

Borut Žalik^{1*}, Niko Lukač¹, Domen Mongus¹

Algoritmi nad velikimi količinami podatkov LiDAR

POVZETEK

V članku predstavimo postopke obdelave velikih količin nestrukturiranih geometrijskih podatkov, pridobljenih s prebirkami LiDAR. Najprej opišemo postopke klasifikacije točk LiDAR v točke, ki ležijo na Zemljinem površju. Opravimo kratek pregled obstoječih metod nato pa na kratko predstavimo našo metodo, temelječo na konceptih matematične morfologije. V nadaljevanju predstavimo zanimivo aplikacijo klasificiranih podatkov LiDAR za določitev sončevega potenciala streh v urbanih področjih. Podamo ključne parametre metode in predstavimo podatke za določitev sončevega potenciala in pridobljene električne energije iz treh različnih tipov celic za občino Beltince.

Ključne besede: računalništvo, daljinsko zaznavanje, LiDAR, klasifikacija.

1. Uvod

Zajemanje podatkov o površju Zemlje je od nekdaj vznemirjalo človeštvo, saj je temelj za naše bivanje v okolju. Ključen podatek pri opisovanju površja je položaj točk v ustreznem koordinatnem sistemu, med katerimi izmerimo še kote in razdalje. Tehnologije zajemanja in opisovanja točk na zemeljskem površju so se seveda spreminjale. Najzgodnejši postopki izpred nekaj 1000 let so uporabljali le količek in vrstico, kasneje so jih zamenjali različni instrumenti. Ena izmed najprikljubljenejših tehnologij današnjega časa je tehnologija LiDAR (Light Detection And Ranging) [1]. Gre za tako imenovano aktivno tehnologijo daljinskega zaznavanja, ki temelji na merjenju razdalje od naprave do objekta z lasersko svetlobo. Ker se svetloba od objektov na površju odbija, nekaj žarkov doseže tudi tla v gosti vegetaciji. Za zajem zemeljskega površja pritrdijo merilnike LiDAR na letalo ali helikopter, naprava pa zatem odbere tudi do 200.000 točk v sekund in, odvisno od višine in hitrosti leta, doseže gostoto nekaj 10 točk na kvadratni meter. Rezultat je ogromna količina nestrukturiranih podatkov (3D točk s prirejenimi parametri, kot so intenziteta odboja, številka odboja, čas zajema), iz katerih želimo povsem samodejno z računalniškimi algoritmi pridobiti uporabne podatke za nadaljnje obdelave. Učinkoviti algoritmi za obdelavo takšnih podatkov danes predstavljajo glavni raziskovalni izziv z množico aplikacij [2, 3]. Osnovni problem opišemo z lahkoto. Naj bo P množica n točk p_i , $0 < i < n$, pridobljenih iz prebirk LiDAR. Vsako točko p_i želimo uvrstiti v eno izmed podmnožic, ki pripadajo terenu, objektom na terenu (na primer hiše),

vegetaciji (nizki ali visoki vegetaciji) ali šumu v podatkih. Postopku pravimo klasifikacija. V prispevku bomo predstavili rezultate lastnih algoritmov klasifikacije, osredotočili pa se bomo na klasifikacijo terena. Kot primer uporabe klasificiranih podatkov LiDAR bomo pokazali uporabo podatkov LiDAR za izračun fotovoltaičnega potenciala streh občine Beltinci.

Članek je razdeljen v štiri poglavja. V poglavju 2 predstavimo algoritem za določanje točk terena, v tretjem poglavju opišemo aplikacijo, ki na temelju klasificiranih podatkov LiDAR izračuna fotovoltaični potencial streh objektov, v četrtem poglavju pa povzamemo članek.

2. Klasifikacija točk terena iz oblaka točk LiDAR

Klasifikacija točk terena velja za enega izmed temeljnih problemov obdelave podatkov LiDAR in je predmet številnih raziskav od samega začetka razvoja tehnologije [4]. Čeprav vse poznane metode temeljijo na dejstvo, da so točke terena nižje od točk objektov nad njim, se specifične posamičnih pristopov med seboj pomembno razlikujejo. Poznane metode, imenovane tudi metode filtriranja podatkov LiDAR, v grobem delimo na [5,6]:

- napovedovalne metode filtriranja, ki se zanašajo na grobo aproksimativno površje, na osnovi katerega izvedejo linearno napovedovanje,
- metode, ki temeljijo na ocenitvi naklona in izhajajo iz predpostavke, da je naklon točk objektov do okoliškega terena občutno večji, kot je naklon med samimi točkami terena ter
- metode matematične morfologije, ki točke LiDAR najprej razporedijo v mrežo enako velikih celic, nad to mrežo pa izvajajo postopke računalniškega vida razvite za obdelavo slik.

V nadaljevanju vsak pristop nekoliko podrobneje predstavimo.

