



## უპილოტო საფრენი აპარატები და ხელოვნური ინტელექტი ძალიან მაღალი რეზოლუციის რუკათშედგენისა და ობიექტების ავტომატური ამოცნობისათვის

ტყეშელაშვილი ნიკა

დოქტორანტი, საქართველოს ტექნიკური უნივერსიტეტი, [tkeshelashvili.nika@gtu.ge](mailto:tkeshelashvili.nika@gtu.ge),  
<https://orcid.org/0009-0008-9353-6897>

### ამსტრაქტი

მაღალი სივრცული გარჩევადობის აეროფოტოსურათებიდან ობიექტების ამოცნობისა და აციფვრის ავტომატიზაცია ერთ-ერთი საკვანძო პრობლემაა დისტანციური ზონდირებისა და ფოტოგრამეტრიის ამოცანებიდან. წინამდებარე კვლევის ფარგლებში შეფასდა და გამოიცა და უპილოტო საფრენი აპარატებისა და ღრმა სწავლების მოდელების გამოყენების შესაძლებლობა ტრადიციული მეთოდების გაუმჯობესების, მონაცემების სიზუსტის გაზრდისა და მატერიალური დანახარჯების შემცირებისათვის სივრცული მონაცემების მოპოვებისა და დამუშავების პროცესში. საკვლევ ტერიტორიაზე, რომელსაც წარმოადგენს ქალაქი ცაგერი და მიმდებარე სოფელი ჭალისთავი რაჭა-ლეჩხუმისა და ქვემო სვანეთის რეგიონში, dji Mavic 3 უპილოტო საფრენი აპარატის საშუალებით მომზადდა მაღალი გარჩევადობის აეროფოტოსურათები, რომელთა ჯამური ფართობი შეადგენს 128 ჰექტარს. კვლევის ერთ-ერთ ძირითად მიზანს წარმოადგენდა მიღებული ორთოფოტოგეგმებიდან შენობების ავტომატური ამოცნობა და დიგიტალურიზაცია, ღრმა სწავლების ალგორითმების გამოყენებით. ამ მიზნის მისაღწევად შეირჩა და გამოიცა და Mask R-CNN ღრმა სწავლების მოდელი. მოდელირების პროცესში გამოყენებულია ციფრული სასიმაღლო მოდელების ორთოფოტოგეგმებთან ინტეგრაციით მიღებული 4 არხიანი გამოსახულებები, რაც დამატებით ტოპოგრაფიულ კონტექსტს ქმნის მოდელისათვის და პოტენციურად ზრდის მის სიზუსტეს. კვლევის შედეგები აჩვენებს, რომ უპილოტო საფრენი აპარატებისა და ღრმა სწავლების მოდელების ინტეგრირებული გამოყენება მნიშვნელოვნად ამარტივებს და აუმჯობესებს სივრცული მონაცემების მოპოვებისა და დამუშავების პროცესს. კერძოდ, dji Mavic 3 უპილოტო საფრენი აპარატის საშუალებით მივიღეთ 3 სანტიმეტრი სივრცული გარჩევადობის ორთოფოტოგეგმები და ციფრული სასიმაღლო მოდელები, ხოლო ჩვენს მიერ გაწვრთნილმა Mask R-CNN ღრმა სწავლების მოდელმა აჩვენა 92%-იანი სიზუსტე საკვლევ არეალზე შენობების ამოცნობისათვის. სტატიაში აღწერილი მეთოდოლოგია და ტექნიკური

საფუძვლები წარმოადგენს მომავალი კვლევების განვითარების ბაზისს და შეიძლება გამოყენებულ იქნეს სხვადასხვა ამოცანების გადაწყვეტისათვის, მაგალითად როგორიცაა, მიწის ადმინისტრირება, სხვადასხვა ინფრასტრუქტურული პროექტები, გარემოს მონიტორინგი, რესურსების მენეჯმენტი და ა.შ. განსაკუთრებით ეს შეიძლება ითქვას საქართველოში არსებული კონტექსტის გათვალისწინებით, როდესაც მაღალი რეზოლუციისა და სიზუსტის სივრცული მონაცემები ხშირად არ არის ხელმისაწვდომი კომპლექსური გარემო-პირობებისა თუ ეკონომიკური ფაქტორების გამო.

