

# Ocenjevanje kvalitete algoritmov zaznavanja cest na satelitskih posnetkih

Klemen Čotar, Janez Zaletelj

Univerza v Ljubljani Fakulteta za elektrotehniko  
janez.zaletelj@ldos.fe.uni-lj.si

## Estimating quality of road detection algorithms for satellite images

*In the paper we address the problem of automatic evaluation of road detection algorithms. The main problem of automatic evaluation procedure is that it requires an accurate reference road mask, which is not readily available, and manual classification of road pixels is not possible due to large image size. Thus we propose to generate reference road masks automatically by using vector road data from GIS. We evaluate and compare results of road detection accuracy and completeness by using two different reference masks, one generated automatically from GIS data, and the second generated by hand. We found that GIS-based automatic evaluation is acceptable for relative evaluation of different road detection algorithms, however it is currently not yet accurate enough for absolute evaluation of road detection accuracy and completeness.*

## 1 Introduction

Satelitski in letalski posnetki zemeljskega površja lahko služijo kot vir informacij o cestnem omrežju, pri čemer uporabljamo algoritme zaznavanja cest na posnetkih. Najpogostejši namen zaznavanja cest na posnetkih je torej izdelava in posodabljanje vektorske baze državnih cest [1], lahko pa zaznavanje cest služi tudi za namen določitve primernih značilnih točk (npr. križišč) za neposredno registracijo satelitske slike v lokalni zemeljski koordinatni sistem [2].

Vizualno določanje cest na satelitskih posnetkih je za človeka dokaj enostavno, saj imajo te prepoznavno geometrijsko obliko in izstopajočo svetlost oziroma barvo. Njihov izgled je sicer odvisen od ločljivosti posnetka, medtem ko na srednjeločljivih posnetkih (velikost slikovnega elementa nekaj metrov) vidimo ceste kot svetle črte, na visokoločljivih posnetkih (pod 2m) ločimo rob ceste ter posamezne prometne pasove. V nadaljevanju se osredotočamo samo na posnetke pridobljene s satelita RapidEye z velikostjo slikovnega elementa 6,5m.

Namen dela je predstaviti metodo samodejnega ovrednotenja kvalitete algoritmov zaznavanja cest. V drugem poglavju predstavimo štiri metode zaznavanja cest, kjer prvi dve temeljita na klasificiranju

odziva Top-Hat morfološkega filtra, zadnji dve pa na strojnem učenju. V poglavju 3 predstavimo problem avtomatizacije postopka ovrednotenja kvalitete zaznanih cest. Vpeljana so merila natančnosti ter kompletnosti detektiranih cest. Predlagani postopek avtomatiziranega ovrednotenja teh meril vključuje izdelavo referenčne maske cestnega omrežja na podlagi podatkov digitalnih cestnih katastrov. Rezultate postopka samodejnega ovrednotenja primerjamo s postopkom na podlagi ročno izdelane referenčne maske, in s tem ocenimo njegovo primernost za evaluacijo različnih algoritmov zaznavanja cest.

## 2 Postopki zaznavanja cest na satelitskih posnetkih

Problem zaznavanja cest na posnetkih je aktualen že več desetletij. Mena [1] je objavil pregled literature, kjer navaja več kot 250 raziskav s tega področja. Najpogosteje uporabljeni postopki pri zaznavi so spektralna klasifikacija, zaznavanje robov in različne morfološke operacije.

Wang [3] na multispektralnem posnetku uporabi algoritem nenadzorovano klasifikacije. Z analizo robov na pankromatskem posnetku nato odpravi napake klasifikacije, na primer odstrani osamljene objekte, ki imajo drugačno obliko od pričakovane za ceste. Poullis [4] predlaga uporabo različno usmerjenih in širokih Gaborjevih filtrov. Na podlagi vseh odzivov zbranih v obliki tenzorjev izvede segmentacijo na posamezna zanimiva območja. Zaznavanje cestnih odsekov z metodo antiparalelnih robov predlaga Doucette [5]. Kot ceste določi mesta, kjer sta zaznana robova razmaknjena za pričakovano širino ceste in smeri gradientov v teh mestih različni za približno 180°. Algoritem z učenjem, ki ga predlaga Ziemsa [6], za vsako digitalno cesto v sistemu GIS izdelava njen pripadajoče področje na satelitskem posnetku in na tem področju odčita spektralne lastnosti. Za vsako cesto izdelava tudi obmejni pas na obeh straneh, kjer prav tako odčita spektralne lastnosti. Zbrane lastnosti in njihova razmerja so nato uporabljene za iskanje cest na drugih posnetkih.

