

DETEKCIA OBJEKTOV Z KAMERY DRONA V OUTDOOR PROSTREDÍ S VYUŽITÍM DEEP LEARNINGU

Analýza a návrh riešenia

Autor: Bc. Jakub Nilabovič
Vedúci práce: RNDr. Ľubomír Antoni, PhD.

1 Úvod

Diaľkovo alebo autonómne riadené bezpilotné vozidlá, inak povedané drony, sa v dnešnej dobe používajú pri hľadaní stratených osôb v ťažkom teréne, kontrolu rastu obilia na poliach, pri natáčaní filmov alebo zachytávaní akčných záberov športových aktivít a tak ďalej. Pri mnohých účeloch sa využíva umelá inteligencia, konkrétne metódy strojové a hlbokého učenia pre rôznorodú autonómiu dronov. Práve pre športové aktivity sú drony veľmi obľúbenou formou tvorby videozáznamov, no častokrát je okolité prostredie nevhodné pre autonómne drony a pre ich ovládanie sú potrební profesionálni piloti, najčastejšie tzv. freestylových dronov. Freestylové drony majú najlepšiu manévrovateľnosť zo všetkých kategórií dronov a častokrát sú poskladané zo súčiastok rôznych výrobcov, nie sú z „jedného kusu“ a sú hardwarovo veľmi prispôsobiteľné. Vďaka prispôsobivej kompatibilite je možné k dronu pripojiť rôzne platformy a moduly s výkonnými grafickými čipmi, ktoré sú schopné využívať hlboké učenie a v reálnom čase napríklad detegovať objekty pomocou kamery drona. Keďže je obtiažne využívať autonómne drony v náročnejších prostrediach, chceme sa v diplomovej práci zamerať na vytvorenie metód pre detekciu objektov v lesnom prostredí a pohotovú manévrovateľnosť drona v tomto prostredí. Úlohou drona bude taktiež sledovanie vopred stanovenej osoby ako napríklad cyklistu. V ďalších krokoch sa zameriame aj na metódy nahrávania video záberov behom letu.

Existuje mnoho komerčných dronov, ktoré využívajú deep learning pre rôznorodé účely. Pre výskumné riešenia podobných problémov je nutné zaobstarať si vhodnú platformu s dostatočne výkonným procesorom/grafickým čipom. Mnoho prípustných riešení

dokážu zvládnuť napr. Raspberry Pi modely s procesorovým akcelerátorom ako je Intel Movidius Stick a podobne, no pre komplexnejšie účely je nutné využiť ďaleko výkonnejšie platformy. Rozhodli sme sa zamerať na použitie platformy Jetson Nano s grafickým čipom od spoločnosti Nvidia. Je viac podobných problémov, ktoré boli riešené použitím práve tejto platformy, dokonca aj detekcia objektov z kamery drona.

1 Dron ako UAV

UAV je skratka pre bezpilotné vzdušné vozidlo, čo je vozidlo bez pilota na palube. UAV môže byť diaľkovo ovládané lietadlo (napr. ovládané pilotom na pozemnej riadiacej stanici), alebo môže lietať samostatne na základe predprogramovaných letových plánov alebo zložitejších dynamických automatizačných systémov. V súčasnosti sa používa na množstvo misií, vrátane prieskumných a útočných rolí. Pre odlišenie UAV od rakiet je UAV definované ako schopný riadeného, trvalého letu poháňaného prúdovým, elektrickým alebo vratným motorom.

