNN) for soil moisture parameter estimation. A 9 layer convolutional neural network was used, consisting of convolutional, pooling, dropout, fully connected and regression layers. We used 1000 ground measurements for each SAR acquisition using L-band fully polarimetric SAR data. The experimental results were verified using 100 ground points. The accuracy of volumetric moisture was around 13%.

1 Uvod

Radar z umetno odprtino (ang. Synthetic Aperture Radar, SAR) je aktivni senzor, ki lahko zajema podatke neodvisno od vremena, podnevi in ponoči. Zaradi tega lahko SAR slike uporabimo v številnih aplikacijah, od meritev vlažnosti, spremljanja stanja gozdov in ocenjevanja biomase, za aplikacije v kmetijstvu, spremljanje urbanega okolja, v aplikacijah za spremljanju potresov in zemeljskih plazov, itd. SAR je nadvse primeren za klasifikacijo zemeljske površine, zaznavanje tarč na površini zemlje in nadzor ter spremljanje zemeljskih procesov (npr. drsenje, tektonske premike, vlažnost, itd.). Interpretacija slik SAR se zaradi mehanizmov sipanja in pegastega šuma v SAR slikah razlikuje od foto-vizualne analize. Analiza in interpretacija SAR slik sta bili v zadnjih desetletjih deležni obsežnih raziskav.

V zadnjih letih so predlagali uporabo več različnih globokih konvolucijskih nevronske mreže (ang. Convolutional Neural Network, CNN). Obstaja več struktur globokih konvolucijskih mrež oz. modelov, npr. AlexNet [1], VGG-S [2], Places-CNN [3], polno konvolucijski semantično segmentacijski model (ang. Fully Convolutional Semantic Segmentation Model) [4], modeli CNN za

salientno objektno subitiranje (ang. CNN Models for Salient Object Subitizing) [5], Places-CNDS modeli za sekcijsko prepoznavo [6], modeli za določevanja starosti in spola [7], GoogLeNet [8], itd. Vsi, v zadnjih letih uporabljeni modeli, se ukvarjajo s točno določenim problemom, kot je to prekomerno prilagajanje, povezave med vozlišči sosednjih slojev, večja kapaciteta učenja, itd.

CNN s kompleksnimi vrednostmi so že bile uporabljene, in sicer v večih pristopih klasifikacije realnih in kompleksnih problemov [9]-[10]. Avtorji so v [9] predstavili model CNN s kompleksnimi vhodnimi podatki in utežmi. Predlagan kompleksni model je bil posplošitev realnega modela. Ena izmed prvih raziskav CNN s kompleksnimi vrednostmi (ang. Complex Value CNN, CV-CNN) za prepoznavo objektov iz polarimetričnih SAR (Pol-SAR) podatkov je bila predstavljena v [11]. Uporabljena je bila struktura z enim samim konvolucijskim slojem, ki je dala obetavne rezultate. CV-CNN je bila predstavljena v [12], kjer je spust po naklonu (ang. Gradient Descent) v polnosti uporabljen za učenje tega tipa nevronske mreže. Primerjava različnih modelov CNN za realnimi podatki (ang. Real-Valued CNN, RV-CNN) za klasifikacijo slik se je razširila tudi na CV-CNN. Avtorji v [13] so predstavili pristop avtomatske prepoznave tarč s pomočjo CV-CNN. Klasifikacija Pol-SAR podatkov s CV-CNN je bila predstavljena v [14]. Avtorji so v [10] predstavili primerjavo med RV-CNN in CV-CNN.

Pol-SAR sistemi imajo več potenciala pri izboljšanju radarskih zmožnosti opazovanja parametrov zemljinega površja. Lahko rečemo, da je polno polarimetrični SAR obetavno orodje za povečanje natančnosti pridobljenih podatkov v različnih vremenskih pogojih pri določevanju poraščenosti in topografije terena. Opravljenih je bilo tudi več raziskav, ki kažejo na to, da lahko s polarimetričnimi podatki uspešno ocenimo parametre zemljinega površja, kot sta npr. vlažnost in razgibanost [16][17][18].

V tem prispevku je predstavljeno ocenjevanje parametrov zemljine površine s pomočjo polno polarimetričnih SAR podatkov. Vlažnost zemlje je ocenjena z uporabo nevronske mreže s kompleksnimi podatki in utežmi, ki ima realne vhodne podatke, in je učena z dvema učnima množicama, ki sta bili pridobljeni ob dveh različnih letnih časih. Predstavljena sta kompleksna nevronska mreža in regresivni model ocenjevanja parametrov. S pomočjo eksperimentalnih podatkov je prikazana učinkovitost in

točnost predstavljene metode ocenjevanja vlažnosti.

