

Duomenų augmentacijos naudojant generatyvinį besivaržantį tinklą saulės kolektorių segmentavimui iš nuotolinio stebėjimo vaizdų

Justinas Lekavičius

Vilniaus universitetas, Matematikos ir informatikos fakultetas,
Naugarduko g. 24, LT-03225 Vilnius
me@justinaslekavicius.com

Santrauka. Populiarijant saulės baterijų naudojimui didėja ir duomenų poreikis planavimui bei valdymui. Deja, šie duomenys sunkiai prieinami arba neegzistuoja, o resursai, skirti segmentavimo modelių mokymui, yra apriboti ir plėtimui reikia daug išteklių. Šiame darbe panaudotas pix2pix generatyvinis besivaržantis tinklas naujų nuotraukų generavimui iš turimų duomenų, padidinant mokymo išteklių DeepLabV3 segmentavimo modeliui kiekį. Naudojant žinių perkėlimą, modelio adaptavimą bei 60% sugeneruotų nuotolinio stebėjimo nuotraukų kaip papildomus mokymo duomenis, padidintas aptiktų kolektorių kiekis, modelio tikslumas (angl. accuracy) padidintas 0.78%, taiklumas (angl. precision) – 3.41%, jautrumas (angl. sensitivity) – 2.49%, F1 metrika – 2.71%, IoU (intersect over union) metrika – 3.19%, o nuostoliai (angl. loss) sumažėjo 0.0282.

Raktiniai žodžiai: gilusis mokymasis, saulės kolektoriai, semantinis segmentavimas, duomenų augmentacijos, generatyviniai besivaržantys tinklai, nuotolinis stebėjimas, žinių perkėlimas.

1 Įvadas

Atsinaujinantys ištekliai, ypač saulės energija išsiskiria savo švarios ir prieinamos elektros gamybos galimybėmis. Saulės baterijų diegimo augimas taip pat kelia duomenų, tokių kaip tikslių kolektorių vietovių, tipų ir specifikacijų, paklausą efektyviam planavimui ir valdymui [1]. Visgi šie duomenys riboti, o jų trūkumui mažinti reikia laiko ir pastangų. Nuotolinio stebėjimo ir giliojo mokymosi derinys išskyla kaip sprendimas, naudojant palydovų vaizdus saulės kolektorių aptikimui ir analizei. Semantinis segmentavimas, naudojant konvoliucinius neuroninius tinklus, tokius kaip FCN [2] ir U-Net [3], leidžia tiksliai identifikuoti saulės kolektorius. Be to, pažangesni mode-

liai, tokie kaip RU-Net [4], ir hierarchiniai metodai, naudojant EfficientNet-B5 tinklą [5], didina aptikimo tikslumą. Nepaisant pažangos, kyla iššūkis dėl sužymėtų duomenų stokos ir yra poreikis įvairesniems duomenų rinkiniams efektyviam modeliui mokymui [6]. Duomenų augmentacija tampa ypač svarbi, o klasikinės augmentacijos bei generatyvinių besivaržančių tinklai [7] atlieka svarbų vaidmenį didinant duomenų kiekį. Šie tinklai, ypač pix2pix [8], suteikia galimybę generuoti tikroviškus vaizdus iš jau turimų duomenų, papildant esamus duomenų rinkinius. Taip gerinamas modelio našumas, ypač palyginus su klasikinėmis augmentacijomis (pasukimais, pakreipimais, ir t.t.), kurios nesukuria visiškai naujų duomenų. Šio tyrimo tikslas – pagerinti saulės kolektorių segmentavimui naudojamo DeepLabV3 modelio našumą naudojant generatyvinį besivaržantį tinklą duomenų augmentacijai. Tyrimo metu DeepLabV3 modeliui naudotas žinių perkėlimas ir modelio adaptavimas o duomenų stokos ir rankinio žymėjimo problema spręsta kuriant naujus duomenis pritaikant pix2pix generatyvinį besivaržantį tinklą.