FAA prijala akronym UAS, čo odráža skutočnosť, že tieto komplexné systémy zahŕňajú pozemné stanice a iné prvky okrem skutočných leteckých dopravných prostriedkov. Oficiálne sa pojem „bepilotné vzdušné dopravné prostriedky“ zmenil na „bepilotný letecký systém“. Termín UAS však nie je široko používaný, pretože termín UAV sa stal súčasťou moderného lexikónu. Počas niekoľkých desaťročí, prešlo UAV z konceptu sci-fi do každodennej reality. Mnohé z týchto aplikácií vzdušných prostriedkov boli však vyvinuté v armáde a široká verejnosť videla, že UAV sa vyvíjajú ako špionážne alebo prieskumné vozidlá používané počas vojny. Nedávno však spotrebitelia zaznamenali vývoj týchto typov lietadiel pre verejné trhy. Lietadlá a helikoptéry na diaľkové ovládanie môžu byť tiež klasifikované ako bepilotné lietadlá, ak majú osobitné druhy výkonu a schopnosti diaľkového ovládania. Jedným z príkladov je navrhované použitie lietajúcich robotov alebo UAV na doručovanie balíkov, alebo ako prostriedkov na boj proti požiarom či policajným pomocníkom.

V dnešnej dobe je UAV tiež známe ako dron. Drony sú využívané z mnohých dôvodov na natáčanie, vojenské sledovanie a rekreačné

aktivity. Spadajú pod oblasť kozmického priestoru, robotiky a mechatroniky. Termín dron však môže byť veľmi zavádzajúci, pretože existuje mnoho rôznych druhov. Dnes je tradičný dron tvorený rámom. Pre každé rameno je samostatný motor, ktorý má prevažne jednu vrtuľu. Má tiež elektronický regulátor otáčok, ktorý prevádzkuje motory. Riadiaca jednotka (letový kontrolér) spracováva všetky podstatné informácie o ovládaní dronu pilotom a o pohybe dronu z inerciálnej mernej jednotky (IMU), ktorá je internou alebo externou súčasťou riadiacej jednotky a vytvára signály pre ovládanie motorov. Vysielač a prijímač pomáhajú pri komunikácii medzi dronom a osobou na zemi, ktorá ho ovláda. Prijímač je pripojený k riadiacej jednotke. Poslednou hlavnou súčasťou je batéria, poháňajúca celé toto zariadenie. Pre typ dronu, ktorý je vyššie popísaný, sa taktiež využíva termín multikoptéra alebo multirotor, teda lietadlo s rotujúcimi nosnými plochami, ktoré má viac ako dva motory. Názvy trioptéra, kvadrokoptéra, hexakoptéra a oktokoptéra sa často používajú na označenie 3, 4, 6 a 8-rotorových vzdušných vozidiel.

V tejto práci sa pre praktickú implementáciu využíva kvadrokoptéra. Čo sa týka letového mechanizmu, tak kvadrokoptéra využíva štyri rôzne vrtule, poháňané štyrmi rôznymi motormi, umiestnenými na štyroch samostatných ramenách. Každá rotujúca vrtuľa vytvára svoj vlastný krútiaci moment. Newtonov tretí zákon uvádza, že pre každú akciu existuje reakcia. Ak sa vrtuľa otáča, rameno, ktoré ju drží, sa bude tiež chcieť otáčať v opačnom smere. Tento jav sa nazýva reakčný točivý moment a to je dôvod, prečo má napríklad tradičný vrtuľník chvostový rotor, ktorý kompenzuje točivý moment trupu. Kvadrokoptéra nepotrebuje chvostový rotor, pretože sa využíva princíp dvoch susedných rotorov, ktoré majú opačné krútiace momenty. Jedna vrtuľa navzájom ruší krútiaci moment susednej vrtule. To umožňuje kvadrokoptéram vznášanie sa. Ak by vznášajúci sa vrtuľník potreboval využiť viac energie, bolo by to viac krútiaceho momentu a z chvostového rotora by bolo potrebné viac energie. Zvládnutie vyrovnanie točivých momentov je fyzikálne náročnejšie ako u multikoptérach, najmä aby pohyb vyzeral hladko. Tieto problémy však vo viac rotorových dronoch neexistujú, pretože zvyšovanie výkonu sa vždy vykonáva tak, že dve vrtule sa otáčajú v smere a dve vrtule v proti smere hodinových ručičiek. Pri pohybe dopredu, sa pre obe predné vrtule aplikuje menej energie, zatiaľ čo pre zadné vrtule viac. Tento princíp platí pre všetky smery otáčania. Pohyb stáčania je však odlišný. Ak by sa mal dron stočiť

