

TECHNICKÁ UNIVERZITA V KOŠICIACH
FAKULTA ELEKTROTECHNIKY A INFORMATIKY



Konferencia UAV 2023

Kód projektu: 313011V422
„Inteligentné operačné a spracovateľské systémy pre UAV“

ISBN 978-80-553-4389-1

2023

Zborník z konferencie UAV 2023

Vydavateľ: Fakulta elektrotechniky a informatiky
Technická univerzita v Košiciach
Letná 9, 040 01 Košice, Slovenská republika

Dátum vydania: máj 2023

Tlač: 50 kusov CD

Jazyk: slovenský, anglický

Strán: 86

Predseda redakčnej rady: doc. Ing. Ján Genči, PhD.

Odborní garanti: prof. RNDr. Peter Vojtáš, DrSc.
doc. Ing. Ján Genči, PhD.
Ing. Štefan Mičko

Programový výbor: Ing. Juraj Vojtáš
doc. Ing. František Jakab, PhD.
Ing. Roman Hraško
Ing. Ondrej Kainz, PhD.

Editor: Ing. Miroslav Michalko, PhD.

O konferencii UAV 2023

Projektová konferencia UAV 2023 bola organizovaná na pôde Technickej univerzity v Košiciach, v rámci prezentačných priestorov Univerziténeho vedeckého parku TECHNICOM, v dňoch 11. – 12. 5. 2023, v rámci projektu:

Názov projektu: Inteligentné operačné a spracovateľské systémy pre UAV

Kód projektu: 313011V422

Prijímateľ NFP: GLOBESY, s.r.o.

Partneri: Qintec a.s.

YMS, a.s.

Technická univerzita v Košiciach (TUKE)

Žilinská univerzita v Žiline (UNIZA)

(ďalej len „projekt UAV“).

Projekt UAV je spolufinancovaný z prostriedkov Európskeho fondu regionálneho rozvoja v rámci Operačného programu Integrovaná infraštruktúra.



Riadiaci orgán:



V zastúpení na základe splnomocnenia:



Obsah

Csaba SZABÓ, Ján KAŠPÁREK

Simulátor letu drónom: model, architektúra a overenie prototypu skúškou 6

Ivan ILAVSKÝ, Peter BOBÁL, Radovan HILBERT, Tomáš IVAN

Využitie virtuálnej reality pre vizualizáciu výsledkov priestorového monitoringu 12

Peter PEKARČÍK, Eva CHOVANCOVÁ

Bezpečnostná analýza útokov na UAV 15

Peter BOBÁL, Radovan SUNEGA, Veronika HORNÍKOVÁ

Priestorový monitoring s využitím GIS 23

Branislav SOBOTA, Štefan KOREČKO, Miriama MATTOVÁ, Lukáš JASENKA

Koncepcia virtuálno-reálného prostredia pre simuláciu práce dronov..... 28

Peter VOJTÁŠ

Image data annotated by objects distances 34

Marek TÓTH, Daniel HREHA, Maroš HLIBOKÝ, Ján MAGYAR, Marek BUNDZEL, Peter SINČÁK

Lokalizácia a plánovanie trasy dronov inteligentnom priestore 40

Ondrej KAINZ, Jakub FRANKOVIČ, Miroslav MICHALKO, František JAKAB

Detekcia zoskupovania ľudí z UAV záznamu 46

Gabriel KOMAN, Milan KUBINA, Patrik BORŠOŠ

Možnosti nasadenia UAV systémov na Slovensku 51

Pavol ONDRÍK, Milan KUBINA, Juraj VOJTÁŠ

UAV technológia v zdravotníctve 56

Pavol ONDRÍK, Milan KUBINA, Juraj VOJTÁŠ

Možnosti využitia UAV technológie 61

Daniel SEDLÁK, Maroš STRIŠOVSKÝ

Meranie vzdialenosti objektu pre UAV pomocou Time-of-Flight snímačov 68

Daniel SEDLÁK, Maroš STRIŠOVSKÝ

Prototypové riešenie UAV v interiéri 72

Matúš BARTKO, Peter FECIĽAK

Predspracovanie dát na palube UAV 76

Stanislav FRANKO, Miroslav MICHALKO, Ondrej Kainz, František JAKAB

Experimental design of UAV usage in intralogistics 81

Detekcia zoskupovania ľudí z UAV záznamu

¹Ondrej KAINZ, ²Jakub FRANKOVIČ,
³Miroslav MICHALKO, ⁴František JAKAB

^{1,2,3,4} Katedra počítačov a informatiky, Fakulta elektrotechniky a informatiky,
Technická univerzita v Košiciach