2 Duomenys ir metodai

Semantinio segmentavimo modelio ir generatyvinio besivaržančio tinklo mokymui naudoti penki skirtingi palydovų nuotraukų su saulės kolektoriais ir jų semantinio segmentavimo kaukių duomenų rinkiniai. Šie rinkiniai yra skirtingų atvaizdo rezoliucijų (1024x1024, 400x400, 256x256), formatų (BMP, PNG) bei erdviųjų rezoliucijų (0.8m, 0.3m, 0.2m, 0.1m). Kiekvienos erdvinės rezoliucijos duomenis sudarė 640 nuotraukų ir jų segmentavimo kaukių porų – iš viso 2560 porų. Siekiant išspręsti atvaizdo ir erdviųjų rezoliucijų skirtumų problemą bei išvengti skalės neatitikimų, atliktas nuotraukų ir jų kaukių dydžių perskaičiavimas, taikantis į bendrines 512x512 atvaizdo ir 0.1m erdvinę rezoliucijas. Nuotraukos, esančios mažesnės negu nustatyta bendroji erdvinė rezoliucija, padidintos, o tada apkarpytos į 512x512 rezoliuciją, atsižvelgiant į intereso regionus, t.y., saulės kolektorių lokacijas nuotraukose, siekiant išvengti informacijos praradimo. Pix2pix hiperparametrai adaptuoti tinkamam segmentavimo kaukės (tipo A) pavertimui į nuotolinio stebėjimo nuotrauką (tipą B). Segmentavimo modelis mokytas pritaikant žinių perkėlimo techniką, t.y., mokymo metu modelio parametrus atnaujinant pasitelkus anksčiau išmokyto kito modelio žinias, siekiant geresnio modelio tikslumo. Modelis vėliau adaptuotas iš naujo mokant tik paskutinį jo sluoksnį „užšaldant“ kitus sluoksnius, t.y., nekeičiant jų parametrų, sie-

kiant išlaikyti žinių perkėlimo naudą. Tuomet, remiantis paskutinio sluoksnio naujais parametrais, „atšaldyti“ ir mokyti visi likę modelio sluoksniai. Taip segmentavimo modelis tiksliau adaptuotas saulės kolektorių segmentavimo užduočiai.

3 Rezultatai

Modeliai mokyti naudojant 2560 nuotraukų-kaukių poras. 80% duomenų naudota modelio mokymui, o po 10% naudota validavimui ir testavimui. Duomenys, naudoti modelio mokymui, taip pat panaudoti ir pix2pix modelio mokymui – iš tų pačių duomenų sugeneruota 2048 naujų nuotraukų-kaukių porų. DeepLabV3 segmentavimo modelis mokytas šešių eksperimentų metu, sukurti šeši skirtingi modeliai. Modelis No_a mokytas su pradinio duomenų rinkiniu, o modelis Basic_a mokytas pradiniam duomenų rinkiniui papildomai pritaikant klasikinės duomenų augmentacijas. Siekiant patikrinti papildomų duomenų naudą, modelis Gan25 mokytas praplečiant mokymo duomenis panaudojant 25% papildomų sugeneruotų nuotraukų-kaukių porų, o modelis Gan25a mokytas papildomai pritaikant klasikinės augmentacijas. Modelis Gan60 mokytas praplečiant duomenų rinkinį optimaliu papildomų sugeneruotų duomenų kiekiu, o modelis Gan60a mokytas pritaikant papildomas klasikinės augmentacijas. Atlikus jautrumo analizę, t.y., mokant segmentavimo modelį vis pridėdant po 10% sugeneruotų nuotraukų-kaukių porų nustatyta, kad naudojant 60% visų šių naujai sugeneruotų duomenų išgautas didžiausias modelio tikslumas, todėl 1228 nuotraukų-kaukių porų naudota kaip papildomi duomenys jau egzistuojančioms 2048 poroms. Eksperimentų metu mokyty modelių testavimo rezultatai pateikti 1 lentelėje. Lyginant su modeliu No_a, mokytu naudojant pradinį duomenų rinkinį, modelio Gan60 vidutinis pikselių tikslumas (angl. pixel accuracy) padidėjo 0.78%, taiklumas (angl. precision) – 3.41%, jautrumas (angl. sensitivity) – 2.49%, F1 metrika – 2.71%, IoU (angl. intersect over union) metrika – 3.19%, o nuostolių (angl. loss) funkcijos vertė sumažėjo 0.0282. Svarbiausia metrika – IoU, indikuojančios modelio tikslumą aptinkant saulės kolektorius nuotolinio stebėjimo nuotraukose lyginant su segmentavimo kauke. Taip pat padidėjo bendras gerai arba prastai aptiktų saulės kolektorių nuotolinio stebėjimo atvaizduose kiekis, o neaptiktų – sumažėjo.