doľava, znamená to, že reakcia krútiaceho momentu bude výraznejšia vo vrtuliach s pravým smerom otáčania (v smere hodinových ručičiek). Keďže pri roztočení rotora vzniká opačná sila vzhľadom na rám, tak sa rám a teda celá kvadrokoptéra stočí doľava. Vzostupný a zostupný pohyb je veľmi jednoduchý. Výkon je buď zvýšený alebo znížený na celý systém vrtúl, aby dron stúpал alebo aby sa dosiahol zostup.

2 Umelá inteligencia


Umelá inteligencia je vedná disciplína, ktorej cieľom je automatizácia intelektuálnych úloh pomocou inteligentných strojov. Intelligentné stroje pomocou algoritmu vytvoreného človekom napodobňujú ľudské kognitívne funkcie a správanie, ako je napríklad učenie alebo riešenie problémov. Typickým príkladom je riadenie robotov, autonómna navigácia automobilov, rozpoznávanie reči alebo obrazu alebo súťaženie s človekom v strategických hrách. V roku 2019 vzniklo Slovenské centrum pre výskum umelej inteligencie (Slovak.AI) ako platforma pre excelenciu v umelej inteligencii a platforma prepájajúca študentov, výskumníkov, podnikateľov, učiteľov, investorov a všetkých ďalších, ktorí sa zaujímajú o umelú inteligenciu. Umelú inteligenciu môžeme vnímať aj širšie. Môžeme hovoriť o digitálnej inteligencii, ktorá integruje do jedného spoločného celku umelú inteligenciu, cloudové počítanie, internet všetkého, virtuálnu realitu a niektoré ďalšie oblasti.

2.1 Hlboké učenie

Hlboké učenie (Deep learning) je trieda algoritmov strojového učenia, ktoré používajú viac vrstiev na postupné extrahovanie funkcií na vyššej úrovni zo surového vstupu. Napríklad pri spracovaní obrazu môžu nižšie vrstvy identifikovať hrany, zatiaľ čo vyššie vrstvy môžu identifikovať koncepty dôležité pre človeka, ako sú číslce, písmená alebo tváre. Pomocou modelu hlbokého učenia si môže algoritmus sám určiť, či je predikcia výsledku presná alebo nie, prostredníctvom vlastnej neurónovej siete.

2.2 Analýza obrazu

Z hľadiska analýzy obrazu je rozpoznávanie objektov všeobecný pojem pre opis súvisiacich úloh počítačového videnia, ktoré zahŕňajú identifikáciu objektov na digitálnych fotografiách.



Obrázok 1 Overview of Object Recognition Computer Vision Tasks

Môžeme rozlišovať medzi týmito tromi základnými úlohami počítačového videnia:

- Klasifikácia obrazu: Predikcia typu alebo triedy objektu na obrázku.

Vstup: Obrázok s jedným objektom, napríklad fotografia.

Výstup: Štítok triedy (napr. jedno alebo viac celých čísel, ktoré sú namapované na štítky triedy).

- Lokalizácia objektov: Nájdenie prítomnosti objektov na obrázku a označenie ich polohy

ohraničovacím rámčekom.


Vstup: Obrázok s jedným alebo viacerými objektmi, napríklad fotografia.

Výstup: Jedno alebo viac ohraničovacích rámcov (napr. definovaných bodom, šírkou a výškou).

- Detekcia objektov: Nájdenie prítomnosti objektov pomocou ohraničovacieho rámčeka a typov alebo tried umiestnených objektov na obrázku.

Vstup: Obrázok s jedným alebo viacerými objektmi, napríklad fotografia.

Výstup: Jeden alebo viac ohraničovacích rámcov (napr. definovaných bodom, šírkou a výškou) a označenie triedy pre každé ohraničujúce rámčeky.