¹Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Laboratorij za geometrijsko modeliranje in algoritme multimedijev, / Smetanova 17, 2000 Maribor, Slovenija

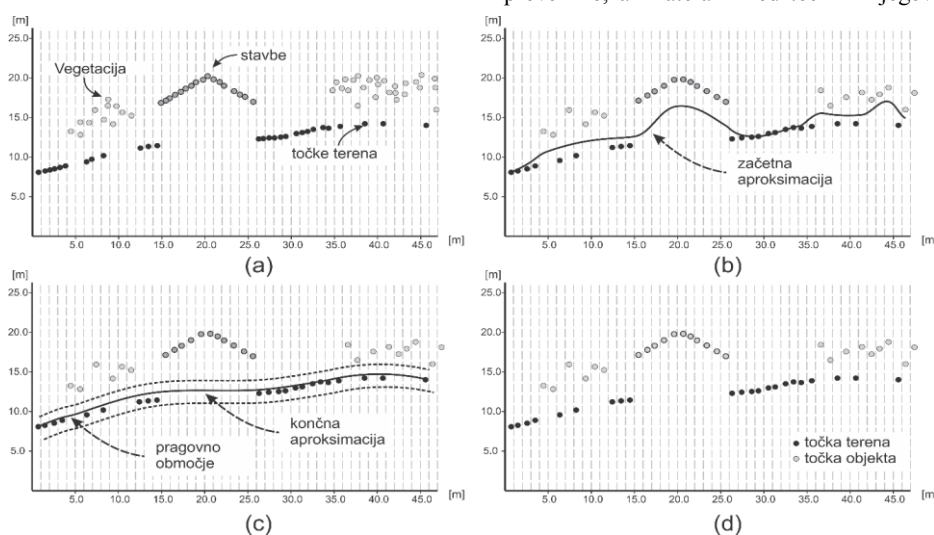
E-naslovi: borut.zalik@um.si; niko.lukac@uni-mb.si; domen.mongus@uni-mb.si

*Avtor za korespondenco

2.1. Napovedovalne metode filtriranja podatkov LiDAR

Osnovna ideja, na kateri temeljijo napovedovalne metode filtriranja podatkov LiDAR, je bila predstavljena v [7] in jo povzema slika 1.

Prvi korak filtriranja z linearnim napovedovanjem predstavlja izračun aproksimativne funkcije, ki daje grobo oceno oblike terena. V ta namen so avtorji v začetku predlagali uporabo linearne aproksimacije z metodo uteženih najmanjših kvadratov. V prvi iteraciji določimo enake utežne vrednosti vsem vhodne točke LiDAR, skozi nadaljnje iteracije pa jih posodabljam z linearno utežno funkcijo. Utežna funkcija sledi predpostavki, da točke nad aproksimativnim površjem pripadajo objektom in jim zato zmanjša utežne vrednosti, medtem ko utežne vrednost točkam pod aproksimativnim površjem poveča. Točkam, katerih višinske razlike so nad vnaprej določeno pragovno vrednostjo, določi utežno vrednost 0, s čimer jih izloči iz nadaljnjega postopka. S postopkom zaključimo, ko sistem preide v stabilno stanje in se utežne vrednosti točk ne spreminjajo več oziroma ko dosežemo vnaprej določenem številu iteracij.



Slika 1. Filtriranje podatkov LiDAR na osnovi linearnega napovedovanja, kjer (a) vhodnim podatkom LiDAR najprej določimo (b) začetni približek terena ter izvedemo (c) pragovno filtriranje, s katerim izločimo točke, ki ne pripadajo terenu. Točkam nato posodobimo utežne vrednosti. Z iterativnim ponavljanjem teh dveh korakov dosežemo (d) klasifikacijo točk terena.

Očitno je, da je natančnost tega pristopa v veliki meri odvisna od izbrane pragovne vrednosti in uspešnosti prilagajanja utežnih vrednosti točk. Avtorja v svoje kasnejšem delu podrobneje analizirata številne definicije utežnih funkcij [8] in pri tem pokažeta, da se optimalna pragovna vrednost spreminja glede na število iteracij. Kot rešitev predlagata vektor pragovnih vrednosti. Vseeno pa sorodna dela izpostavlja težave metode pri klasifikaciji točk terena s spremenljivim naklonom. Razgibani tereni namreč zahtevajo dinamično prilagajanje utežnih funkcij. Lee in Younan [9] zato predlagata prilagodljivo filtriranje normaliziranih višinskih razlik, kjer uvedeta številne prilagoditvene parametre, na primer parameter faktor zakasnitve in stopnja filtriranja. Čeprav tako občutno izboljšata natančnost pristopa predvsem v najzahtevnejših primerih, tudi ta metoda ni zmožna odpraviti pglavitnih pomanjkljivosti pristopov, ki temeljijo na grobi aproksimaciji površja. Ker takšna

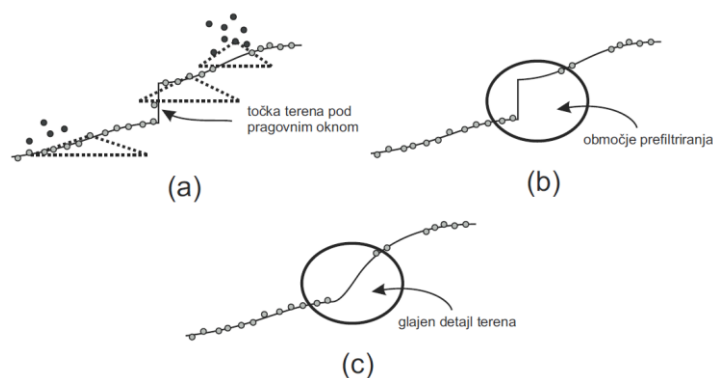
aproximacija daje zelo zglajeno oceno površja, ti pristopi pogosto izločijo detajle terena (na primer ostre robove, prepade ter nasipe) in pomotoma ohranijo majhne in nizke objekte (na primer nizko vegetacija, ograje in avtomobile) [4,5,6].