2 Struktura nevronske mreže s kompleksnimi podatki

CNN je predstavljena z več sloji nevronske mreže. Struktura CNN se deli na vhodni sloj, kateremu lahko sledita sloja podvzorčenja in regularizacije, zaključni pa se s polno povezanim slojem. Vhod v CNN je slika, ki jo obdelamo z več siti. Odziv sita pridobimo s konvolucijo - konvolucijski odziv kodira vhodne podatke in določi značilke z zmanjšanjem dimenzionalnosti vhodne slike.

Odzivi sit predstavljajo vhod v nenasičene aktivacijske funkcije, kar lahko drastično pospeši učenje CNN. Največkrat uporabljena aktivacijska funkcija je ReLU, ki jo uporabimo za izločevanje nelinearnih procesov. Aktivacijska funkcija ReLU je bila uporabljena za vsakim konvolucijskim in polno povezanim slojem. Zadnji sloj predlagane konvolucijske mreže uporablja softmax aktivacijsko funkcijo, s katero zagotovimo maksimalno multinominalno logistično regresijo. Izhod iz konvolucijskega sita je po navadi podvzorčen, saj želimo zmanjšati dimenzije značilk, s čimer pa naredimo značilke neodvisne od premikov. Ko uporabimo 2×2 max-pool sloj podvzorčenja, se izhod razdeli v celice dimenzij 2×2 , ki se med seboj ne prekrivajo. V vsaki 2×2 celici ohranimo le najvišjo vrednost, s tem pa smo dimenzijo izhodne slike zmanjšali za faktor 2, detektirane značilke pa so neobčutljive na premik objekta.

Tako kot pri RV-CNN, tudi pri CV-CNN vhod temelji na 2D multikanalnem vhodu, t.i. polju kanalov (ang. channel maps). Največja razlika med RV-CNN in CV-CNN je, da je vsak vhodni kanal predstavljen v kompleksni domeni, v kompleksni domeni pa so tudi skriti sloji, ki so predstavljeni s konvolucijski siti, sloji podvzorčenja in aktivacijskimi funkcijami.

Konvolucijski sloj izvaja konvolucijo med drsečim oknom in kompleksno vhodno delno sliko, kjer le-ta služi kot polje sit. Rezultat je matrika, kjer je vsaka izhodna vrednost seštevek skalarnega produkta kompleksnih vrednosti drsečega okna in vhodne delne slike. Za iskanje več značilk v vhodni delni sliki uporabimo več polj sit. Izhod iz več polj sit lahko označimo tudi kot izhodno polje, ki ga povežemo na sigmoid ali tanh aktivacijske funkcije. V primeru predlagane rešitve je bila uporabljena sigmoid aktivacijska funkcija, s pomočjo katere se ustvari polje značilk. Rezultat konvolucije, ki vključuje izhod prejšnjega skritega sloja, lahko opišemo kot $O_i^{(l+1)} \in \mathfrak{S}^{W_2 \times H_2 \times I}$ in ga lahko izračunamo kot

$$\begin{aligned} O_i^{(l+1)} &= \frac{1}{1 + \exp(-\Re(V_i^{(l+1)}))} \\ &+ j \frac{1}{1 + \exp(-\Im(V_i^{(l+1)}))} \\ V_i^{(l+1)} &= w_{ik}^{(l+1)} \star O_k^{(l)} + b_i^{(l+1)} \end{aligned} \quad (1)$$

kjer je polje sit opisano kot $w_{ik}^{(l)} \in \mathfrak{S}^{F \times F \times K \times I}$, vhodno polje značilk kot $O_i^{(l)} \in \mathfrak{S}^{W_1 \times H_1 \times K}$, odmik pa kot $b_i^{l+1} \in \mathfrak{S}^I$. Spremljivka l predstavlja število trenutnih

slojev, kjer \star predstavlja konvolucijski operator. $V_i^{(l+1)}$ predstavlja uteženo vsoto vhodnih podatkov vse do i -tega izhodnega polja značilkv sloju $l+1$. Konvolucijski sloj je določen s številom značilk I , velikostjo sita $F \times F \times K$, korakov S in dodanih ničel P .