Obrázok 2 ukážka detekcie objektov

2.3 Konvolučné neurónové siete

Dosiahnutie nášho riešenia spočíva vo využití detekcie objektov. Týmto metódam sa venujú CNN (konvolučné neurónové siete). Konvolučné neurónové siete sú trieda hlbokých neurónových sietí. Názov „konvolučná neurónová sieť“ naznačuje, že sieť využíva matematickú operáciu nazývanú konvolúcia. Konvolučné siete sú

špecializovaný typ neurónových sietí, ktoré používajú konvolúciu namiesto násobenia všeobecných matic najmenej v jednej z ich vrstiev. Konvolučná neurónová sieť sa skladá zo vstupnej a výstupnej vrstvy a tiež z viacerých skrytých vrstiev. Skryté vrstvy CNN zvyčajne pozostávajú zo série konvolučných vrstiev. Aktivačná funkcia je zvyčajne vrstva ReLU a za ňou postupne nasledujú ďalšie konvolúcie, ako sú združovacie vrstvy, úplne spojené vrstvy a normalizačné vrstvy, ktoré sa označujú ako skryté vrstvy, pretože ich vstupy a výstupy sú maskované aktivačnou funkciou a konečnou konvolúciou. Návrh neurónových sietí v tejto práci pozostáva z analýzy MobileNet architektúry (ktorá využíva hĺbkovú a bodovú konvolúciu nasledovanú batch normalizáciou a ReLu) a Fast R-CNN (rýchlejšia R-CNN má dve siete: regionálna návrhová sieť (RPN) na generovanie regionálnych návrhov a sieť využívajúca tieto návrhy na detekciu objektov).



Obrázok 3 Konvolučná sieť

2.4 MobileNet architektúra


MobileNet je efektívna a prenosná architektúra CNN, ktorá sa používa v aplikáciách v reálnom svete. MobileNet primárne používa na vytvorenie ľahších modelov hĺbkovo oddeliteľné konvolúcie namiesto štandardných konvolúcií použitých v predchádzajúcich architektúrach. MobileNet zavádza dva nové globálne hyperparametre (multiplikátor šírky a multiplikátor rozlíšenia), ktoré umožňujú vývojárom modelov vymeniť latenciu alebo presnosť za rýchlosť a malú veľkosť v závislosti na ich požiadavkách.

MobileNet architektúry sú postavené na hĺbkovo oddeliteľných vrstvách konvolúcie. Každá hĺbkovo oddeliteľná vrstva konvolúcie sa

skladá z hĺbkovej konvolúcie a bodovej konvolúcie. Počítaním hĺbkových a bodových konvolúcií ako samostatných vrstiev má MobileNet 28 vrstiev. Štandardný MobileNet má 4,2 milióna parametrov, ktoré je možné ďalej meniť sa vhodným vyladením hyperparametra šírky.

Mulplikátor šírky (označený ako α) je globálny hyperparameter, ktorý sa používa na konštrukciu menších a menej výpočtovo nákladných modelov. Jeho hodnota leží medzi 0 a 1. Pre danú vrstvu a hodnotu α sa počet vstupných kanálov „M“ stane $\alpha * M$ a počet výstupných kanálov „N“ sa stáva $\alpha * N$, čím sa znižujú náklady na výpočet a veľkosť modelu za cenu výkonu. Náklady na výpočet a počet parametrov sa zhruba znížia o faktor α^2 . Niektoré bežne používané hodnoty α sú 1,0,75,0,5,0,25.

Druhý parameter zavedený v MobileNet sa nazýva multiplikátor rozlíšenia a je označený ρ . Tento hyperparameter sa používa na zníženie rozlíšenia vstupného obrázka, čo následne znižuje vstup do každej vrstvy o rovnaký faktor. Pre danú hodnotu ρ sa rozlíšenie vstupného obrazu stane $224 * \rho$. To znižuje výpočtové náklady o faktor ρ^2 .