2.2. Metode filtriranja podatkov LiDAR glede na naklon

Metode, ki so zmožne odpraviti nekatere pomanjkljivosti pristopov z linearnim napovedovanjem (vendar ne vseh), temeljijo na oceni naklon med točkami in njihovo okolico. Enega izmed prvih takšnih pristopov je predlagal Vosselman [10]- Izhajal je iz predpostavke, da se naklon terena ne dvigne nad določeno pragovno vrednost. Takšna predpostavka daje možnost pragovnega filtriranja točk glede na gradient, ki ga tvori s svojo sosesčino. V ta namen je predlagal pragovno funkcijo v obliki stožca, ki ga določa polmer osnovnega kroga v ravnini xy ter višina glede na koordinato z . Hitro lahko opazimo, da polmer kroga določa preiskovalno okolico, višina pri danem polmeru pa pragovno vrednost naklona. Postopek filtriranja nato izvedemo tako, da vrh stožca premaknemo v dane točke ter preverimo, ali katera izmed točk iz njegove okolice leži pod

njim. Če pod stožcem najdemo eno ali več točk iz okolice, potem dano točko označimo kot točko objekta in jo izločimo. Kadar pa pod stožcem ne leži nobena točka, lahko dano točko označimo kot del terena (glej sliko 2a).

Uspešnost tega pristopa je v prvi vrsti odvisna od pravilno določenih vrednosti naklona, oziroma višine stožca in njegovega polmera. Ker osnovna različica metode predvideva konstanten naklona, tudi ta metoda ni primerna za obdelavo razgibanih terenov s spremenljivim naklonom. Še zlasti kadar teren vsebuje nezvezne predele, podana definicija pragovne funkcije pogosto povzroči njihovo prefiltriranje in vodi do zglajenega digitalnega modela reliefa, kot to prikazuje slika 2.




Slika 2. Filtriranje podatkov LiDAR glede na naklon, kjer je **(a)** pragovna funkcija določena v obliki stožca premeščenege v točko, ki jo trenutno filtriramo. Dano točko označimo kot del terena, kadar se pod stožcem ne nahaja nobena točka iz okolice. V nasprotnem primeru točko označimo kot del objekta in jo izločimo. Takšen pristop vodi do **(b)** prefiltriranja nezveznih predelov terena in posledično **(c)** zglajenega digitalnega modela reliefa.

Eden izmed prvih pristopov k odpravi te pomanjkljivosti je predstavil Sithole [11]. V ta namen je podrobneje analiziral več tehnik ocenitve lokalnega naklona terena, iz katerih lahko izpeljemo učinkovitejšo definicijo pragovne funkcije. Čeprav je tako uspel občutno izboljšati odpornost filtra na lokalne variacije terena, tega ni uspel povsem odpraviti. Zaradi simetrične definicije pragovne funkcije predlagani pristop še vedno ni zmožen uspešno filtrirati nezveznih in nesimetričnih predelov terena. Posebno težavo predstavljajo točke lokalnih ekstremov in prevojev, kjer se gradienti v različnih smereh občutno razlikujejo. Možno rešitev tega problema sta nedavno predstavila Wang in Tseng [12], ki sta predlagala tako imenovani dvosmerni prilagodljiv filter, ki temelji na delitvi pragovne funkcije (stožca) na dve polovici. Vsak izmed filtrov je tako zmožen ohraniti nezveznosti terena v nasprotni smeri, rezultat filtriranja pa tako predstavlja unija točk, ohranjenih z enim ali drugim filtrom. Čeprav takšen pristop vodi do ohranitve detajlov terena, pa občutno poslabša izločanje objektov, še zlasti kadar so ti veliki in nizki (na primer skladišča). Tovrstni pristopi prav tako ne nudijo najvišje stopnje natančnosti pri filtriranju točk nizke vegetacije na strmih pobočjih. Točke nizke vegetacije

imajo namreč relativno nizek naklon do svoje okolice, medtem ko je naklon terena lahko visok. Posledično to pomeni, da začetna predpostavka, na kateri temeljijo predstavljeni postopki filtriranja, ne drži več [4,5,6]. Zato nedavno predstavljena študija Werbroucka in sodelavcev [13] predlaga uporabniško nadzorovano pragovno filtriranje naklonov z vizualno interpretacijo podatkov. Takšen pristop seveda zahteva zelo intenzivno uporabniško interakcijo, a je to edini način, s katerim lahko dosežemo visoko stopnjo natančnosti na osnovi ocenitve naklonov.

2.3. Metode matematične morfologije

Čeprav je bila prva metoda filtriranja podatkov LiDAR s koncepti matematične morfologije predstavljena že leta 1996, so ti pristopi (kot bomo predstavili v nadaljevanju) komaj v zadnjem času prevzeli vodilno vlogo na tem področju tako iz vidika natančnosti kot tudi računske učinkovitost. Vsem tovrstnim postopkom je skupno to, da vhodni oblak točk najprej razporedijo v mrežo enako velikih celic, nad njo pa izvajajo operacije, izpeljane iz morfološkega širjenja in krčenja [14].



Slika 3. Primer izravnavanja detajlov na **(a)** prečnem prerezu vhodnih podatkov LiDAR, **(b)** razporejenih v mrežo enako velikih celic z uporabo **(c)** morfološkega krčenja ter **(d)** širjenja.