Namen sloja podvzorčenja je, da zmanjšamo dimenzije delne slike. V predstavljeni rešitvi je dosežena prostorska nespremenljivost, kar pomeni, da je predlagana CNN neobčutljiva na manjše spremembe in premike [14]. V večini to dosežemo z max-pool funkcijo. Funkcija podvzorčenja povpreči vrednosti v oknu, max-pool funkcija pa nato izbere najvišjo vrednost, ki se ohrani. Izbrana funkcija povprečenja v kompleksni obliki je bila določena kot

$$O_i^{(l+1)}(x, y) = \underset{u, v=0, \dots, g-1}{\text{ave}} O_i^{(l)}(x \cdot s + u, y \cdot s + v) \quad (2)$$

kjer je g faktor podvzorčenja, s pa korak. (x, y) predstavlja lokacijo značilke na i -tem elementu $O_i^{(l+1)}(x, y)$. Polno povezana plast je namenjena klasifikaciji po izračunanem izhodu iz zadnje konvolucijske plasti in plasti podvzorčenja. V primeru CV-CNN je uporabljenih več polno povezanih svojev, saj je s tem zagotovljena povezava med posameznimi nevroni v prejšnji plasti [14]. Izhod lahko ocenimo kot

$$\begin{aligned} O_i^{(l+1)} &= f(\Re(V_i^{(l+1)})) \\ &+ j f(\Im(V_i^{(l+1)})) \\ V_i^{(l+1)} &= \sum_{k=1}^K \omega_{ik}^{(l+1)} \cdot O_k^{(l)} + b_i^{(l+1)} \end{aligned} \quad (3)$$

kjer K predstavlja število nevronov v l -ti plasti. Izhodna plast je predstavljena kot $1 \times C$ vektor, kjer nam C predstavlja število razredov in hkrati dolžino izhodnega vektorja. Izhodni vektor je kompleksen, zato moramo v prejšnjem izrazu zamenjati skalar 1 s kompleksno vrednostjo $(1 + 1j)$. Delna slika pripada tistemu razredu, od katerega je razdalja v izhodnem vektorju najkrajša.

3 Globoka regresivna mreža za detekcijo vlažnosti tal

V predstavljeni metodi je uporabljen regresivni model z CNN za ocenjevanje parametrov. Sestavljen je iz vhodnega sloja, ki mu sledi kopica skritih slojev. Posamezni skriti sloj je sestavljen iz konvolucijskega sloja, podvzorčenja in polno povezanega sloja. Zadnji sloji v regresivni CNN določijo velikost in tip izhodnega podatka. Kadar imamo opravka z regresivnim problemom, moramo na koncu strukture nevronske mreže pred regresivni sloj postaviti polno povezan sloj. Regresivni sloj izračuna srednji kvadratični pogrešek (ang. Mean Squared Error, MSE), ki jo določimo kot $MSE = \sum_{i=1}^R \frac{1}{R} (t_i - \Theta_i)^2$, kjer je R število odzivov, t_i je ciljni izhod, in Θ_i je napovedan izhod za odziv i . V izhodnem vektorju velikosti n vsaka vrednost predstavlja ustrezeni element Θ in je odvisna od reda porazdelitve verjetnosti.

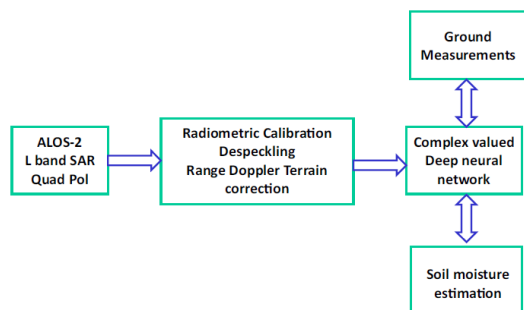
Na izhodih konvolucijskih slojev je bila izvedena normalizacijska funkcija, s katero smo skrajšali čas učenja.

ReLU plast je bila uporabljena za dodajanje nelinearnosti in za zmanjšanje problema z zmanjšanjem gradienta. ReLU in normalizacijska funkcija sta prav tako pripomogla k zmanjšanju števila aktiviranih nevronov med interferenco. Za zmanjšanje dimenzionalnosti je bilo uporabljeno podvzorčenje s povprečenjem in faktorjem 2 ter korakom 2 piksla. Prvi skriti nivo v CNN je običajno konvolucijski sloj in služi za izločanje značilk. Sito velikosti 7×7 je bilo uporabljeno v vseh skritih slojih, število sit pa je bilo med 4 in 32. Pri izločanju značilk v optičnih slikah je po navadi uporabljeno sito 3×3 . Z uporabo sita velikosti 7×7 so bile zajete večje prostorske informacije, kar je izboljšalo prepoznavo za 0,5%. S tem smo tudi zmanjšali število parametrov CNN, hkrati pa ohranili enako potencialno površino detekcije. Za zadnjim konvolucijskim slojem je uporabljen osipni sloj z vrednostjo 0,1, s katerim preprečimo prekomerno prilagajanje.