Obrázok 4 MobileNet architektúra, využívajúca hĺbkovú a bodovú konvolúciu nasledovanú batch normalizáciou a ReLu

3 Systémy pre spracovanie obrazu dronom


Hlavným problémom spracovania obrazu dronom je ten, že dron super výkonné počítače z hľadiska rozmeru a váhy neunesie. Preto sa

štandardne zaviedli 2 druhy systémov. Palubný systém s využitím grafických procesorov spracováva obraz vďaka kompaktným malým platformám alebo modulom, ktoré nie sú tak výkonné ako fyzické počítače, ktoré využívajú najlepšie grafické karty, ale sú prispôsobené na riešenie optimalizovaných problémov. Druhým systémom je mimo palubný systém, kde dron iba vysiela snímané video k pozemnej stanici a stanica tak nemá žiadne obmedzenia pre použitie výkonných grafických procesorov.

3.1 Palubný GPU systém

Palubný systém GPU sníma letecké záznamy a dodáva dáta do palubného modulu, ako je znázornené na obrázku 5. Systém v tomto prípade generuje rámec výsledkov detekcie s menom a percentom spoľahlivosti.

V tomto procese je modul zodpovedný za spracovanie celého algoritmu a prenos dát cez sieť. Pozemná stanica, ktorá je spojená s touto sieťou, prijíma údaje o vysielaní a zobrazuje výsledky. Z výstupu monitorovania je tiež možné získať detegovaný cieľový názov, spoľahlivosť a upozornenie.




Obrázok 5 Palubný GPU systém s využitím Jetson AGX Xavier

3.2 Mimo palubný GPU systém

Palubný systém zvyčajne vykonáva všetku prácu sám, v tomto systéme však palubné zariadenie vykonáva iba časť práce. Palubné zariadenie je zodpovedné za streamovanie zaznamenaných obrazových údajov. Teda na drone sú zobrazovacie procesory a nastavenia prenosového systému v reálnom čase na komunikáciu s pozemnou stanicou. Pozemná stanica založená na GPU prijíma údaje a algoritmus na spracovanie nespracovaných obrazových.

Na obrázku 6 je zobrazený príklad diagramu celej pozemnej stanice mimo GPU. Neskôr sa detegovaný cieľ zobrazí spolu s menom a spoľahlivosťou na monitore pozemnej pracovnej stanice. Takáto stanica taktiež vie zasahovať do ovládania drona, ak by dochádzalo k rôznym problémom.



Obrázok 6 Mimopalubný systém využívajúci GTX 1080

4 Návrh riešenia

Z pohľadu detekcie objektov je pred vytvorením deep learning systému potrebné získanie dostatočného množstva dát. Pre naučenie potrebných objektov ako je bicykel, cyklista alebo strom sa využíva dataset COCO, ktorý obsahuje segmentované objekty rôzneho typu. Pri riešení tohto problému budú testovacie dáta tvoriť videozáznamy a fotografie lesného prostredia, ktoré obsahujú označené objekty rámečkmi a štítkom. Pri získavaní dát sa využili kamery pripevnené k hrudi a helme cyklistu a taktiež pilotovanie drona s pripevnenou kamerou ku konštrukcii. Pre doplnenie databázy dát môžeme využiť videozáznamy a fotografie z internetu.

Výsledným riešením je využitie mobilnej siete, ktorá je pripravená na fyzickom výkonnom počítači a takýto upravený a natrénovaný systém sa využije priamo na platforme drona, ktorá sa využíva na spracovávanie obrazu v reálnom čase.

4.1 COCO dataset


Dátová sada MS COCO (Microsoft Common Objects in Context) je rozsiahla dátová sada na detekciu objektov, segmentáciu, detekciu kľúčových bodov a titulkové súbory. Dataset pozostáva z 328 tis. Obrázkov. Prvá verzia dátového súboru MS COCO bola vydaná v roku 2014. Obsahuje 164 tis. Obrázkov rozdelených na cvičné (83 tis.), Validačné (41 tis.) A testovacie (41 tis.) Sady. V roku 2015 bola vydaná ďalšia testovacia sada 81 000 obrázkov, vrátane všetkých predchádzajúcich testovacích obrázkov a 40 000 nových obrázkov.