Slika 3 prikazuje primer uporabe morfološkega širjenja in krčenja, ki vodi do najpogosteje uporabljenega operatorja, ki ga imenujemo morfološko odpiranje. Na sliki 3a lahko vidimo prečni prerez vhodnega oblaka točk, ki ga razporedimo v mrežo enako velikih celic glede na ravnino xy . Slika 3b prikazuje prečni prerez mreže, kjer je vsaka celica predstavljena v obliki stolpca in vsebuje natanko eno točko. Operator morfološkega krčenje (prikazan na sliki 3c) določi novo višinsko vrednost točke tako, da ji pripiše najnižjo višinsko vrednost točke v njeni okolici, določeni s strukturnim elementom W . Nasprotno pa operator širjenja (prikazan na sliki 3d) določi novo višinsko vrednost točke glede na najvišjo vrednost točke iz njene okolice. Če krčenje in širjenje izvedemo zaporedno, izvedemo izravnavo izstopajočih visokih predelov, kot to prikazuje slika 3d. Tej operaciji pravimo morfološko odpiranje, velikost izravnanih detajlov pa določa strukturni element.

Prvi postopek filtriranja podatkov LiDAR z uporabo morfološkega odpiranja je predlagal Kilian s sodelavci [15]. Postopek iterativno povečuje strukturni element ter tako postopno izravna vedno večje objekte. V vsakem koraku izračuna višinsko razliko med točkami pred in po uporabi morfološkega odpiranja ter zabeleži velikost filtra pri katerem je ta prerastla določeno pragovno vrednost. To vrednost uporabi za izračun utežne vrednosti aproksimativne funkcije s katero določi digitalni model reliefa. Čeprav je postopek relativno naiven, nakazuje poglobljeno težavo, s katero se srečamo pri uporabi morfoloških filtrov za klasifikacijo podatkov LiDAR. Ker je velikost izravnanih detajlov odvisna od velikosti strukturnega elementa, glavni izziv teh pristopov predstavlja ustrezna definicija strukturnega elementa. Majhen strukturni element namreč ni zmožen odstraniti velikih objektov (na primer hiš). Nasprotno pa velik strukturni element poškoduje dejale terena pri odstranjevanju velikih objektov. Zardi tega, podobno kot v primeru predstavljene metode, tudi številne kasnejše metode temeljijo na iterativnem pristopu s postopnim spreminjanjem strukturnega elementa [16].

Chen s sodelavci [16] je predstavil metodo prilagojeno za terene s spremenljivim naklonom, ki temelji na predpostavki, da objekti povzročijo opazno večje spremembe naklona kot so spremembe v naklonu terena. Filtriranje točk tako dosežemo s pragovnimi vrednostmi, ki so določene glede na gradient v dani točki. Zaradi tega pa metoda ni zmožna ohraniti ostrih nezveznih predelov terena, na primer skal in nasipov [5]. Izboljšavo je predlagal Qi s sodelavci [17], ki izhaja iz predpostavke, da se višinske vrednosti robov terena spreminjajo, medtem ko imajo objekti (npr. zgradbe) enako visoke robove. Očitno je, da predstavljena metoda ni možna izločiti objekte kompleksnejših oblik.

Pristop, ki se oddaljuje od analize gradientov za filtriranje podatkov LiDAR in temelji na postopnem zmanjševanju strukturnega elementa, sta predlagala Mongus in Žalik [4]. Tako imenovani hierarhični morfološki pristop temelji na postopen približevanju interpolacijske ploskve dejanskemu terenu s postopnim vključevanjem novih točk. V vsakem koraku se v ta namen izvede morfološko odpiranje višinskih razlik med točkami in približka terena ter izloči točke, ki pri tem presežejo pragovno vrednost, določeno s statistično analizo ustvarjenih višinskih razlik. Izločene točke interpoliramo in v naslednji

približek terena vključimo le najnižjo točko vsaki celici podporne mreže. Predstavljen postopek je nedavno izboljšal Chen s sodelavci [19], ki je odpravil potrebo po statistični analizi za določanje pragovnih vrednosti, Pingel s sodelavci [18] pa je predlagal postopek, ki uporablja interpolacijsko funkcijo zgolj za določanje pragovnih vrednosti pri postopnem zmanjševanju strukturnega elementa.

Čeprav te metode danes veljajo za najbolj natančne, so iterativne in posledično računsko zahtevne. Mongus in Žalik [20] sta zato predlagala hierarhični pristop, ki namesto klasičnih morfoloških operatorjev uporablja tako imenovane atributne filtre. To so filtri, ki namesto vnaprej določenega strukturnega elementa filtrirajo podatke zgolj glede na določeno njegovo lastnosti. Avtorja sta v ta namen uporabila površino, postopek pa s postopnim povečevanjem površine filtrira doseže hierarhično dekompozicijo podatkov v enem samem prehodu. Čeprav je natančnost predlaganega postopka primerljiva s sorodnimi metodami, pa ta pristop ne omogoča odstranjevanja pripetih objektov, na primer mostov.