**საკვანძო სიტყვები:** უპილოტო საფრენი აპარატები, ციფრული სასიმაღლო მოდელი, ორთომოზაიკა, ხელოვნური ინტელექტი, ობიექტების ავტომატური ამოცნობა

## შესავალი

აეროფოტოსურათებიდან ობიექტების ამოცნობითა და შემდგომ მათი დიგიტალიზაციით მიღებული მონაცემები მნიშვნელოვანია არაერთი სივრცული პრობლემის გადაჭრისათვის. მათ შორის აღსანიშნავია 3D კადასტრის წარმოება, ურბანული დაგეგმარება, გარემოს მონიტორინგი და ა.შ. (Audebert et al., 2018). ასეთი მონაცემების შეგროვების ტრადიციული მეთოდები, რაც გულისხმობს გამოსახულებებიდან ობიექტების მანუალურ აციფრვას დიდ დროს, მატერიალურ და ადამიანურ რესურსს საჭიროებს, ხოლო ხშირ შემთხვევაში ამ ინფორმაციის სწრაფი შეგროვება და დამუშავება გადამწყვეტი მნიშვნელობისაა.

უკანასკნელ პერიოდში უპილოტო საფრენი აპარატებისა და ხელოვნური ინტელექტის სწრაფი განვითარება და ხელმისაწვდომობის ზრდა ამ ტექნოლოგიების გეოსივრცული კვლევებისა და პრაქტიკული ამოცანების გადაწყვეტისათვის ფართომასშტაბიანი გამოყენების შესაძლებლობას იძლევა.

ტრადიციულად, დედამიწის ზედაპირის დისტანციური ზონდირებისა და ოპტიკური თუ სხვა ტიპის გამოსახულებების მიღებისათვის ძირითად წყაროს წარმოადგენს დედამიწის სადამკვირვებლო თანამგზავრული მისიები და პილოტირებულ საფრენ აპარატებზე განთავსებული სენსორები, რომელთა ექსპლუატაცია და მოპოვებული მასალების სამეცნიერო თუ პრაქტიკული მიზნებით გამოყენება ხშირად გარკვეულ შეზღუდვებთანაა დაკავშირებული. პილოტირებული აპარატებისათვის ეს გამოიხატება მათი ოპერირებისათვის საჭირო მაღალი ხარჯებით, ამინდთან დაკავშირებული შეზღუდვებითა და ადამიანების უსაფრთხოების რისკთან. ხელოვნური თანამგზავრებიდან მოპოვებულ მონაცემები ხშირად დაბალი სივრცითი და დროითი რეზოლუციისა, ხოლო მაღალი გარჩევადობის გამოსახულებები ძვირადღირებულია, რაც ართულებს მათზე წვდომას.

უპილოტო საფრენი აპარატების (დრონების) გამოყენება დისტანციური ზონდირების მიზნებისათვის ნაკლებად ძვირადღირებულ და უფრო პრაქტიკულ ალტერნატივას წარმოადგენს, ვინაიდან ზემოთ ჩამოთვლილი შეზღუდვების უმეტესობა მათზე არ ვრცელდება. სპეციალიზირებული დრონების გამოყენებით, პრაქტიკულად დროითი და სივრცითი შეზღუდვის გარეშე შესაძლებელია ძალიან მაღალი გარჩევადობის (რამდენიმე სანტიმეტრიანი რეზოლუციის) ორთოფოტოებისა და ციფრული სასიმაღლო მოდელების

მიღება (Colomina & Molina, 2014). უპილოტო საფრენი აპარატების ამ უპირატესობების გამოყენებით შესაძლებელი ხდება სწრაფად ცვალებადი ურბანული გარემოს რუკათშედგენა და განხლებული ინფორმაციის მოპოვება, ბუნებრივი კატასტროფებით გამოწვეული ზიანის სწრაფი შეფასება და ა.შ. (Calantropio et al., 2021). მიუხედავად ამისა, მიღებული მასალების სწრაფად და ხარისხიანად დამუშავება ჯერაც გამოწვევად რჩება, განსაკუთრებით დიდი მოცულობის მონაცემების არსებობისას, რაც პროცესის ავტომატიზაციის საჭიროებას განაპირობებს.

ხელოვნური ინტელექტის, ღრმა სწავლების მოდელების ადაპტაცია დისტანციური ზონიდრებით მიღებული გამოსახულების ანალიზისათვის და მათზე ობიექტების ავტომატური ამოცნობისა და დიგიტალიზაციისთვის ინტენსიური კვლევის საგანს წარმოადგენს შესაბამის საერთაშორისო სამეცნიერო წრეებში. უკანასკნელი ათწლეულის განმავლობაში ამ ამოცანებისათვის არაერთი მოდელი და ალგორითმი გამოიცადა.

წინამდებარე კვლევის ფარგლებში განხორციელდა უპილოტო საფრენი აპარატიდან მიღებული აეროფოტოების გამოყენებით ძალიან მაღალი გარჩევადობის ორთოფოტო გაზმებისა და ციფრული სასიმაღლო მოდელების მომზადება ქალაქ ცაგერის ტერიტორიისათვის და მიღებული გამოსახულებებიდან ობიექტების, ამ შემთხვევაში, შენობების ავტომატური ამოცნობისა და აციფრვის შესაძლებლობების გამოცდა ღრმა სწავლების ალგორითმების გამოყენებით.