Za učenje CNN sta bili uporabljeni metoda vzratnega razširjanja in stohastični gradientni spust ob naslednji konfiguraciji učenja: velikost mini-batch je bila 22 z 30 epohami. Konfiguracija hitrosti učenja igra pomembno vlogo. Pri učenju predlagane CNN je bila hitrost učenja konfigurirana z: hitrost inicializacije je bila 10^{-5} , faktor hitrosti osipanja je bil 0,01, delna hitrost načrtovanja s periodo osipanja pa 10. Učenje je potekalo s pomočjo grafičnega procesorja oz. grafične kartice Geforce GTX 1080 proizvajalca Nvidia. Najboljši rezultati so bili z delnimi slikami velikosti 31×31 , kjer je bil koren povprečne kvadratne napake RMSE (ang. Root Mean Square Error) okrog 0,55 pri učenju in 0,48 pri validaciji.

3.1 Obdelava SAR podatkov v L-pasu


Blokovna shema obdelave podatkov je prikazana na sliki 1. SAR sliki, pridobljeni z ALOS-2 v decembru 2018 in juniju 2021, sta bili obdelani. Sliki sta bili radiometrično kalibrirani, odstranjene so bile pege, izvedena je bila Doppler-jeva korekcija terena in izluščene to bile T3 matrike. T3 matrike so bile uporabljene v procesu globokega učenja nevronske mreže, s pomočjo katere smo želeli določiti vlažnost zemlje. Da smo lahko določili vlažnost, smo morali izluščiti volumetrično sipanje na izbranem področju.




Slika 1: Potek obdelave podatkov za ocenjevanje vlažnosti iz SAR podatkov, pridobljenih z radarjem v L frekvenčnem pasu.

4 Eksperimentalni rezultati

SAR slike so bile zajete nad mestom Maribor, Slovenija. Cilj eksperimenta je bil oceniti vlažnost zemlje na SAR sliki dimenzije 7000×4000 slikovnih točk, ko to prikazuje slika 2. Predstavljena metoda ocenjevanja vlažnosti zemlje je bila uporabljena s SAR slikami, zajetimi v letu 2018 in 2021. Na sliki 3 je ocenjena volumetrična vlažnost za SAR sliko, zajeto v letu 2018, na sliki 4 pa je ocenjena volumetrična vlažnost za SAR sliko istega terena, zajeto v letu 2021. Slika 5 prikazuje primerjavo med ocenjenima vrednostima s pomočjo predlagane metode in med izmerjeno vrednostjo vlažnosti na zemeljski površini. RMSE med izmerjeno in ocenjenima volumetričnima vlažnostima v letu 2018 in 2021 znaša 10,4% in 13,4%. Uporabljenih je bilo 1000 podatkov za učenje nevronske mreže in 100 podatkov za verificiranje. Natančnost ocenjene vlažnosti zemlje je za obe učni množici (SAR slike iz leta 2018 in SAR slike iz leta 2021) podobna. Natančnost za učno množico iz leta 2018 znaša 13,1%, za učno množico iz leta 2021 pa 10,4%.




Slika 2: SAR slika pridobljena v letu 2018 z ALOS-2 predstavljena s Pauli RGB.



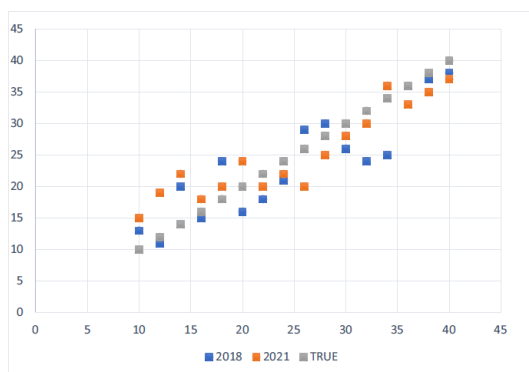
Slika 3: S pomočjo predlagane metode in SAR slike zajete v letu 2018 ocenjena volumetrična vlažnost zemlje.

5 Sklep

V tem prispevku je pridelana uporaba globoke konvolucijske nevronske mreže za ocenjevanje vlažnosti zemlje



Slika 4: S pomočjo predlagane metode in SAR sliko zajeto v letu 2021 ocenjena volumetrična vlažnost zemlje.