3. Določanje fotovoltaičnega potenciala streh iz klasificiranih točk LiDAR

Ena izmed zelo zanimivih aplikacij uporabe podatkov LiDAR je določanje sončnega potenciala streh, ki temelji na fotovoltaičnem pojavu (ang. photovoltaic, PV) [22]. Ker tehnologija pomembno vpliva na zmanjševanje onesnaževanja ozračja in toplo-grednih emisij, je vse bolj razširjena inštalacija sistemov PV v urbanih območjih. Pri tem je eno izmed ključnih vprašanj iskanje dovolj primernih površin na strehah stavb za inštalacijo tovrstnih sistemov, da se investicija v celoti povrne. Primernost površja je predvsem odvisna od geografske lokacije, naklona, orientacije, lokalne klime ter vpliva senčenja iz okolice. Sončni potencial predstavlja najbolj primerno metriko, ki upošteva vse naštet faktorje vpliva. Izračuna se s pomočjo povprečnega dnevnega ali kumulativnega obsevanja nad dano površje skozi celotno leto. Sončno obsevanje se lahko izračuna s pomočjo direktne, difuzne in odbojne komponente sončnega sevanja. Difuzno obsevanje je posledica perturbacij direktnega obsevanja (npr. atmosferskega sipanja, oblakov, in onesnaženost zraka) med Soncem in danim površjem na Zemlji. Direktno obsevanje prav tako ne doseže površij, ki so osenčena. Praviloma prejmejo ta površja le difuzno obsevanje iz vidnega dela neba. Odbojno obsevanje se pojavi, kadar se difuzno ali direktno obsevanje odbije od nekega površja, kjer je potrebno upoštevati odbojni koeficient materiala. Vse komponente obsevanja se v praksi izračunajo kot dobri približki, saj je simulacija lokalnega podnebja oziroma dnevnega vremena za eno leto vnaprej praktično nemogoča. Dober približek je uporaba večletnih meritev globalnega in difuznega obsevanja s piranometrom. V zadnjem desetletju je prav tako možno uporabiti satelitske podatke o spektru obsevanja [23]. Čeprav so lokalne meritve na površju bolj natančne, imajo satelitske meritve prednost na hribovitih površjih, kjer bi interpolacija lokalnih meritev imela večjo napako. Podatki LiDAR omogočajo odlično analizo topografskih značilnosti površja (t.j. naklona in orientacije) ter analizo senčenja okolice.

V zadnjih letih je bilo razvitih več rešitev, ki uporabljajo podatke LiDAR za izračun sončnega potenciala. Vöegtle s

sodelavci [24] je analiziral sončni potencial nad avtomatsko določenimi ravnimi deli streh različnih stavb. Kassner in sodelavci [25] so predstavili podatke LiDAR v 2.5D mreži, kjer so nato nad zamaskiranimi površji streh izračunali sončni potencial. Jochem je s sodelavci [26] razvil natančnejšo metodo za izračun sončnega potenciala, kjer je upošteval senčenje delov streh iz okolice. Za izračun sončnega potenciala so uporabili algoritem r.sun [27], ki uporablja indeks CSI (ang. clear-sky index) za aproksimacijo difuznega in direktnega sončnega obsevanja. Jochem in sodelavci [28] so nato predstavili metodo za izračun sončnega potenciala, ki upošteva transparentno senčenje vegetacije. Pri tem so si pomagali z razmerjem med prvim in zadnjim odbojem laserskega žarka. Natančnost takšnega senčenja je tako odvisna od števila posnetkov na lokaciji skozi leto. Levinson je s sodelavci [29] razvil bolj natančno metodo za ugotavljanje vpliva senčenja od vegetacije s pomočjo modelom za posamezno vrsto vegetacije. Strehe stavb niso edina atraktivna površja za namestitve sistemov PV, saj so nekatere stene stavb prav tako primerne. Stene objektov lahko zelo natančno zajamemo z mobilnim laserskim prebiranjem, kar je naredil Jochem ter njegovih sodelavcev v [30]. Investitorje za izkoriščanje sončne energije zanima količina proizvedene električne energije, kar pa sončni potencial ne omogoča. Zato je nastala metrika fotovoltaičnega potenciala, ki upošteva karakteristiko polprevodnega materiala modulov PV ter razsmernika, nameščenega na sistemu PV. Hofierka in Hanuk [31] sta algoritem r.sun aplicirala v urbanem območju. Pri tem sta izračunala potencial PV za module iz kristalnega silicija. Wiginton je s sodelavci [32] določil potencial PV na večjih regijah s tehnologijo GIS ter razpoznavanjem stavb nad zajetimi aerosonetki. Brito in sodelavci [33] so predvideli potenciala PV za del Lizbone z orodjem SolarAnalyst. Jakubiec in Reinhart [34] pa sta izračunala potencial PV nad urbanim območjem s pomočjo simulacije Daysim. Prav tako sta upoštevala temperature streh. Pred kratkim sta Nguyen in Pearce [35] ocenila PV potencial nad podatki LiDAR za polikristalne in amorfne silicijeve celice.

V tem poglavju predstavimo izboljšano metodo za izračun PV potenciala, ki temelji na predhodnem delu iz sončnega potenciala [36] ter upoštevanja karakteristike različnih modulov PV in razsmernika. V podpoglavju 3.1 bomo najprej na kratko povzeli metodo za izračun sončnega potenciala ter predstavili metodo za izračun potenciala PV. Metodo smo aplicirali nad klasificiranimi podatki LiDAR občine Beltinci, kar podrobneje predstavimo v podpoglavju 3.2.