### კვლევის მეთოდები და მასალები

ქალაქი ცაგერი, როემლიც საკვლევ არეალს წარმოადგენს, რაჭა-ლეჩხუმისა და ქვემო სვანეთის რეგიონში მდებარეობს და ცაგერის მუნიციპალიტეტის ადმინისტრაციული ცენტრია. ქალაქის ტერიტორიის ფართობი დაახლოებით  $16.8 \text{ კმ}^2$ -ია, ხოლო მოსახლეობის რაოდენობა 2014 წლის აღწერით 1320 კაცს შეადგენს.

ქალაქ ცაგერის მდებარეობა, განაშნიანების თავისებურებები, ტოპოგრაფიული მახასიათებლები, აგრეთვე ურბანული და რურარული გარემოს მიქსი ხელსაყრელია წინამდებარე კვლევის მიზნების განსახორციელებლად და გამოსაცდელი მეთოდების ეფექტურობის შესაფასებლად საქართველოს პირობებისათვის.

კვლევაში გამოყენებული აეროფოტოსურათები მოპოვებულია 2024 წლის ივნისში ჩატარებული საველე ექსპედიციის ფარგლებში ქალაქ ცაგერსა და მიმდებარე სოფელ ჭალისთავში, dji Mavic 3 უპილოტო საფრენი აპარატით განხორციელებული ფრენების შედეგად.

dji Mavic 3 წარმოადგენს მცირე ზომის (C1 კლასი) კვად-კოპტერს, რომელიც აღჭურვილია მაღალი გარჩევადობის სენსორის მქონე RGB კამერით. კამერის მონაცემები ნაჩვენებია ცხრილი 1-ში. დრონს გააჩნია GNSS მხარდაჭერა (GPS, Galileo, BeiDou). თუმცა, ორთომოზაკების სანტიმეტრის დონეზე რეფერენსირების, ფარდობითი და გლობალური სიზუსტის გასაზრდელად, გადაღებების დროს მოეწყო საკონტროლო წერტილები, რომელთა კოორდინატები განისაზღვრა Emlid Reach RS 2+ მაღალი სიზუსტის GNSS მობილური მიმღების

საშუალებით. აეროგადაღებების ფარგლებში, რომელიც ქალაქ ცაგერსა და სოფ. ჭალისთავში სამ სხვადასხვა არეალზე განხორციელდა, ჯამში დაიფარა 128 ჰექტარი ტერიტორია. ფრენის სიმაღლე მიწის ზედაპირიდან შეადგენდა 120 მეტრს, სიჩქარე - დაახლოებით 8.5 მ/წმ. ფრენის ტრაექტორიის მაგალითი ერთ-ერთი არეალისათვის მოცემულია ფიგურა 1-ზე.



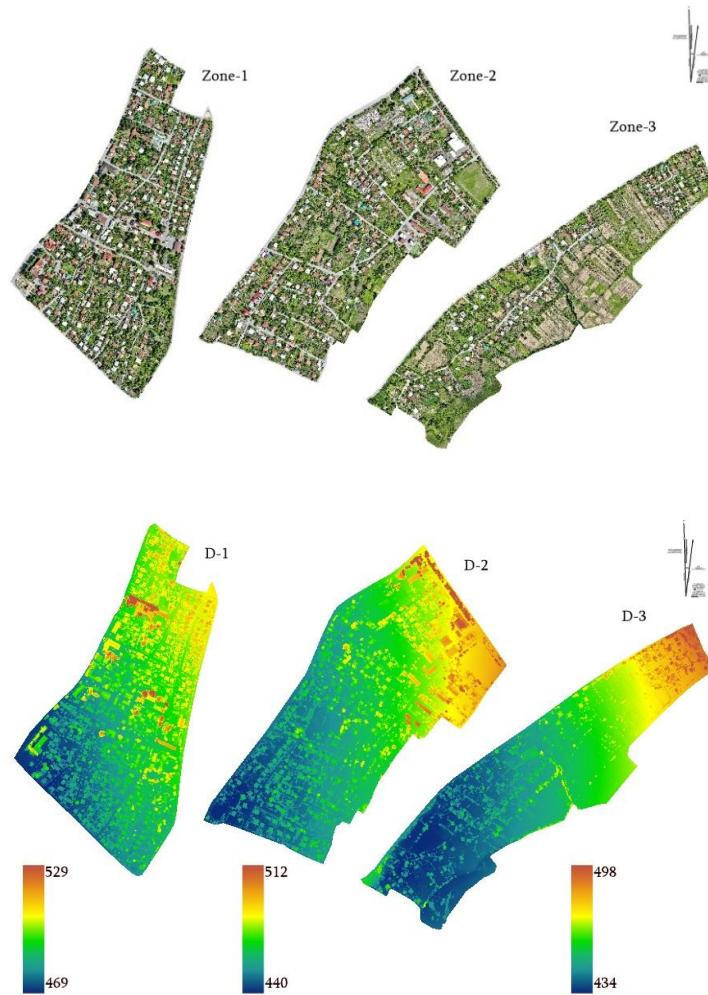
ფიგურა 1. ფრენის ტრაექტორია Zone-2 ორთოფოტოსათვის