Slika 5: Primerjava med ocenjeno volumetrično vlažnostjo za podatke pridobljene v letu 2018 in 2021 z meritvijo na zemeljski površini.

s pomočjo podatkov, pridobljenih iz SAR, ki deluje v L frekvenčnem pasu. Predstavljena nevronska mreža je sestavljena iz devet konvolucijskih slojev, ReLU in aktivacijskih slojev. Zadnji je regresivni sloj, ki je uporabljen za zmanjšanje dimenzij podatkov. Eksperimentalni rezultati so pokazali, da se je v tem prispevku predstavljena metoda zmožna približati realnim vrednostim vlažnosti zemlje, kjer pride do volumetričnega sipanja. S pomočjo podatkov iz različnih časovnih obdobj lahko sklepamo, da predstavljena metoda dobro oceni vlažnost z vegetacijo poraščenih območij. S pomočjo primerjave eksperimentalnih rezultatov z meritvijo vlažnosti na zemeljskem površju, vidimo, da s predlagano metodo lahko ocenimo vlažnost zemlje do okrog 13% natančno. S tem smo pokazali, da lahko s pomočjo radarja, ki deluje v L frekvenčnem pasu, ocenimo vlažnost tal.

Literatura

[1] A. Krizhevsky, I. Sutskever, and G. E. Hinton: ImageNet classification with deep convolutional neural networks, *Advances in neural information processing systems*, pp. 1097–1105, 2012

[2] K. Chatfield, K. Simonyan, A. Vedaldi, and A. Zisserman: Return of the devil in the details: Delving deep into convolutional nets, *arXiv preprint arXiv:1405.3531*, 2014

[3] B. Zhou, A. Lapedriza, J. Xiao, A. Torralba, and A. Oliva: Learning deep features for scene recognition using places database, *Advances in Neural Information Processing Systems*, pp. 487–495, 2014

[4] E. Shelhamer, J. Long, and T. Darrell: Fully convolutional networks for semantic segmentation, *arXiv preprint arXiv:1605.06211*, 2015

[5] J. Z. at all: Salient object subitizing, in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 4045–4054

[6] L. Wang, C.-Y. Lee, Z. Tu, and S. Lazebnik: Target classification using the deep convolutional networks for sar images, *arXiv preprint arXiv:1505.02496*, 2015

[7] G. Levi and T. Hassner: Age and gender classification using convolutional neural networks, in *2015 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2015, pp. 34–42

[8] P. C. Z. Ge, C. Mccool: Content specific feature learning for finegrained plant classification, in *Working notes of CLEF 2015 con*, 2015

[9] N. Guberman: On complex valued convolutional neural networks, *CoRR*, vol. abs/1602.09046, 2016. [Online]. Available: <http://arxiv.org/abs/1602.09046>

[10] H. G. Zimmermann, A. Minin, and V. Kusherbaeva: Comparison of the complex valued and real valued neural networks trained with gradient descent and random search algorithms, in *European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning. Bruges (Belgium)*, 2011

[11] R. Haensch and O. Hellwich: Complex-valued convolutional neural networks for object detection in polsar data, in *8th European Conference on Synthetic Aperture Radar*, June 2010, pp. 1–4

[12] C. A. Popa: Complex-valued convolutional neural networks for realvalued image classification, in *2017 International Joint Conference on Neural Networks (IJCNN)*, May 2017, pp. 816–822

[13] M. Wilmanski, C. Kreucher, and A. Hero: Complex input convolutional neural networks for wide angle sar atr, in *2016 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, Dec 2016, pp. 1037–1041

[14] Z. Zhang, H. Wang, F. Xu, and Y. Q. Jin: Complex-valued convolutional neural network and its application in polarimetric sar image classification, *IEEE Transactions on Geoscience and Remote Sensing*, pp. 1–12, 2017

[15] A. K. Fung, *Microwave Scattering and Emission Models and their Applications.*, Boston: Artech House, 1994

[16] N. Baghdadi, P. Dubois-Fernandez, X. Dupuis, and M. Zribi: Sensitivity of main polarimetric parameters of multi-frequency polarimetric sar data to soil moisture and surface roughness over bare agricultural soils, *IEEE Geoscience and Remote Sensing Letters*, vol. 10, no. 4, pp. 731–735, 2013

[17] I. Hajnsek, E. Pottier, and S. Cloude: Inversion of surface parameters from polarimetric sar, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 41, no. 4, pp. 727–744, 2003

[18] N. Pierdicca, L. Pulvirenti, and G. Pace: A prototype software package to retrieve soil moisture from sentinel-1 data by using a bayesian multitemporal algorithm, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, no. 1, pp. 153–166, 2014