3.1. Metoda za izračun sončnega in fotovoltaičnega potenciala

Klasificirane podatke LiDAR vstavimo v 2.5D mrežo Ψ iz n celic z ločljivostjo 1m^2 , kar vzpostavi topologijo za ugotavljanje topografskih značilnosti, kot sta naklon β_i in orientacija γ_i za dano celico $C_i \in \Psi$; $i = \{1, 2, \dots, n\}$. Za vsako celico v mreži izračunamo sončni potencial tako, da integriramo izračunana instantna sončna obsevanja z določenim časovnim korakom. Instantno prostorsko in časovno odvisno sončno obsevanje za dano celico je definirano kot:

$$I_i(t) = Ib_i(t)(1 - S_i(t)) + Id_i(t) \left[\frac{W}{m^2} \right]$$


kjer je t časovni trenutek, Ib_i direktno obsevanje, S_i koeficient senčenja ter Id_i količina difuznega obsevanja za celico C_i . Direktno in difuzno obsevanje pridobimo iz meritev s piranometrom čim bliže dani lokaciji. Pri tem smo upoštevali vpadni kot sončnih žarkov Φ_i , ki ga izračunamo s pomočjo kotov β_i in γ_i [37]. Koeficient senčenja izračunamo za vsako celico v mreži za določen časovni korak, ter sproti spreminjamo položaj Sonca z algoritmom SOLPOS [38]. Dana celica C_a je lahko senčena tudi od neke druge celice C_b v primeru, da velja pogoj za $S_i = 1$:

$$S_i(t) = \begin{cases} 1 & C_b \cdot z > l^2(C_a, C_b)\mu - C_a \cdot z \\ 0 & \text{sicer} \end{cases}$$

kjer l^2 definira l^2 -normo oz. evklidsko razdaljo, μ pa višinski korak za horizontalno razdaljo dveh sosednjih celic na poti med C_a in položajem Sonca. Podatki LiDAR običajno ne obsegajo celotnega področja, ki lahko vpliva na senčenje streh. Zato se lahko uporabimo tudi večločljivostno senčenje za doseganje večje natančnosti. Za to smo uporabili podatke DMR širše okolice z nižjo ločljivostjo za izračun senc okolice po istem postopku kot za visokoločljivostne podatke LiDAR [36]. V metodi smo prav tako upoštevali časovno odvisno senčenje vegetacije, ki temelji na podatkih LAI (ang. Leaf Area Index) [39]. LAI ponazarja količino oz. gostoto vegetacije projicirane na vodoravno ravnino pod vegetacijo. V primeru senčenja od vegetacije posodobimo koeficient S_i :

$$S_i(t) = \max(S_i(t), 1 - e^{-KL})$$

kjer je K faktor prepustnosti svetlobe, L pa razmerje med ploščino projicirane krošnje na ravnino ter ploščino celotni ravnini pod vegetacijo. Na sliki 4 vidimo difuzno in direktno obsevanje ter primer senčenja od vegetacije.



Slika 4. Določanje instantnega sončnega obsevanja. Vpadni kot Φ_i definiramo z normalo $C_{i,n}$ za dano celico. Na sliki vidimo tudi vpliv senčenja od vegetacije.

Metoda ne upošteva obsevanja zaradi odbojev, saj teh informacij iz podatkov LiDAR ne moremo pridobiti. Sončni

potencial nato izračunamo kot kumulativno obsevanje za neko časovno obdobje:

$$SP_i(t) = \int I_i(t) dt \left[\frac{\text{Wh}}{\text{m}^2} \right].$$


Fotovoltaični potencial smo določili s pomočjo nominalne karakteristike učinkovitosti (t.j. Watt-peak [Wp]) za določen polprevodniški material (glej tabelo 1). Pri tem smo uporabili instantno sončno obsevanje, ki smo ga pomnožili s faktorjem učinkovitosti $\eta \in [0, 1]$.

Tabela 1. Faktorji učinkovitosti za tri iz med najbolj uporabljenih polprevodniških materialov.

Polprevodniški material	Faktor učinkovitosti (η)
Amorfni silicij (A-Si)	0.16
Monokristalni silicij (M-Si)	0.11
Polikristalni silicij (P-Si)	0.08


3.2. Analiza nad občino Beltinci

Metodo smo uspešno aplicirali na podatke LiDAR za občino Beltinci, kjer smo upoštevali 10-letne meritve globalnega in difuznega obsevanja (glej sliko 5) vremenske postaje v Rakičanu za časovno obdobje enega leta ter časovnim korakom 1 ure. Direktno obsevanje se je preprosto izračunalo z odštevanjem difuznega od globalnega obsevanja.



Slika 5. Graf povprečnih meritev globalnega in difuznega obsevanja za Rakičan za zadnjih 10 let.

Na sliki 6 so prikazani podatki LiDAR občine Beltinci, povprečno senčenje skozi leto, ter direktno in difuzno obsevanje. Vpliv direktnega obsevanja je posebej izrazit na površjih usmerjenih proti jugu.




Slika 6. Vizualizacija centra Beltincev, kjer so (a) klasificirani podatki LiDAR, (b) povprečno senčenje skozi leto, (c) direktno obsevanje in (d) difuzno obsevanje.

Nato smo izračunali PV potencial nad danimi podatki (glej sliko 7) za tri najbolj uporabljene module PV (glej tabelo 1). Kot pričakovano, obstaja linearna odvisnost med nominalno karakteristiko učinkovitostjo modula PV ter izračunanim sončnim potencialom. Zato daje tudi monokristalni silicij (M-Si) najboljše rezultate.