¹ondrej.kainz@tuke.sk, ²jakub.frankovic@student.tuke.sk,
³miroslav.michalko@tuke.sk, ³miroslav.michalko@tuke.sk, ⁴frantisek.jakab@tuke.sk

Abstrakt — V prezentovanom výskume sa zameriavame na detekciu zoskupovania ľudí zo záberov UAV. Zhodnocujeme algoritmy detekcie objektov a zhlukovacie algoritmy a následne navrhujeme riešenie, ktoré zahŕňa modul pre detekciu osôb a používateľské rozhranie. Na detekciu ľudí z poskytnutých videozáznamov bol implementovaný skript v jazyku Python. Výstupom je okrem videa s ohraničujúcimi rámčekmi aj JSON súbor obsahujúci geografické dáta detegovaných osôb, ktoré sa následne načítajú do používateľského rozhrania. Používateľské rozhranie poskytuje možnosť analyzovať údaje a zisťovať skupiny ľudí, ktoré sú zobrazené na reálnej mape v podobe tepelnej mapy. Rozhranie obsahuje aj nastavenia pre detekciu skupín, ako je minimálny počet ľudí v skupine a maximálna vzdialenosť medzi ľuďmi/skupinami. Používateľské rozhranie je tiež pripravené prijímať dáta pomocou WebSocketu, čím simuluje nasadenie v reálnom prostredí, zobrazujúc dáta z bezpilotného lietadla. Vyhodnotenie demonštruje efektívnosť navrhovanej metódy pri zisťovaní zoskupovania ľudí zo záberov UAV a potenciál pre ďalší vývoj v reálnych scenároch.

Kľúčové slová — Detekcia objektov, detekcia ľudí, mapa, Python, TypeScript, UAV, video, YOLO, zhlukovanie.

I. ÚVOD

Detekcia a sledovanie objektov vo videu je jedna z hlavných úloh patriacich pod počítačové videnie. Táto oblasť má dnes veľké možnosti uplatnenia a podľa [1] bude čoraz bežnejšie používaná na analýzu prostredia v automatizovaných systémoch riadenia vozidiel, vyhodnocovanie pohybu ľudí v medicíne a športe, sledovanie objektov v priemyselných systémoch, alebo rozpoznávanie činnosti ľudí pomocou bezpečnostných systémov.

Na rozdiel od statických obrázkov videá obsahujú oveľa viac informácií, ktoré sa menia v závislosti od času aj miesta. Spracovanie a analýza dát z videí dovoľuje identifikovať nie len statické, ale aj dynamické vlastnosti objektu, čo ma za následok zvýšenie efektivity automatizovaných systémov na detekciu, ako takých.

V súčasnosti existuje mnoho vyvinutých algoritmov detekcie a sledovania objektov. Z tých relatívne starších môžeme spomenúť algoritmus na sledovanie osôb vo videu založený na metóde Monte Carlo pre Markovove reťazce a známy je aj algoritmus na detekciu a sledovanie osôb založený na metóde SVM.

V súčasnosti sú používané a vyvíjané algoritmy vytvorené na základe konvolučných neurónových sietí [2] [3], ktoré sú odolné voči zmenám osvetlenia, pozadia a umožňujú detekciu aj pri výraznom prekryvaní objektov. Sledovanie skupiny ľudí je jednou z najžiadanejších úloh pre sledovacie systémy na báze videa, ale tento problém stále nie je úplne vyriešený. Existuje množstvo prístupov na riešenie tohto problému, avšak vzhľadom na nasledujúce problémy je efektivita ich práce nedostatočná. Formovanie efektívnej sady funkcionalít, ktoré budú použité na detekciu a sledovanie objektov vo videu, je jednou z najťažších úloh, pretože pre ňu existujú obmedzenia všeobecne vyplývajúce z požiadaviek. Aktuálne už sú vyvinuté riešenia, ktoré sú dizajnované pre detekciu a sledovanie objektov vo videu, ako napríklad ľudí, dymu, či ohňa [4]. Na základe toho môžeme povedať, že sada funkcionalít pre detekciu a sledovanie bude v značnej miere súvisieť s tým, čo chceme sledovať. Preto, aby sme vyvinuli efektívne metódy, techniky a algoritmy na detekciu a sledovanie objektov vo videách, je potrebné jasne formalizovať úlohu algoritmu, je potrebné špecifikovať objekty pre detekciu a sledovanie, určiť hlavné fázy tohto

procesu, ako aj kritériá, ktoré umožnia zhodnotiť kvalitu spracovania a ukázať, ako sa to v praxi realizuje.