სულ შეგროვდა 1600 აეროფოტოსურათი, რომელთა ფოტოგრამეტრული დამუშავების, ორთოფოტო და ციფრული სასიმაღლო მოდელების გენერაციისათვის გამოვიყენეთ Agisoft Metashape Professional 1.8 პროგრამული უზრუნველყოფის საშუალება.

სენსორი	4/3 CMOS, ეფექტური პიქსელები: 20 MP
ლინზა	ხედვის არე: 84° ფორმატი: 24 მმ დიაფრაგმა: f/2.8 - f/11
ჩამკეტის სიჩქარე	8-1/8000 წმ
მაქს. გამოსახულების ზომა	5280x3956

ცხრილი 1. dji Mavic 3 კამერის სპეციფიკაციები

აეროფოტოსურათების დამუშავების შედეგად თითოეული ფრენის არეალისათვის მივიღეთ ძალიან მაღალი გარჩევადობის (პიქსელის ზომა - 3 სმ) ორთომოზაიკები და ციფრული სასიმაღლო მოდელები (ფიგურა 2).



ფიგურა 2. მიღებული ორთოფოტო გეგმები და ციფრული სასიმაღლო მოდელები

გამოსახულებებიდან ობიექტების ავტომატური ამოცნობისა და შენობების დიგიტალიზაციისათვის შეირჩა Mask R-CNN (Mask Region-based Convolutional Neural Network) (He et al., 2017) ღრმა სწავლების მოდელი. მოდელს შეუძლია როგორც ობიექტების ამოცნობა, ისე გამოსახულების სეგმენტაცია პიქსელის დონეზე და წარმოადგენს მანამდე არსებული Faster R-CNN ღრმა სწავლების მოდელის მოდიფიცირებულ ვარიანტს, რომლის გამოყენებაც შესაძლებელი იყო მხოლოდ ობიექტების ამოცნობისათვის, მაგრამ არა სეგმენტაციისათვის. Mask R-CNN-ის სეგმენტაციის შტო თითოეულ ინტერესის რეგიონზე ცალკეული კლასებისათვის წარმოქმნის ზონებს tXt ზომით. ზონის პროგნოზირებისათვის გამოიყენება სიგმოიდის აქტივაციის ფუნქცია:

$$M_{i,j}^{\hat{}} = \sigma(W * X + b) \quad (1)$$

სადაც,  $M_{i,j}^{\hat{}}$  წარმოადგენს პროგნოზირებული ზონის პიქსელების მნიშვნელობებს თითოეული კლასისათვის.

პროგნოზირებული ზონის შემადგენელი პიქსელებისათვის გამოყენებულია ბინარული ჯვარედინი ენტროპიის დანაკარგის ფუნქცია, რომელიც გამოიხატება ფორმულით (2):

$$L_{mask} = -\frac{1}{m^2} \sum_{i,j} [M_{i,j} \log(M_{i,j}^\wedge) + (1 - M_{i,j}) \log(1 - M_{i,j}^\wedge)] \quad (2)$$

სადაც,  $m$  ასახავს პიქსელების რაოდენობას საპროგნოზო ზონაში, ხოლო  $M_{i,j}$  - საწვრთნელი მონაცემების ბინარულ ფენსს.

მოდელისათვის ოპტიმალური პიპერპარამეტრები შეირჩა რამდენიმე ვარიაციის გამოყენებით ექსპერიმენტირების საფუძველზე. შერჩეული პარამეტრები მოცემულია ცხრილი 2-ში.

პარამეტრი	მნიშვნელობა
ქსელი	Mask R-CNN
ხერხემალი	ResNet-101
სწავლების სიჩქარე	0.001
ნაკრების ზომა	4
ეპოქა	70
შემავალი გამოსახულების ზომა	128 x 128
მომენტუმი	0.9
წონის შემცირება	0.0001
აუგმენტაცია	ამობრუნება, როტაცია, სკალირება
დანაკარგის ფუნქცია	ჯვარედინი ენტროპია

ცხრილი 2. მოდელისათვის შერჩეული პარამეტრები

მოდელის გასაწვრთნელად გამოვიყენეთ Zone-1 ორთომოზაიკიდან ხელით აციფრული შენობების მოხაზულობები (ფიგურა 3), საიდანაც აიციფრა 330 შენობა-ნაგებობა. გარდა ამისა, Zone-1 და Zone-3, არსებული შენობა-ნაგებობებით, წარმოადგენს საწვრთნელ და ვალიდაციის მონაცემებს 70% / 30% თანაფარდობით, ხოლო Zone-2 გამოყენებულია როგორც სატესტო არეალი გაწვრთნილი მოდელის შესაფასებლად.