4. Zaključek

LiDAR je laserski merilnik, ki, če je pritrjen na satelit, letalo ali helikopter, z veliko hitrostjo, natančnostjo in gostoto zajema točke s površja terena. Medtem ko so glavni tehniški problemi samega merilnika LiDAR že uspešno rešeni, ostaja velik izziv pri avtomatski klasifikaciji zajetih točk. Točke tipično razvrstimo v točke terena, točke na objektih (na primer hiše, mostovi, ceste, železnice, daljnovodi), točke nizke, srednje in visoke vegetacije, ter šumne točke. Pričetek vsake klasifikacije je določitev točke samega terena, ki jih lahko obravnavamo kot nekakšno ozadje diskretizirane 3D slike. Klasifikaciji terena posvetimo drugo poglavje, v katerem najprej na kratko opišemo obstoječe pristope, nekoliko več časa pa se posvetimo pristopu, ki smo ga razvili v našem laboratoriju. Glede na rezultate

objavljene v [4 in 21] je naša metoda med najuspešnejšimi obstoječimi metodami. V nadaljevanju pokažemo eno izmed zelo zanimivih aplikacij nad klasificiranimi podatki LiDAR, to je določanje fotovoltaičnega potenciala streh na večjem urbanem področju. Predlagana metoda je trenutno najpopolnejša metoda za to nalogo, saj uporablja natančne topografske podatke samih streh (naklon, orientacija) in njihove okolice, ki jih je mogoče zajeti samo s tehnologijo LiDAR. Metoda vključuje direktno, difuzno in odbojno komponento sončnega sevanja, senčenje okoliških objektov, senčenje vegetacije glede na letni čas in večločljivostno senčenje okoliškega terena. Metoda dosega več kot 95% ujemanje glede na meritve, kot smo pokazali v [36]. Neposredna nadgradnja metode je upoštevanje karakteristik sončnih celic, s katerim lahko ocenimo količino letno proizvedene električne energije ter ocenimo čas povračila investicija. Samo metodo smo preizkusili na podatkih celotne občine Beltinci. Izdelali smo tudi spletno in mobilno inačico programske rešitve, ki na enostaven in občanom razumljiv način poda informacijo o primernosti njihove strehe za izkoriščanje sončne energije [40]. Sama aplikacija in njen pomen v lokalnem okolju bo podrobneje v svojem prispevku predstavil dr. Matej Gomboši, župan občine Beltinci.



Slika 7. Vizualizacija centra Beltincev, kjer vidimo količino proizvedene električne energije za 1m^2 za celice (a) A-Si, (b) P-Si in (c) M-Si.

Zahvala

Avtorji se zahvaljujejo Ministrstvu za izobraževanje, znanost in šport ter Evropskemu skladu za regionalni razvoj (projekt DoFPoLO), Občini Beltinci za podatke LiDAR, Agenciji Republike Slovenije za okolje za podatke obsevanja ter Javni agenciji za raziskovalno dejavnost Republike Slovenije (J2-3650 in J2-5479).

Literatura

- Petrie, G.; Toth, C. K. 2008. *Topographic Laser Ranging and Scanning: Principles and Processing*. CRC Press: Boca Raton, USA, 2008; pp. 29–86.
- Brandtberg, T.; Warner, T.; Landenberger, R.; McGraw, J. Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density lidar data from the eastern deciduous forest in North America. *Remote Sensing of Environment* 2003, 85(3), 290-303.
- Brenner, C. 2000. Towards fully automatic generation of city models. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 2000, 33(3), 85-92.
- Mongus, D.; Žalik, B. Parameter-free ground filtering of LiDAR data for automatic DTM generation. *ISPRS Journal of Photogrammetry and Remote Sensing* 2012, 66 (1), 1–12.
- Sithole, G.; Vosselman, G. Experimental comparison of filter algorithms for bare earth extraction from airborne laser scanning point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing* 2004, 59 (1-2), 85–101.
- Liu, X. Airborne LiDAR for DEM generation: some critical issues. *Progress in Physical Geography* 2008, 32 (1), 31–49.
- Kraus, N.; Pfeifer, N. Determination of terrain models in wooded areas with airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing* 1998, 53 (4), 193–203.
- Pfeifer, N.; Reiter, T.; Briese, C.; Rieger, W. Interpolation of high quality ground models from laser scanner data in forested areas. *International Archives of Photogrammetry and Remote Sensing* 1999, 32 (3/W14), 31–36.
- Lee, H. S.; Younan, N. DTM extraction of LiDAR returns via adaptive processing. *IEEE Transactions on Geoscience and Remote Sensing* 2003, 41 (9), 2063–2069.
- Vosselman, G. Slope based filtering of laser altimetry data. *International Archives of Photogrammetry and Remote Sensing* 2000, 33, 935–942.
- Sithole, G. Filtering of laser altimetry data using a slope adaptive filter. *International Archives of Photogrammetry and Remote Sensing* 2001, 34(3/W4), 203–210.
- Wang, C.; Tseng, Y. DEM generation from airborne LiDAR data by an adaptive dualdirectional slope filter. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 2010, 38 (7B), 628–632.
- Werbrouck, I.; Antrop, M.; Van Eetvelde, V.; Stal, C.; De Maeyer, P.; Bats, M.; Bourgeois, J.; Court-Picon, M.; Crombe, P.; De Reu, J.; De Smedt, P.; Finke, P. A.; Van Meirvenne, M.; Verniers, J.; Zwervaegher, A. Digital elevation model generation for historical landscape analysis based on lidar data, a case study in Flanders (Belgium). *Expert Systems with Applications* 2011, 38 (7):8178–8185, 2011.
- Serra, J. *Image analysis and mathematical morphology*; Academic Press, London, UK, 1982.
- Kilian, J.; Haala, N.; Englich, M. Capture and evaluation of airborne laser scanner data. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 1996, 31 (B3), 383–388.
- Zhang, K.; Whitman, D. Comparison of three algorithms for filtering airborne LiDAR data. *Photogrammetric Engineering & Remote Sensing* 2005, 71 (3), 313–324.
- Chen, Q.; Gong, P.; Baldocchi, D.; Xie, G. Filtering airborne laser scanning data with morphological methods. *Photogrammetric Engineering & Remote Sensing* 2007, 73 (2), 175–185.
- Qi, C.; Gong, P.; Baldocchi, D.; Xie, G. Filtering airborne laser scanning data with morphological methods. *Photogrammetric Engineering & Remote Sensing* 2007, 73 (2), 175–185.
- Pingel, T.J.; Clarke, K.C.; McBride, W.A. An improved simple morphological filter for the terrain classification of airborne LIDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing* 2013, 77(1), 21–30.
- Chen, C.; Li, Y.; Li, W.; Dai, H. A multiresolution hierarchical classification algorithm for filtering airborne LiDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing* 2013, 82(1), 1–9.
- Mongus, D.; Žalik, B. Computationally efficient method for the generation of a digital terrain model from airborne LiDAR data using connected operators. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 2013, In press, 1–12.
- Robinson, D.; Stone A. Solar radiation modelling in the urban context. *Solar Energy* 2004, 77(3), 295–309.
- Tapiador, F. J. Assessment of renewable energy potential through satellite data and numerical models. *Energy & Environmental Science* 2009, 11, 1142–1161.
- Vöegtle, T.; Steinle, E.; Tóvári, D. Airborne Laser scanning data for determination of suitable areas for photovoltaics. *International Archives of Photogrammetry and Remote Sensing* 2005, 36, 215–220.
- Kassner, R.; Koppe, W.; Schüttenberg, T.; Bareth, G. Analysis of the solar potential of roofs by using official