1 lentelė. Mokyty modelių testavimo rezultatai, pritaikant žinių perkėlimą ir adaptavimą.

Eksperimentas (modelis)	Vid. tiksl. (%)	Vid. taikl. (%)	Vid. jautr. (%)	Vid. F1 (%)	Vid. IoU (%)	Vid. Nuost.	Aptikti saulės kolektoriai (IoU)		
							Gerai ≥ 0.5	Prastai < 0.5	Nėra = 0
No_a	97.89	86.72	85.62	85.25	80.13	0.0650	229	12	15
Basic_a	97.88	89.63	86.51	86.50	81.32	0.0547	235	13	8
Gan25	98.09	89.11	85.94	85.71	80.42	0.0586	229	16	11
Gan25a	97.91	88.84	87.25	87.08	81.41	0.0550	238	8	10
Gan60	98.67	90.13	88.81	87.96	83.32	0.0368	237	11	8
Gan60a	98.04	89.82	87.69	87.77	82.90	0.0611	238	9	9

4 Išvados

Žinių perkėlimas, modelio adaptavimo technikos bei duomenų augmentacijos naudojant generatyvinį besivaržantį tinklą turi, palyginus su klasikinių augmentacijų naudojimu, didesnę naudą semantinio segmentavimo modelio našumui. Padidintas aptiktų saulės kolektorių kiekis bei aptikimo tikslumas, taip pat išvengta rankinio papildomų duomenų žymėjimo turint ribotą kiekį duomenų. Skirtingi duomenų rinkiniai turi būti suvienodinti į bendrą erdvinę rezoliuciją bei vaizdo raišką, siekiant pastovumo modelio mokymo metu, minimalaus informacijos praradimo ir skalės neatitikimo problemos išvengimo. Padidinus mokymo duomenų kiekį naudojant 60% sugeneruotų nuotolinio stebėjimo vaizdų, išmokytas segmentavimo modelis pademonstravo geresnes tikslumo, taiklumo, jautrumo, F1 ir IoU metrikas.

Literatūra

- [1] F. M. Guangul, G. T. Chala, "Solar Energy as Renewable Energy Source: SWOT Analysis," in 2019 4th MEC International Conference on Big Data and Smart City (ICBDSC), Jan. 2019, pp. 1–5. doi: 10.1109/ICBDSC.2019.8645580.
- [2] J. Long, E. Shelhamer, and T. Darrell, "Fully Convolutional Networks for Semantic Segmentation." arXiv, Mar. 08, 2015. <http://arxiv.org/abs/1411.4038>
- [3] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation." arXiv, May 18, 2015. <http://arxiv.org/abs/1505.04597>
- [4] L. Li and E. Lau, "RU-Net: Solar Panel Detection From Remote Sensing Image," in 2022 IEEE Green Energy and Smart System Systems (IGESSC), Long Beach, CA, USA: IEEE, Nov. 2022, pp. 1–6. doi: 10.1109/IGESSC55810.2022.9955325.

- [5] F. Ge, G. Wang, G. He, D. Zhou, R. Yin, and L. Tong, "A Hierarchical Information Extraction Method for Large-Scale Centralized Photovoltaic Power Plants Based on Multi-Source Remote Sensing Images," *Remote Sensing*, vol. 14, no. 17, Art. no. 17, Jan. 2022, doi: 10.3390/rs14174211.
- [6] X. Sun, B. Wang, Z. Wang, H. Li, H. Li, and K. Fu, "Research Progress on Few-Shot Learning for Remote Sensing Image Interpretation," *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing*, vol. 14, pp. 2387–2402, 2021, doi: 10.1109/JSTARS.2021.3052869.
- [7] I. J. Goodfellow *et al.*, "Generative Adversarial Networks." arXiv, Jun. 10, 2014. doi: 10.48550/arXiv.1406.2661.
- [8] P. Isola, J.-Y. Zhu, T. Zhou, and A. A. Efros, "Image-to-Image Translation with Conditional Adversarial Networks." arXiv, Nov. 26, 2018. <http://arxiv.org/abs/1611.07004>