II. TEORETICKÉ VÝCHODISKÁ

Časť vyvíjaného systému bude v priloženom videu cielene vyhľadávať osoby. Na základe údajov z detekcie bude výstupom súbor JSON s dátami a rovnako video zobrazujúce detegované osoby pomocou ohraničujúcich rámcov. Takáto analýza je dosiahnuteľná použitím počítačového videnia spolu s modelom hlbokého učenia [5]. Počítačové videnie spolu so spracovaním obrázkov, strojovým učením a hlbokým učením poskytuje efektívne riešenia na detekciu a sledovanie objektov, v našom prípade ľudí, vo videu. Počítačové videnie extrahuje informácie zo vstupných obrázkov, respektíve videí, aby boli pre výpočtový stroj v pochopiteľnej, jednoduchej forme a následne predpovedá vizuálny vstup rovnako, ako ľudský mozog. Pre dosiahnutie tohto správania sa objekty detegujú v reálnom čase použitím vhodného algoritmu [5]. Aktuálne najpoužívanejšie algoritmy v tomto kontexte používajú konvolučné neurónové siete, ktoré majú za úlohu detekciu a zistenie vzdialenosti medzi objektami.)

Konvolučné neurónové siete sú špeciálnym druhom neurónových sietí určené na spracovanie dát, ktoré majú topológiu podobnú mriežke [6]. Boli používané od roku 1980, avšak s pribúdajúcou výpočtovou silou moderných počítačov a taktiež so zvyšujúcou sa dostupnosťou tréningových dát dosiahli konvolučné neurónové siete významné výsledky pri niektorých zložitých úlohách, ako napríklad vizuálne vnímanie, či rozpoznávanie hlasu [7]. Autor [8] konštatuje, že od roku 2000 boli s veľkou úspešnosťou konvolučné neurónové siete používané na detekciu, rozdelenie a rozpoznanie objektov a oblastí v obrázkoch.

Neurofyziológovia David Hubel a Torsten Wiesel ukázali, že určité neuróny v zrakovej kôre cicavcov selektívne reagovali na obrázky a časti obrazov špecifických tvarov. Vo svojich experimentoch zistili, že keď sa napríklad mačke ukázali obrázky obsahujúce malé čiary pod jedným uhlom, tak niektoré z neurónov rýchlo vystrelili. Iné neuróny rýchlo vystrelili naopak v reakcii na obrázky malých čiar pod iným uhlom [9]. Neskoršia práca odhalila, že iné neuróny boli špecializované na to, aby reagovali na obrázky obsahujúce zložitejšie tvary, ako sú rohy, dlhšie čiary a veľké okraje.

Podobne sa konvolučné neurónové siete učia funkcie hierarchicky z obrázkov [6]. Klasifikujú obrázky kombináciou jednoduchších definícií, ako sú rohy a okraje. Keďže pre počítač je ťažké porozumieť významu obrázku reprezentovaného ako súbor hodnôt pixelov, hlboké učenie rieši tento problém rozdelením tohto komplikovaného mapovania na sériu vnorených jednoduchých mapovaní, z ktorých každé je opísané inou vrstvou modelu. V architektúre konvolučných neurónových sietí je obraz definovaný pixelmi vo vstupnej vrstve. Potom séria skrytých vrstiev extrahuje z obrázka čoraz abstraktnejšie prvky [10]. Toto je hlavná myšlienka konvolučných neurónových sietí.

Konvolučná neurónová sieť (CNN) je biologicky inšpirovaný proces. Je to umelá neurónová sieť, ktorá sa posúva dopredu a najčastejšie sa používa v počítačovom videní a strojovom učení na skúmanie vizuálnych snímok [11].