გამოსახულებებიდან შენობების ავტომატური ამოღება დაკავშირებულია რიგ სირთულეებთან, რომელთაგან აღსანიშნავია საკვლევ ტერიტორიაზე წარმოდგენილი შენობების კომპლექსური ფორმა, ზომა, ტექსტურა, ფერი და სახურავის მასალა, აგრეთვე ისეთი ობიექტების არსებობა, როგორიცაა ხეები და ჩრდილები აეროფოტოსურათებზე. მოდელის წარმადობის გასაზრდელად და არასწორად პროგნოზირებული შენობების რაოდენობის შესამცირებლად ორთოფოტოებთან, რომლებიც 3 სპექტრული არხისაგან (RGB) შედეგება, განხორციელდა ციფრული სასიმაღლო მოდელების კომბინირება. შედეგად მივიღეთ 4 არხიანი (RGBD) გამოსახულებები, რომლებიც მოდელს აწვდის არამხოლოდ სპექტრულ, არამედ ტოპოგრაფიულ ინფორმაციასაც, რაც მნიშვნელოვანი მდგრენელია ცვალებადი რელიეფის პირობებში.

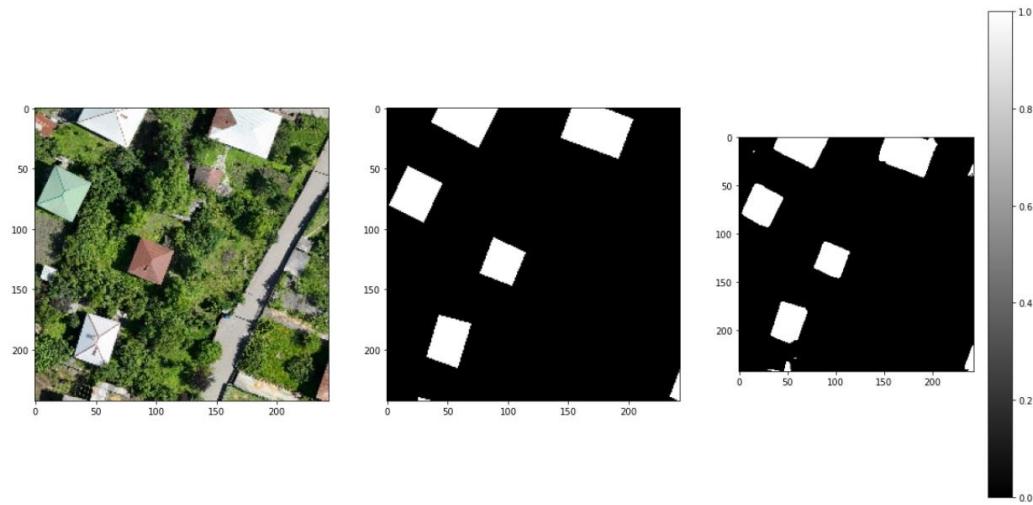


ფიგურა 3. ორთომოზაიკა (Zone-1) აციფრული შენობების გადაფარვით

მიღებული 4 არხიანი გამოსახულებები ცხრილი 2-ში მოცემული სიდიდის შესაბამისად დაიჭრა  $128 \times 128 \times 1$  პიქსელის ზომის ფრაგმენტებად. რაოდენობის გასაზრდელად და მრავალფეროვანი კონტექსტის შესაქმნელად განხორციელდა ამ მონაცემების აუგმენტაცია, მათ შორის გამოსახულებების როტაცია, სკალირება და ა.შ.

### კვლევის შედეგები

Mask R-CNN ღრმა სწავლების მოდელის გაწვრთნის, ოპტიმიზაციისა და შედეგების შეფასებისათვის გამოვიყენეთ Tensorflow Keras V2.16.1 მოდული. ვალიდაციის მოანცემთა ნაკრების ერთ-ერთი ფრაგმენტისათვის პროგნოზირების შედეგი ნაჩვენებია ფიგურა 4-ზე.