Na základe spätnej väzby od komunity sa v roku 2017 rozdelenie školenia a overovania zmenilo z 83K / 41K na 118K / 5K. Nové rozdelenie používa rovnaké obrázky a anotácie. Testovacia sada z roku 2017 je podmnožinou 41 tis. Obrázkov testovacej sady z roku 2015. Vydanie z roku 2017 navyše obsahuje nový neoznačený súbor údajov s veľkosťou 123 kB. COCO má niekoľko funkcií ako segmentácia objektov, rozpoznávanie v kontexte, segmentácia superpixelových vecí a podobne.

4.2 Platforma Nvidia Jetson Nano

Vývojová platforma Jetson Nano alebo Jetson Xavier NX, ktorá má výkonný a zároveň optimalizovaný grafický procesor spoločnosti NVIDIA. Grafický procesor tvorí 128 jadrový NVIDIA Maxwell™ architecture-based GPU a centrálny procesor štvorjadrový ARM® A57. Jetson dokáže spracovávať video v rozlíšení 4K s 30 fps (pri kodeku H.264/H.265) alebo 4K so 60 fps (s kodekom H.264/H.265). Pamäť tvorí 4 GB 64-bit LPDDR4 s prenosovou rýchlosťou 25.6 GB za sekundu. Podporuje operačný systém Linux Tegra®. Modul má rozmery 100mm x 80mm a váhu 250g.

Táto platforma má dostačujúce parametre, pre zvládnutie problémov ako sú detekcia a sledovanie objektov s využitím ovládania drona, čoho je dôkazom mnoho podobných projektov riešených komunitou Jetson Nano.




Obrázok 7 Nvidia Jetson Nano

4.3 Simulácia v prostredí UNITY

Pri dosiahnutí dostatočne správneho spracovania malými testami je rozumné zlepšovanie systému na princípe počítačových simulácií oproti reálnym letovým testom pre časové obmedzenie letu z hľadiska

vybíjania batérie a taktiež kde je možné riziko nehôd, pri ktorých by mohlo dôjsť k vážnym poruchám dronu a jeho súčastí.

Unity (NYSE: U) je popredná svetová platforma pre vytváranie a prevádzkovanie 3D obsahu (RT3D) v reálnom čase. Tvorcovia, od vývojárov hier až po umelcov, architektov, automobilových dizajnérov, filmových tvorcov a ďalších, používajú Unity na oživenie svojich fantázií. Platforma Unity poskytuje komplexnú sadu softvérových riešení na vytváranie, prevádzkovanie a monetizáciu interaktívneho 2D a 3D obsahu v reálnom čase pre mobilné telefóny, tablety, počítače, konzoly a zariadenia rozšírenej a virtuálnej reality. Tím výskumu a vývoja spoločnosti zameraný na viac ako 1 800 osôb udržiava spoločnosť Unity v čele vývoja vďaka spolupráci s partnermi, aby zabezpečila optimalizovanú podporu pre najnovšie vydania a platformy. Aplikácie vyvinuté tvorcami Unity boli v roku 2020 stiahnuté viac ako päť miliárdkrát mesačne.



Obrázok 8 Digitálne prostredie lesa v UNITY

Na obrázku je príklad digitálneho prostredia, v ktorom je možná simulácia detekcie objektov. S dostupných knižníc, ktoré obsahujú model dronu a jeho fyzikálne správanie sa v priestore, sa k výslednej simulácii dá pristupovať porovnateľne ako pri lietaní dronom v reálnom prostredí.

Záver

V posledných rokoch sa zvyšuje dopyt po detekcii a sledovaní cieľov z leteckého snímkovania pomocou dronov a za pomoci palubných napájaných senzorov a zariadení. Pre riešenie tohto problému sa využívajú efektívne metódy založené na princípe hlbokého učenia. Zabudovaný hardvérový systém umožňuje dronom vykonávať palubné výpočty potrebné na sledovanie objektov v reálnom čase. Moduly s grafickými procesormi ako je napríklad Nvidia Jetson sú vhodné pre výpočty v reálnom čase aj na malých lietajúcich dronoch.