Na základe požiadaviek nášho problému, kde údaje pozostávajú z hodnôt zemepisnej šírky a dĺžky, by bolo najlepšie použiť zhlukovacie algoritmy, ktoré dokážu spracovať priestorové údaje.

Niektoré z zhlukovacích algoritmov, ktoré dobre fungujú s priestorovými údajmi, zahŕňajú hierarchické algoritmy, K-means, Gaussove zmiešané modely a algoritmy založené na hustote, ako je DBSCAN [12]. Pre tento typ údajov môžu dobre fungovať aj samoorganizujúce sa mapy. Pokiaľ ide o škálovateľnosť, K-means a DBSCAN sú efektívne a dokážu dobre spracovať veľké množiny údajov. Hierarchické algoritmy a modely gaussovských zmesí však nemusia byť také efektívne pre veľké súbory údajov.

III. METODOLÓGIA

Navrhovaný experimentálny systém by používateľovi mal poskytnúť možnosť detegovať ľudí zo vstupu vo forme videa vytvoreného pomocou UAV a následnú analýzu výsledkov vo forme rozpoznávania skupín. Na základe bodov zadávacieho listu sme sa rozhodli pre analýzu pomocou zhlukovacích algoritmov. Aby výsledná analýza bola používateľsky prívetivá, rozhodli sme sa implementovať algoritmus, ktorý detegovaným osobám na základe informácií poskytnutých samotným modulom a informácií poskytnutých z UAV dokáže priradiť geografické súradnice. Následne tieto dáta premietneme na reálnu mapu, kde budú vyobrazené v podobe tepelnej mapy (z angl. heatmap). Používateľ bude vidieť niekoľko tepelných máp a za každou bude v pozadí iný zhlukovací algoritmus, aby používateľ vedel v reálnom čase porovnávať jednotlivé algoritmy.

Riešenie sme preto rozdelili na niekoľko jednotlivých modulov, z ktorých sa každý bude starať o určitú časť riešenia:

- Klientský modul.
- Serverový modul.

- Výpočtový modul.
- Databáza.

Klientský modul sa bude starať o vyobrazenie informácií používateľovi pomocou používateľského rozhrania vo forme webu. Serverový modul bude akýsi stredobod, ktorý bude obsluhovať všetky ostatné časti. Klientský modul s ním pomocou HTTPS bude komunikovať, dostávať od neho informácie, ako aj mu informácie posielat'. Výpočtový modul od neho bude dostávať požiadavky na výpočet. Spolu s požiadavkami dostane aj dáta a bude serverový modul informovať o výsledku. Databáza bude nutná kvôli systému prihlasovania a histórii výpočtov.

IV. VÝSLEDKY

Nižšie uvedené údaje tabuľke č. 1 predstavujú vyhodnotenie vlastného modelu YOLOv7 v porovnaní s niekoľkými predtrénovanými modelmi YOLOv7 na rôznych metrikách. Ako prebiehal tréning vlastného modelu, na ktorý referujeme v tabuľke.

Metóda resp. algoritmus YOLO, ktorý využívame na detekciu osôb z videosekvencie, bol vybraný po dôkladnom zhodnotení rôznych možností v práci [13]. Práca porovnávala niekoľko detekčných algoritmov podľa rôznych kritérií, akými sú rýchlosť, presnosť a robustnosť. Výsledky ukázali, že YOLO prekonalo ostatné algoritmy v našom špecifickom scenári, čím sa dosiahla rýchla a spoľahlivá detekcia.

Metriky použité na vyhodnotenie modelov sú presnosť, zapamätanie (z angl. recall), F1 skóre, stredná priemerná presnosť (mAP) pri 0.5 a 0.95 IoU a čas na odvodenie jednej snímky. Presnosť meria podiel skutočne pozitívnych detekcií zo všetkých predpovedaných pozitívnych detekcií, spätná väzba meria podiel skutočne pozitívnych detekcií zo všetkých pozitívnych detekcií a F1 skóre je harmonickým priemerom presnosti a zapamätania. mAP meria priemernú presnosť vo všetkých kategóriách objektov pri rôznych hodnotách IoU.