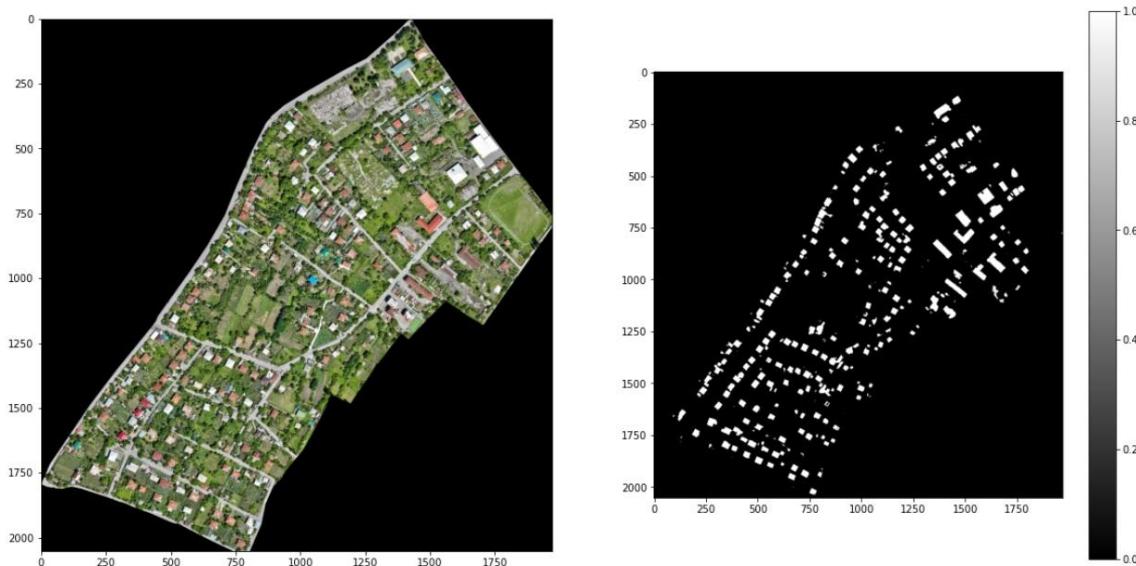
ფიგურა 4. მარცხნიდან მარჯვნივ: 1. RGBD გამოსახულების ფრაგმენტი; 2. ხელით აციფრული შენობები; 3. მოდელის პროგნოზირებული შენობები

ცხრილი 3-ში მოცემულია მიღებული მოდელის წარმადობის შეფასების საზომები სატესტო მონაცემთა ნაკრებისათვის (Zone-2) შესაბამისი მნიშვნელობებით. მოდელმა წარმატებით მოახერხა გამოსახულებაზე არსებული ობიექტებიდან შენობების იდენტიფიცირება 92%-იანი სიზუსტით, რაც საკმაოდ მაღალი მაჩვენებელია.

საზომი	მიღებული მნიშვნელობები	განსაზღვრება
Precision	0.92	აღმოჩენილი ობიექტების 92% სწორად იდენტიფიცირდა როგორც შენობა
Recall	0.84	სატესტო გამოსახულებაზე ფაქტობრივად არსებული შენობების 84% იდენტიფიცირდა სწორად
IoU	0.77	პროგნოზირებული და საწვრთნელი შენობების საზღვრის ჩარჩოების თანხვედრის მაჩვენებელი
F1-Score	0.89	მიღებული Mask R-CNN მოდელის საერთო უჯერტურობა საკლუვი არგალისათვის

ცხრილი 3. მიღებული მოდელის წარმადობის მაჩვენებლები

როგორც ზემოთ აღინიშნა, სატესტო მონაცემს წარმოადგენდა Zone-2 ორთომოზაიკა, რომელიც მოდელს არასდროს „უნახავს“. გამოსახულება ჯამში მოიცავს 450-ზე მეტ განსხვავებული ზომის, ფორმის, შეფერილობისა თუ დანიშნულების შენობა-ნაგებობას. ფიგურა 6-ზე ნაჩვენებია Zone-2 ორთომოზაიკა, მოდელის მიერ აღმოჩენილი შენობების რასტრულ გამოსახულებასთან ერთად.



ფიგურა 5. სატესტო ორთომოზაიკა და მოდელის პროგნოზირების შედეგები

გამოსახულებებზე (ფიგურა 4 და ფიგურა 5) ჩანს, რომ ჩვენს მიერ გაწვრთნილმა მოდელმა როგორც ვალიდაციის, ისე სატესტო მონაცემთა ნაკრებისათვის უმეტესად მაღალი სიზუსტით აღმოაჩინა შენობა-ნაგებობები, ხოლო სხვა ობიექტები, როგორიცაა ღობეები, გზები, ხეები და ა.შ. სწორად მიიჩნია უკანა ფონის სიდიდეებად.