V članku bomo primerjali rezultate klasifikacije cest na satelitskem posnetku za štiri različne metode zaznavanja. Vse metode kot vhodni podatek uporabl-

jajo RapidEye satelitske posnetke, ki jih sestavlja 5 spektralnih kanalov, od modrega do bližnje infra-rdečega. Cilj vseh postopkov je generirati čim natančnejšo binarno masko cestnega omrežja za podani satelitski posnetek.

V splošnem imajo vsi predlagani postopki štiri osnovne korake, a) predobdelavo in normalizacijo vhodnega posnetka, b) izračun značilik (npr. odziv Top-Hat filtra), c) klasifikacijo slikovnih elementov in d) strukturno analizo za odstranjevanje napak.

## 2.1 Postopek Top-Hat z adaptivnim pragom

Slika 1 prikazuje diagram postopka detekcije cest na podlagi odziva Top-Hat morfološkega filtra.




Figure 1: Shema modulov metode s Top-Hat in adaptivnim pragom.

Cilj spektralne normalizacije vhodnih slik je odstraniti vpliv pogojev zajema (čas, osvetlitev, naklon satelita ipd.) ter izboljšati kontrast cest glede na ozadje, pri tem smo uporabili postopek linearnega raztega histograma vhodnega posnetka v določenem območju slikovnih vrednosti (slika 1).

Spektralno normaliziran posnetek nato obdelamo z morfološko operacijo Top-Hat, ki poudari področja svetlejša od okolice in manjša od uporabljenega strukturnega elementa, torej poudari svetle linije na sliki. Uporabljen okrogli strukturni element je konstantne velikosti in prilagojen ločljivosti sensorja na satelitu. Ceste, ki jih želimo zaznati, so na posnetkih srednje ločljivosti široke do 3 slikovne elemente, izstopajo le avtoceste, ki so lahko tudi trikrat širše od navadnih cest in predstavljajo problem pri zaznavanju.

Klasifikacija slikovnih elementov v razreda cest in okolice poteka na podlagi upravljanja odziva Top-Hat filtra. Pri tem postopek A (*adaptivni prag*) za klasifikacijo cest uporablja adaptivno določeni prag, s katerim se izvede binarizacija. Svetlostni prag za binarizacijo ne sme biti postavljen prenizko, kar bi vodilo v zaznavo cest z veliko šuma. Previsok prag pa bi odstranil veliko cest z manjšim kontrastom glede na okolico. Prag se zato določi na podlagi analize histograma odziva Top-Hat filtra, kjer se poišče koleno histograma, ki loči manjši del slik. elementov z visokim odzivom od večjega dela z nizkim.

S pomočjo strukturne analize oblike povezanih cestnih segmentov poskušamo v zadnjem koraku popraviti napake oziroma odstraniti objekte z lastnostmi, ki se razlikujejo od tipičnih cestnih odsekov. V prvem koraku odstranimo vse nepovezane strukture s površino manjšo od predvidene, nato izračunamo objemajočo elipso in njeno sploščenost ter odstranimo preveč okrogle segmente.

## 2.2 Postopek s Houghovo transformacijo

Postopek B (*Houghova transformacija*) se od prejšnjega razlikuje v metodi klasifikacije odziva Top-Hat filtra. Za vse točke z dovolj velikim odzivom izrežemo manjšo okolico ter na njej izračunamo Houghovo transformacijo, s čimer dobimo seznam in parametre nekaj premic, ki opisujejo izbrano okolico. Kot cestni segment klasificiramo samo tiste točke, ki ležijo na premici, ki povezuje svetle točke v okolici. S tem zagotovimo, da končne točke ležijo na daljših svetlih segmentih, in odstranimo naključne posamezne svetle točke, npr. hiše ali kratke cestne odseke.

## 2.3 Postopki s strojnim učenjem

Prvi dve metodi uporabljata kot značilko za detekcijo cest odziv Top-Hat filtra s fiksno velikim strukturnim elementom. V nadaljevanju pa nas zanima, ali lahko z več atributi in s pomočjo strojnega učenja klasifikatorja dobimo natančnejše rezultate segmentacije.