YOLOv7 má niekoľko predtrénovaných modelov, ktoré sa líšia z hľadiska výkonu. Ich výkon bol overovaný na súbore údajov MS COCO. Tiež sa líšia rýchlosťou spracovania a priemernou presnosťou (AP). Vyššie modely, ako napríklad YOLOv7-E6E, majú najvyššie AP a dokážu spracovať väčšie obrázky, ale sú pomalšie z hľadiska rýchlosti spracovania. Na druhej strane, modely ako YOLOv7 majú nižšie AP, ale dokážu spracovať obrázky vyššou rýchlosťou. Naš vlastný model je natrénovaný na modeli YOLOv7-X, ktorý bol pre nás zaujímavý z pohľadu rýchlosti a zároveň aj presnosti.

Nižšie v tabuľke č. 1 prezentujeme výsledky našich experimentov s detekciou objektov na vlastnom súbore údajov. Ten pozostáva z 24 200 obrázkov, ktoré boli rozdelené na tréning a testovanie v pomere 70 ku 30. Testovanie sme obmedzili len na detekciu osôb, čo znamená, že tabuľka obsahuje hodnoty odrážajúce len štatistiky týkajúce sa osôb, keďže predtrénované modely sú trénované na súbore údajov MS COCO, ktorý obsahuje oveľa viac tried, ako náš vlastný súbor údajov obsahujúci zábery z dronov.

Model	Presnosť	Zapamätanie	F1 Skóre	mAP .5	mAP .95	Čas na snímku
Náš model	0.938	0.885	0.910	0.927	0.608	13.0 ms
YOLOv7	0.341	0.493	0.403	0.355	0.127	12.2 ms
YOLOv7-X	0.414	0.468	0.439	0.368	0.134	17.2 ms
YOLOv7-W6	0.323	0.392	0.354	0.28	0.099	9.6 ms
YOLOv7-E6	0.37	0.387	0.378	0.298	0.108	16.3 ms
YOLOv7-D6	0.356	0.405	0.379	0.304	0.109	19.9 ms
YOLOv7-E6E	0.355	0.406	0.379	0.305	0.11	24.6 ms

Tabuľka 1 Porovnanie finálneho modelu s predtrénovanými modelmi YOLOv7.

Vlastný model YOLOv7 celkovo dosiahol výrazne vyššie skóre vo väčšine metrick v porovnaní s vopred trénovanými modelmi, čo dokazuje, že rozhodnutie natrénovať vlastný model na špecifickom súbore údajov bola správna voľba. Vyšší čas na odvodenie jedného rámca však naznačuje, že môže byť potrebná ďalšia optimalizácia na zlepšenie výkonu modelu v aplikáciách v reálnom čase.

Na vyhodnotenie výkonu nášho systému sme uskutočnili experiment s použitím videa, ktoré bolo zaznamenané z najvyššieho poschodia budovy Technickej univerzity v Košiciach. Simuluje scenár UAV letiaceho vo vysokej nadmorskej výške a detekcie osôb na zemi. Výhodou použitia tohto záznamu je, že nám umožňuje jednoducho overiť presnosť nášho systému, keďže vieme relatívne presne odhadnúť polohu zdroja a môžeme porovnať systémom odhadovanú polohu detegovanej osoby s jej skutočnou polohou.

Zistenú polohu osoby porovnáваме so skutočnou polohou získanou z online máp. Ako mieru presnosti používame euklidovskú vzdialenosť medzi týmito dvoma polohami. Túto vzdialenosť sme počítali algoritmom, ktorý predstavil v online článku autor Chris Veness [14]. Algoritmus s využitím Harvesinovej formuly dokáže vyrátať vzdialenosť medzi dvoma geografickými bodmi.



Obrázok 1 Detegovaná osoba 1 vo videosekvencii (a) a predikovaná poloha (b)

Ako vidíme na obrázku 1(a), detegovaná osoba sa nachádza približne v spodnej línii tretieho parkovacieho miesta vpravo. Podľa obrázku 1(b), ktorý znázorňuje predikovanú polohu na mape, je zistená poloha niekde pod touto čiarou, čo znamená, že ju s miernou odchýlkou môžeme nazvať správne zistenou. Podľa nášho výpočtu je odchýlka 5.1 metra.