- LiDAR data. *International Archives of Photogrammetry and Remote Sensing* 2008, 37, 399–403
26. Jochem, A.; Höfle, B.; Rutzinger, M.; Pfeifer, N. Automatic roof plane detection and analysis in airborne LiDAR. *Sensors* 2009, 9 (7), 5241–5262.
 27. Šuri, M.; Hofierka, J. A new GIS-based solar radiation model and its application to photovoltaic assessments. *Transactions in GIS* 2004, 8 (2), 175–90.
 28. Jochem, A.; Höfle, B.; Hollaus, M.; Rutzinger, M. Object detection in airborne LiDAR data for improved solar radiation modeling in urban areas. *International Archives of Photogrammetry and Remote Sensing* 2009, 38, 1–6.
 29. Levinson, R.; Akbari, H.; Pomerantz, M.; Gupta, S. Solar access of residential rooftops in four California cities. *Solar Energy* 2009, 83 (12), 2120–2135.
 30. Jochem, A.; Höfle, B.; Rutzinger, M. Extraction of vertical walls from mobile laser scanning data for solar potential assessment. *Remote Sensing* 2011, 3 (4), 650–667.
 31. Hofierka, J.; Kanuk, J. Assessment of photovoltaic potential in urban areas using open-source solar radiation tools. *Renewable Energy* 2009, 34 (10), 2206–2214.
 32. Wiginton, L.K.; Nguyen, H.T.; Pearce, J. Quantifying rooftop solar photovoltaic potential for regional renewable energy policy. *Computers, Environment and Urban Systems* 2010, 34 (4), 345–357.
 33. Brito, M.C.; Gomes, N.; Santos, T.; Tenedório, J.A. Photovoltaic potential in a Lisbon suburb using LiDAR data. *Solar Energy* 2012, 86 (1), 283–288.
 34. Jakubiec, J.A.; Reinhart, C.F. A method for predicting city-wide electricity gains from photovoltaic panels based on LiDAR and GIS data combined with hourly Daysim simulations. *Solar Energy* 2013, 93, 127–143.
 35. Nguyen, H.T.; Pearce, J.M. Automated quantification of solar photovoltaic potential in cities. *International Review for Spatial Planning and Sustainable Development* 2013, 1 (1), 57–70.
 36. Lukač, N.; Žlaus, D.; Seme, S.; Žalik, B.; Štumberger, G. Rating of roofs' surfaces regarding their solar potential and suitability for PV systems, based on LiDAR data. *Applied Energy* 2013, 102, 803–812.
 37. Duffie, J.A.; Beckman, W.A. *Solar Engineering of Thermal Processes*. Wiley-Interscience: New Jersey, USA, 2006.
 38. Reda, I.; Afshin, A. Solar position algorithm for solar radiation applications. *Solar Energy* 2004, 76 (5), 577–589.
 39. Yuan, H.; Dai, Y.; Xiao, Z.; Ji, D.; Shanguan, W. Reprocessing the MODIS Leaf Area Index products for land surface and climate modelling. *Remote Sensing of Environment* 2011, 115 (5), 1171–1187.
 40. Brumen, M.; Lukač, N.; Smogavec, G.; Repnik, B.; Gomboši, M.; Žalik, B. Geografski IS za prikaz sončnega potenciala nad georeferenciranimi podatki. V: Heričko, M. (ur.); Kous, K. (ur.). V: Sodobne tehnologije in storitve: OTS 2013: zbornik osemnajste konference, Maribor, 18. in 19. junij 2013. Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko, Inštitut za informatiko, 2013, str. 163-174.