V našem primeru je izbranih sedem atributov, ki opisujejo posamezni slikovni element posnetka. To so koordinate elementa, svetlost točke na prvem spektralnem kanalu, kjer so ceste svetlejšje kot okolica, in svetlost na petem spektralnem kanalu, kjer so ceste temnejše kot okolica. Sledijo jim odziv Top-Hat transformacije z dvema različno širokima strukturnima elementoma (5 in 7 pikselov). Z zadnjim diskretnim atributom class programu povemo, v kateri razred pri klasifikaciji spadajo prej navedeni podatki. Podatki za cestne odseke so označeni z vrednostjo 1, okolica pa z 0. Kot metoda razvrščanja podatkov je uporabljena metoda podpornih vektorjev (SVM).

Dve metodi s strojnim učenjem se razlikujeta glede na način generiranja učne množice. Postopek D (*ročno določena učna množica*) uporablja ročno izbiro točk cest in njihove okolice, za vsakega od obeh razredov (ceste, okolica) je bilo ročno izbranih 200 točk iz celotnega posnetka velikosti 11.000 x 7.000 slikovnih elementov. Za vsak vzorec (točko) je bilo potem izračunanih sedem atributov, ki potem predstavljajo značilko točke v postopku učenja.

Postopek C (*avtomatsko določena učna množica*) pa izbere vzorce učne množice na podlagi referenčnih podatkov o cestnem omrežju. Pripravili smo ročno poravnane maske cest, ki so bile generirane na podlagi vektorske baze cestnega omrežja. Na tej referenčni maski pa imajo ceste širino večjo od dejanske širine vidnih cest, da lahko kompenziramo napake pri poravnavi. Zato določen delež pikselov iz učne množice razreda cest dejansko pripada razredu okolice.

## 3 Ovrednotenje kvalitete zaznave

Rezultate opisanih algoritmov želimo objektivno ovrednotiti, da bo možna kvalitativna primerjava med njimi. Ovrednotenje temelji na primerjavi mask cest, pri čemer masko zaznanih cest primerjamo z masko referenčnih cest, ki pa jo moramo še pripraviti oziroma

mora biti natančno poravnana s samo satelitsko sliko.




Figure 2: Prikaz zaznanih (bela) in referenčnih cest (siva barva) pri uporabi ročno označenih referenčnih cest (leva slika) ter maske digitalnih cest (desna slika).

Slika 2 prikazuje isto območje satelitskega posnetka, na katerem so združeni podatki o zaznanih (bela) in referenčnih cestah (siva). Želimo čim večje prekrivanje zaznanih in referenčnih cest, ostalo so nezaželene napake. Leva slika prikazuje ročno narisane referenčne ceste, desna pa avtomatsko generirane referenčne ceste.

### 3.1 Generiranje referenčnih cest

Pri metodi z ročnim označevanjem smo označili človeku vidne ceste na posnetku, ki tudi sovpadajo z zaznanimi cestami, in ne vsebujejo odsekov, ki so zakriti z gozdom ali drugimi objekti. Ročno označevanje je zamuden postopek, za potrebe poskusa smo tako označili štiri manjše izseke satel. posnetkov.

Avtomatsko določanje referenčnih cest uporablja podatke o lokaciji cest, pridobljene iz digitalnih podatkovnih baz GIS. Vektorje cest smo na izbranem območju rasterizirali in s tem pridobili masko referenčnih cest  $R$ . Ker so vektorji cest podani v ortofoto projekciji, satelitska slika pa predstavlja pogled na pokrajino z določenega kota snemanja, se razdalje ne ujemaajo ter prihaja do popačenj predvsem v goratih področjih. Izvesti je potrebno postopek poravnavanja referenčne in maske zaznanih cest. Kot kaže slika 2, so referenčne ceste rasterizirane širše od njihove dejanske širine, da kompenziramo nenatančnosti pri poravnavi satelitskega posnetka na referenčno masko cest. Poleg tega smo v digitalnih podatkih ugotovili prisotnost napak, predvsem manjkajoče novejšje cestne odseke, največkrat avtoceste in avtocestne priključke, ter razliko med digitalno in dejansko obliko cestnih odsekov.

### 3.2 Merila kvalitete

Pri merjenju kvalitete ocenjujemo pravilnost klasifikacije vsakega slikovnega elementa neodvisno. Zaznane ter referenčne ceste zato predstavimo kot množice točk, katerih elementi so koordinate točk  $(x, y)$ . Množico točk referenčnih cest označimo z  $\mathcal{R} = \{(x, y)\}$ , množico točk zaznanih cest pa z  $\mathcal{D} = \{(x, y)\}$ .