Pre získanie podrobných metrických údajov o snímkových frekvenciách a výpočtovom výkone sme vykonali komparatívnu analýzu súčasných najmodernejších algoritmov detekcie viacerých objektov založených na hlbokom učení s využitím GPU. Systém metód sledovania pohybujúcich sa objektov je založený na rozšírení jednoduchého sledovania v reálnom čase. Je vyvíjaný integráciou prístupu asociačnej metriky založenej na hlbokom učení a jednoduchého online sledovania a sledovania v reálnom čase, ktorý využíva metodiku sledovania hypotéz s Kalmanovým filtrovaním a asociačnú metriku založenú na hlbokom učení. Ďalej je zavedený navigačný systém, ktorý sleduje cieľovú polohu pomocou algoritmu založeného na GPU.

Pre čo najpresnejšiu úpravu parametrov systému je dostupná simulácia pohybu v digitálnom prostredí UNITY. V neskorších krokoch po dosiahnutí požadovaného výsledku simulácií bude možné prejsť na testovanie systému pri reálnom lete drona.

Literatúra

1. NILABOVIČ J., ANTONI, Ľ., Autonómne ovládanie drona na rekonštrukciu pôdorysu interiéru, Bakalárska práca. Košice, Univerzita Pavla Jozefa Šafárika v Košiciach, 2019.
2. ANTONI, Ľ., PARALIČ, J., BUTKA, P. et al. Dátová veda a jej aplikácie, 1. vydanie. Košice, Univerzita Pavla Jozefa Šafárika v Košiciach, 2020. ISBN 978-80-8152-917-7.
3. HOSSAIN, Sabir; LEE, Deok-jin. Deep learning-based real-time multiple-object detection and tracking from aerial imagery via a flying robot with GPU-based embedded devices. Sensors, 2019, 19.15: 3371.

4. BUDIHARTO, Widodo, et al. Fast object detection for quadcopter drone using deep learning. In: 2018 3rd International Conference on Computer and Communication Systems (ICCCS). IEEE, 2018. p. 192-195.
5. HOWARD, Andrew G., et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications. arXiv preprint arXiv:1704.04861, 2017.
6. KÖREZ, Atakan; BARIŞÇI, Necaattin. Object Detection with Low Capacity GPU Systems Using Improved Faster R-CNN. Applied Sciences, 2020, 10.1: 83.
7. REN, Shaoqing, et al. Faster r-cnn: Towards real-time object detection with region proposal networks. IEEE transactions on pattern analysis and machine intelligence, 2016, 39.6: 1137-1149.
8. Deep learning [online]. [cit. 2020-12-24]. Dostupné z: https://en.wikipedia.org/wiki/Deep_learning
9. Deep learning vs machine learning [online]. [cit. 2020-01-23]. Dostupné z: <https://www.zendesk.com/blog/machine-learning-and-deep-learning/>
10. Object Recognition [online]. [cit. 2019-05-22]. Dostupné z: <https://machinelearningmastery.com/object-recognition-with-deep-learning/>
11. Convolutional neural network [online]. [cit. 2019-05-22]. Dostupné z: https://en.wikipedia.org/wiki/Convolutional_neural_network
12. Faster R-CNN [online]. [cit. 2019-05-22]. Dostupné z: <https://medium.com/@smallfishbigsea/faster-r-cnn-explained-864d4fb7e3f8>
13. COCO [online]. [cit. 2014-05-01]. Dostupné z: <https://paperswithcode.com/dataset/coco>
14. JU, Cheng; BIBAUT, Aurélien; VAN DER LAAN, Mark. The relative performance of ensemble methods with deep convolutional neural networks for image classification. Journal of Applied Statistics, 2018, 45.15: 2800-2818.
15. Forest Scene in Unity [online]. [cit. 2019-07-26]. Dostupné z: <https://80.lv/articles/realistic-scanned-assets-for-forest-scenes-in-unity/>