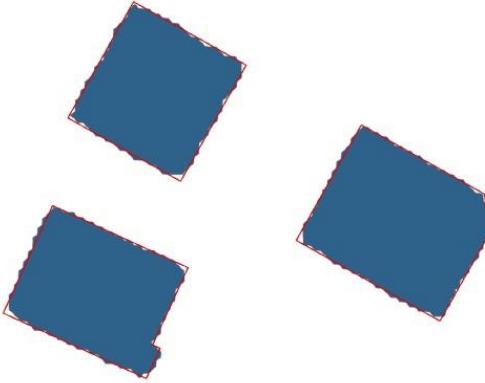
მიუხედავად ამისა, რიგ შემთხვევებში მოდელს მაინც გაუჭირდა ზოგიერთი ხე-მცენარეებით დაფარული და მცირე ზომის შენობების აღმოჩენა (განსაკუთრებით, როცა მათ მიმდებარედ წარმოდგენილია უფრო დიდი ზომის შენობები). გამოსახულების დაჩრდილულ ან პირიქით, გადანათებულ არეალებზე და კომპლექსური უკანა ფონის პირობებში აღმოჩენილი შენობების ნაწილს ჰქონდა არაწესიერი ფორმები. დრონით მიღებულ გამოსახულებაზე, მისი ძალიან მაღალი სივრცული რეზოლუციიდან გამომდინარე, ბევრი მცირე ზომის ობიექტია გარჩევადი. ამ მცირე დეტალებს ზოგჯერ გააჩნია „ხმაურის“ ეფექტი, რაც დამატებით სირთულეს ქმნის შენობის კიდეების გარემომცველი ობიექტებისგან განსხვავების პროცესში. ასევე, რამდენიმე მონაკვეთზე, ძირითადად ასფალტისა და ბეტონის საფარის მქონე გზის ფრაგმენტები არასწორად კლასიფიცირდა შენობად, რაც განპირობებულია ამ ობიექტების ტექსტურული, სტრუქტურული და სპექტრული მსგავსებით. ხშირ შემთხვევაში ეს მსგავსებები დაბალანსდა ციფრული სასიმაღლო მოდელის ინტეგრაციის საშუალებით.



ფიგურა 6. აღმოჩენილი შენობებების მოხაზულობები გადაფარული ორთომოზაიკის ფრაგმენტზე

ფიგურა 6-ზე ნაჩვენებია Zone-2 ორთომოზაიკის ფრაგმენტი მოდელის მიერ აღმოჩენილი შენობების გადაფარვით. ფრაგმენტზე წარმოდგენილია 16, უმეტესად საცხოვრებელი შენობა. როგორც გამოსახულებიდან ჩანს, 16 შენობიდან მოდელმა მაღალი სიზუსტით ამოიცნო თორმეტი, საერთოდ გამორჩა ორი (შენობა 3 და 11), ხოლო კიდევ ორი შენობის (4, 15) მოხაზულობა მნიშვნელოვნად აცდენილია ფაქტობრივ მდგომარეობას, რაც განპირობებულია ზემოთ აღწერილი გარემოებებით.

Mask R-CNN მოდელის მიერ პროგნოზირებული შენობების მთლიანი ფაილი მიიღება რასტრულ ფორმატში, სადაც პიქსელები მნიშვნელობით 1 შეესაბამება შენობა-ნაგებობებს, ხოლო მნიშვნელობით 0 - ყველა დანარჩენ ობიექტს გამოსახულებაზე (ფიგურა 6). შენობების ფენის სხვადასხვა დანიშნულებისამებრ გამოყენებისა და GIS-ში მანიპულაციისათვის განხორციელდა რასტრის კონვერტაცია პოლიგონალურ შეიძფაილებად. ვექტორიზაციის შედეგად მიღებულ შენობის პოლიგონებს გააჩნიათ გარკვეული არტეფაქტები და არასრულყოფილი ფორმები, მათ შორის რასტრული ფენის სპეციფიკიდან გამომდინარე. აღნიშნული უზუსტობების გამოსასწორებლად დამატებით განხორციელდა შენობების ვექტორული ფენის რეგულარიზაცია ე.წ. ხაზის კომპრესიის ალგორითმის (Gribov, 2019) გამოყენებით.



ფიგურა 7. შენობის პოლიგონების რეგულარიზაციის შედეგი

დამუშავების შედეგი და განსხვავება დამუშავებამდე არსებულ შენობების მოხაზულობას შორის მოცემულია ფიგურა 7-ზე. რეგულარიზაციის ეტაპის შედეგად მიღებული შენობების ვექტორული ფენა, შესაძლებელია გამოყენებულ იქნეს შენობების ინვენტარიზაციის, ციფრული რუკების მომზდების, სხვადასხვა გეოგრაფიულ მონაცემებთან ინტეგრაციისა და სხვა გეოსივრცული ამოცანებისათვის.