Figure 3: Rezultati evaluacije natančnosti in completenessi štirih metod. Temni liki predstavljajo rezultat ročne, svetli avtom. evaluacije. Krogci predstavljajo metodo C, kvadrati metodo D, trikotniki B in rombi metodo A. Krivulje povezujejo povprečne rezultate posamezne metode, povezana črta predstavlja ročno evaluacijo, črtkana črta avtomatsko.

Kvaliteta je določena z naslednjimi merami, ki so v literaturi [7] navedene kot standardne mere za ovrednotenje kvalitete zaznave cest. Natančnost zaznave  $P$  definiramo kot delež zaznanih slikovnih elementov cest, ki se ujemaajo z referenčnimi cestami, in je podana z enačbo

$$P = \frac{N(\mathcal{D} \cap \mathcal{R})}{N(\mathcal{D})}. \quad (1)$$

Za izračun kvalitete okrog referenčnih cest izberemo pas neke širine, točke tega pasu pa označimo z množico  $\mathcal{R}$ . Vse točke množice  $\mathcal{D}$ , ki ležijo znotraj tega pasu, obravnavamo kot pravilno zaznane ceste, točke izven tega pasu pa kot nepravilno zaznane ceste.

Kompletnost zaznave  $C$  pa definiramo kot delež slikovnih elementov referenčnih cest, ki jih je algoritem pravilno razpoznal kot ceste,

$$C = \frac{N(\mathcal{D} \cap \mathcal{R})}{N(\mathcal{R})}. \quad (2)$$

Ker različni algoritmi vračajo različno debele zaznane ceste, completenessi zaznave ne moremo računati preprosto kot delež pokritosti referenčnih cest z zaznanimi točkami. Namesto pokritosti računamo dolžine pokritih odsekov. Zaznane točke, ki ustrezajo referenčnim cestam, s postopkom tanjšanja spremenimo v krivulje debeline 1 slikovni element. Število točk tako predstavlja dolžino odsekov. Enako izračunamo dolžino tudi vseh referenčnih cest, torej completenessi izračunamo kot kvocient števila točk v teh dveh množicah. Za namen medsebojne primerjave uporabljenih metod izračunamo skupno merilo kvalitete  $Q = 2 \frac{PC}{P+C}$ .

## 4 Eksperiment

Na podlagi podanih kriterijev kvalitete zaznavanja cest želimo primerjati različne metode zaznavanja. Ker pa je ročna izdelava referenčne maske cest zelo zamudna, je možna le za manjše izseke satelitske

slike. Če želimo ovrednotiti kvaliteto na celotnem posnetku ali več posnetkih, potrebujemo avtomatizirano metodo evaluacije.

V poskusu želimo oceniti, ali je možno z avtomatizirano evaluacijo na podlagi digitalnih podatkov o cestnem omrežju učinkovito in zanesljivo primerjati različne metode detekcije cest na satelitskih slikah. V ta namen smo pripravili štiri manjše izseke iz štirih različnih satelitskih posnetkov (različni meseci), ki tudi prikazujejo vsebinsko različna področja pokrajine. Za vse štiri izseke so bile pripravljene po dve maski referenčnih cest, prva (oznaka 1) z ročnim označevanjem, druga (oznaka 2) pa na podlagi rasterizacije GIS vektorjev ter poravnave mask.

Za vsak izsek <sup>(1)...</sup><sup>(4)</sup> smo izvedli detekcijo po štirih metodah, ter za vsako masko cest izvedli evaluacijo glede na obe referenčni maski, s čimer smo dobili rezultate  $P_{A,1}^{(1)}, C_{A,1}^{(1)}, P_{A,2}^{(1)}, C_{A,2}^{(1)}$ , itd. Za vsako metodo smo izračunali še povprečno natančnost  $\bar{P}_{A,1}, \bar{P}_{A,2}$  in kompletnost  $\bar{C}_{A,1}, \bar{C}_{A,2}$  preko vseh štirih izsekov. Rezultati so izrisani v sliki 3, kjer črni liki označujejo ročno referenčno masko ter svetli liki avtom. generirano masko. Dve krivulji pa povezujejo točke povprečnih rezultatov posamezne metode, in sicer si sledijo metode od leve proti desni: C, D, B, A. Povezana črta predstavlja povprečne rezultate štirih metod na podlagi ročne evaluacije, črtkana pa na podlagi avtomatske evaluacije. Tabela 1 pa prikazuje izračunano skupno kvaliteto zaznavanja cest za posamezne metode, in sicer glede na ročno in avtomatsko generirano referenčno masko.

