

## Razvrščanje sumljivih področij na avtofluorescenčnih bronhoskopskih slikah v maligne/nemaligne

Tomaž Finkšt<sup>1</sup> – Jurij Franc Tasič<sup>2</sup> – Marjeta Zorman Terčelj<sup>3</sup> – Marko Meža<sup>2,\*</sup>

<sup>1</sup> Univerza v Ljubljani, Fakulteta za strojništvo, Slovenija

<sup>2</sup> Univerza v Ljubljani, Fakulteta za elektrotehniko, Slovenija

<sup>3</sup> Univerzitetni klinični center Ljubljana, Klinični oddelek za pljučne bolezni in alergijo, Slovenija

Namen študije je bil razvoj postopka za razvrščanje sumljivih področij na bronhoskopskih slikah, ki predstavljajo maligna/nemaligna področja. Ustrezno izobražen specialist pulmologije s tehniko bronhoskopskega slikanja bronhialnih cevi identificira področja tkiva, na katerih opazi za maligno tkivo sumljiva področja. Bronhoskopsko preiskavo izvaja z uporabo slikanja in opazovanja slike z uporabo bele svetlobe, na kateri opazi spremembe v površini sluznice ter z uporabo ozko-valovne modre svetlobe ter opazovanja avtofluorescenčnega odziva tkiva v področju rdečih in zelenih valovnih dolžin. Maligno tkivo namreč za razliko od nemalignega izseva več svetlobe v področju rdečih valovnih dolžin kot v področju zelenih valovnih dolžin.

V okviru raziskave smo analizirali delovanje razvitega algoritma v smislu natančnosti razvrščanja sumljivih vzorcev tkiva. Na voljo smo imeli s strani specialista bronhoskopije sumljiva področja določena kot maligno tkivo. Za omenjena področja smo imeli na voljo bronhoskopske slike zajete z belo svetlobo ter z avtofluorescenčno svetlobo. Za področja smo imeli na voljo »ground truth« o razvrščanju tkiv v maligna/benigna na podlagi biopsije tkiva iz sumljivega področja, ki so bila patološko pregledana. V študijo smo vključili 44 sumljivih vzorcev, od katerih je bilo 22 malignih in 22 nemalignih.

Omenjene slike smo najprej obdelali, da smo na njih poiskali sumljiva področja. Sumljiva področja smo določili z metodo upravljanja razmerja rdečega in zelenega kanala avtofluorescenčne slike. Na sliki smo z algoritmi za iskanje robov in morfološkim zapiranjem področij določili sumljiva področja ter rezultate primerjali s področji, ki so jih na istih slikah ročno označili specialisti bronhoskopije.

V nadaljevanju smo za sumljiva področja izračunali nabor značilik, ki so služile kot neodvisne spremenljivke v drugem koraku – razvrščanju vzorcev. Pripravili smo dva nabora značilik. Za prvi nabor smo ponovili postopek, ki je že bil opisan v literaturi Bountris in sod. in je zajemal izračun 725 teksturnih značilik, ter redukcijo njihove dimenzije z uporabo metode analize osnovnih komponent (PCA). Za drugi nabor smo izračunali naš predlog značilik, ki je bil sestavljen iz parametrov dveh Gaussovih funkcij, s katerima smo aproksimirali potek histograma rdečega in zelenega kanala avtofluorescenčne slike. Omenjena nabora značilik in pripadajočo »ground truth« klasifikacijo vzorcev smo uporabili za učenje različnih razvrščevalnikov.

Prvi korak v obdelavi slik: določanje sumljivih področij je dajal v primerjavi s področji, ki so jih določili specialisti, zadovoljive rezultate: kot narobe pozitivne (ang. False Positive) smo označili od 8,7 % do 11,1 % slikovnih elementov in kot narobe negativne (ang. False Negative) smo označili od 8,4 % do 11,0 % slikovnih elementov.

V naši raziskavi smo uspešno ponovili metodo razvrščanja vzorcev, ki so jo predlagali avtorji Bountris in sod. Ko smo v omenjeni raziskavi objavljene rezultate primerjali z rezultati, ki smo jih dobili z uporabo našega nabora značilik smo ugotovili, da se na našem naboru vzorcev naša metoda obnaša bolje. Z različnimi algoritmi za grajenje razvrščevalnikov smo na Bountris-ovem in sod. naboru značilik dosegli natančnost med 90,4 % in 92,1 %, na našem naboru značilik pa natančnost od 90,9 % do 95,8 %.

Omenjeno raziskavo bi veljalo ponoviti na večjem vzorcu podatkov, da bi lahko identificirali vse morebitne težave, ki nastanejo pri vzorcih, ki precej odstopajo od vzorcev, ki smo jih imeli na voljo. Še vedno gre za metodo, ki lahko služi za razvoj podpornega orodja, ki bi omogočilo lažje delo specialistu bronhoskopije. Slabost omenjenega pristopa je tudi v tem, da je prilagojen za specifično napravo in bi zahteval prilagoditev na sorodne naprave.

Glavni prispevek omenjene metode je izboljšanje objavljene metodologije Bountris in sod. v smislu natančnosti in zmanjšanja kompleksnosti določanja značilik.

**Ključne besede:** segmentacija slik, zaznavanje robov, avtofluorescenčna bronhoskopija, razvrščanje, strojno učenje