## დასკვნა

მოცემული კვლევის მიზანს წარმოადგენდა ერთის მხრივ, უპილოტო საფრენი აპარატებით ძალიან მაღალი გარჩევადობის ორთოფოტოგეგმების მომზადების, ხოლო მეორეს მხრივ, მიღებული გამოსახულებებიდან ხელოვნური ინტელექტის მოდელების გამოყენებით ობიექტების ავტომატური ამოცნობისა და აციფვრის შესაძლებლობების შეფასება საქართველოს პირობებისათვის. ამ მიზნების განსახორციელებლად გამოყენებული dji Mavic 3 უპილოტო საფრენი აპრატის საშუალებით მივღეთ 3 სანტიმეტრიანი სივრცული რეზოლუციის ორთომოზაიკები და ციფრული სასიმაღლო მოდელები ქალაქ ცაგერისა და სოფელ ჭალისთავის 128 ჰექტარი ტერიტორიისათვის. გამოსახულებებიდან შენობების ავტომატური ამოცნობისათვის გამოიცადა Mask R-CNN ღრმა სწავლების მოდელი, სხვადასხვა ჰიპერპარამეტრების კომბინაციით. საბოლოოდ შერჩეულმა მოდელმა აჩვენა 92%-იანი საერთო სიზუსტე საკვლევ არეალზე შენობების ამოცნობისათვის.

მიუხედავად წინა თავებში განხილული ლიმიტაციებისა, შეიძლება ითქვას, რომ სტატიაში აღწერილი მეთოდოლოგიის გამოყენებით ეფექტურადაა შესაძლებელი სხვადასხვა

სივრცული მონაცემების სწრაფად და ნაკლები მატერიალური დანახაჯებით მოპოვება ტრადიციულ მეთოდებთან შედარებით. კვლევის შემდგომი ეტაპებისათვის რეკომენდირებულია უპილოტო საფრენი აპარატებით აეროფოტოსურათების მოპოვების და დამუშავების განსხვავებული ტექნიკის დასატესვა სხვადასხვა გარემო-პირობებში, აგრეთვე უფრო ღრმა ქსელების და პარამეტრების ვარიაციების გამოცდა განსხვავებული ობიექტების ავტომატური დეშიფრირებისათვის.

## 2. გამოყენებული ლიტერატურა

Audebert, N., Le Saux, B., & Lefevre, S. (2018). Beyond RGB: Very high resolution urban remote sensing with multimodal deep networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 140, 20-32. <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2017.11.011>

Calantropio, A., Chiabrando, F., Codastefano, M., & Bourke, E. (2021). DEEP LEARNING FOR AUTOMATIC BUILDING DAMAGE ASSESSMENT: APPLICATION IN POST-DISASTER SCENARIOS USING UAV DATA. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v-1-2021, 113-120. <https://doi.org/10.5194/isprs-annals-V-1-2021-113-2021>

Colomina, I., & Molina, P. (2014). Unmanned Aerial Systems for Photogrammetry and Remote Sensing: A Review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92, 79-97. <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2014.02.013>

Gribov, A. (2019). Optimal Compression of a Polyline While Aligning to Preferred Directions. *International Conference on Document Analysis and Recognition Workshops (ICDARW)*, (pp. 98-102). Sydney, NSW, Australia. <https://doi.org/10.1109/ICDARW.2019.00022>

He, K., Gkioxari, G., Dollar, P., & Girshick, R. (2017). Mask R-CNN. *IEEE International Conference on Computer Vision (ICCV)*, (pp. 2980-2988). Venice, Italy. <https://doi.org/10.1109/ICCV.2017.322>

# UAVs and AI for Very High Resolution Map Creation and Automatic Object Detection

## Abstract

Automation of object detection and extraction from VHR aerial imagery for high definition mapping is significant challenge for various remote sensing and photogrammetry applications. This study investigates the use of Unmanned Aerial Vehicles (UAVs) and Deep Learning models to enhance the traditional, manual methods and increase accuracy and efficiency of spatial data acquisition and processing. The dji Mavic 3 UAV was used to capture high-resolution aerial images over a 128 hectare area in town Tsageri and village Chalistavi, located in the Racha-Lechkhumi and Lower Svaneti region, Georgia.

One of the main objective of this research was to detect and extract building footprints from generated orthomosaics using deep learning techniques. The Mask Region-based Convolutional Neural Network (Mask R-CNN) was employed for this task. To further improve the model's performance, Digital Elevation Models were integrated with the orthomosaics, resulting in a four-channel raster that provided additional topographical context for more accurate building extraction.

The findings indicate that the integration of Unmanned Aerial Vehicles and Deep Learning techniques offers significant improvements in acquisition and processing efficiency of geospatial data. Namely, we were able to create VHR orthomosaics with spatial resolution of 3.2 cm using dji Mavic 3 UAV. Trained Mask R-CNN model showed 92% precision for building prediction in the study area. Methods and techniques described in this paper have important implications for various applications, including land administration, infrastructure development and environmental management. Methodology used in present study provides a valuable framework for future researches and practical applications, especially in such developing and mountainous countries as Georgia, where high-resolution and accurate spatial data is often unavailable due to complex environmental conditions and economic factors.

**Keywords:** UAVs, DEM, Orthomosaic, Artificial Intelligence, Automatic object detection