	A	B	C	D
$Q_1$	0.481	0.518	0.343	0.435
$Q_2$	0.488	0.516	0.481	0.488

Table 1: Ovrednotenje skupne kvalitete detekcije cest za posamezne metode glede na ročno referenčno masko ( $Q_1$ ) in glede na avtomatsko refer. masko ( $Q_2$ ).

## 5 Rezultati in zaključek

Primerjava rezultatov ročne in avtomatske evaluacije na sliki 3 pokaže, da sta obliki obeh krivulj zelo podobni, sta pa med sabo premaknjeni. V primerjavi z ročno metodo označevanja cest, za katero smatramo, da je natančnejša (v okviru zmožnosti operaterja in vidljivosti cest na posnetku), nam avtomatsko generirane maske cest v povprečju pokažejo previsoko natančnost metod. Vzrok je v večji širini referenčne ceste potrebni zaradi nenatančnosti poravnave, kar pomeni, da se tudi cestam bližnji objekti (hiše) klasificirajo kot pravilna zaznava. Po drugi strani je izmerjena kompletnost cest nekaž nižja. Zanimivo je, da je skupna kvaliteta (tabela 1) pri metodah A in B kljub tem razlikam praktično enaka, pri C in D pa je izračunana kvaliteta večja pri avtomatskih maskah. Za bolj zanesljivo primerjavo obeh načinov evaluacije pa bi bilo potrebno generirati več vzorcev ročnih mask.

Kljub slabostim avtomatskega načina evaluacije pa nam ta lahko dobro služi za primerjavo posameznih metod. Po obeh kriterijih izstopa metoda B s Houghovimi krivuljami, ki kot kriterij ceste vpeljuje lego slikovnega elementa na daljšem ravnem odseku, okolica za izračun je v tem primeru velika  $19 \cdot 19$  pikselov. Metoda A (adapt. prag odziva Top-Hat) pri klasifikaciji točke upošteva veliko manjšo okolico, kar pomeni več nepravilnih manjših odsekov. Metoda D z ročno določeno učno množico se po kvaliteti približa metodi A, saj je ena bistvenih značilk tudi Top-Hat odziv. Metoda C je slabša zaradi nenatančne učne množice, v kateri se nahajajo tudi točke blizu cest, kar povzroči najvišjo kompletnost zaznavanja, vendar s tem tudi zmanjšano natančnost.

Rezultati kvalitete po obeh načinih izračuna nam kljub temu pokažejo, da metoda avtomatiziranega generiranja referenčnih točk kljub svojim slabostim omogoča dobro relativno primerjavo kvalitete posameznih metod detekcije, ne pa še izračuna absolutnih vrednosti kriterijev. Za odpravo napak pa bi bilo potrebno izboljšati način poravnavanja referenčne maske in detektirane maske cest.

## References

- [1] J.B.Mena, "State of the art on automatic road extraction for gis update: A novel classification," *Pattern Recognition Letters*, vol. 24, pp. 3037–3058, 2003.
- [2] J.Zaletelj, U.Burnik, and J.F.Tasic, "Registration of satellite images based on road network map," in *Proceedings 8th International Symposium on Image and Signal Processing and Analysis (ISPA 2013)*, Trieste,Italy, 2013, pp. 46 – 53.
- [3] R. Wang and Y. Zhang, "Extraction of urban road network using quickbird pan-sharpened multispectral and panchromatic imagery by performing edgeaided post-classifications," in *Proceedings International Society for Photogrammetry and Remote Sensing*, 2003.
- [4] C. Poullis, S. You, and U. Neumann, "A vision-based system for automatic detection and extraction of road networks," in *Applications of Computer Vision, 2008. WACV 2008, IEEE Workshop on*, 2008.
- [5] P. Doucette, "Automated road extraction from high resolution multispectral imagery," *Photogrammetric Engineering & Remote Sensing*, vol. 70, no. 12, 2004.
- [6] M. Ziemsa, M. Gerkeb, and C. Heipke, "Automatic road extraction from remote sensing imagery incorporating prior information and colour segmentation," *PIA*, vol. 7, pp. 141–147, 2007.
- [7] C. Heipke, "Evaluation of automatic road extraction," *International Archives of Photogrammetry and Remote Sensing*, vol. 32, pp. 151–160, 1997.