Webové rozhranie je navrhnuté tak, aby poskytovalo používateľsky príjemný spôsob vizualizácie a analýzy údajov zhromaždených algoritmom detekcie ľudí. Používateľ môže interagovať s približovaním mapy, upravovaním nastavení, či výberom detegovanej skupiny. Rozhranie tiež poskytuje niektoré štatistiky o údajoch, ako je celkový počet zistených ľudí, alebo napríklad počet ľudí na skupinu, resp. zhluk. Rozhranie používa algoritmus DBSCAN a K-means na vykonávanie zoskupovania údajov na základe priestorových aj časových prvkov. Používateľ môže upraviť rôzne parametre, ako napríklad počet zhlukov a zistiť, ako to ovplyvňuje výsledky v reálnom čase.

V. ZÁVER

Cieľom predstaveného výskumu experimentálne implementovať a overiť riešenie, ktoré dokáže efektívne detegovať ľudí z videosekvencie a následne nad výslednými dátami vykonávať analýzu, ktorá dokáže detegovať skupiny ľudí využitím zhľukovania.

Riešenie problému sme dekomponovali do viacerých modulov, z ktorých relevantné pre tento výskum boli výpočtový modul a modul používateľského rozhrania. Výpočtový modul sa stará o detekciu osôb vo videu, kde sa hneď po detekcii taktiež určuje geografická poloha ľudí. Tento modul využíva náš vlastný model, ktorý bol vyvinutý jemným doladovaním predtrénovaného modelu YOLOv7-X. Doladovanie prebiehalo v niekoľkých iteráciách na špeciálnom súbore dát, ktorý obsahoval 24 200 snímok vytvorených z bezpilotného lietadla. Vývoj vlastného modelu sa v konečnom dôsledku ukázal ako veľmi efektívny, pretože priniesol vynikajúce výsledky v porovnaní s predtrénovanými modelmi YOLOv7.

Modul používateľského rozhrania je vyvinutý za účelom zobrazovania dát, ktoré sú výstupom výpočtového modulu. Na základe nich dokáže tento modul vykonávať analýzu a zobrazovať výsledky v reálnom čase v podobe textu, ako aj priamo na reálnej mape, respektíve jej troch inštanciách, kde na každej mape je využívaný iný zhľukovací algoritmus. Hlavnou mapou je mapa využívajúca algoritmus DBSCAN, ktorý sme na základe analýzy určili za najvhodnejší pre kontext prezentovaného výskumu a povahu údajov. V module je možné nastaviť atribúty ako *minimálny počet ľudí v skupine*, alebo *maximálna vzdialenosť medzi osobami pre vytvorenie skupiny*. Kombináciou týchto parametrov dokáže používateľ efektívne analyzovať zhľuky v dátach poskytnutých výpočtovým modulom, na základe čoho môže vyvodzovať ďalšie dôsledky a performovať akcie.

Prínos je nepochybne vo vývoji vlastného modelu pre detekciu osôb z bezpilotného lietadla, ako aj jeho následné využitie v programe, ktorý túto funkcionality zlučuje s algoritmom odvodzovania geografických súradníc z detegovaných osôb v obraze. Vďaka vytvoreniu funkčného výpočtového modulu bolo možné implementovať webové používateľské rozhranie, ktoré sa snaží zjednotiť moderný dizajn, jednoduchosť a poskytnúť potrebnú funkcionality na detekciu skupín ľudí v dátach, ktoré sú výstupom výpočtového modulu. Okrem toho používateľské rozhranie prináša možnosť sledovať a analyzovať dáta vzdialeného UAV v reálnom čase s využitím WebSocketu. Táto funkcionality však bola overená iba experimentálne simulovaním potrebných dát v skripte jazyku Python.

POĎAKOVANIE

Táto publikácia vznikla vďaka podpore v rámci Operačného programu Integrovaná infraštruktúra 2014 - 2020 pre projekt: Inteligentné operačné a spracovateľské systémy pre UAV, s ITMS kódom projektu 313011V422, spolufinancovaný zo zdrojov Európskeho fondu regionálneho rozvoja.



EURÓPSKA ÚNIA
Európske štrukturálne a investičné fondy
OP Integrovaná infraštruktúra 2014 – 2020



MINISTERSTVO
DOPRAVY
SLOVENSKEJ REPUBLIKY

ZDROJE

- [1] CAVALLARO, Andrea. Video tracking : theory and practice. Chichester, West Sussex, UK Hoboken, NJ: Wiley, 2010. ISBN 978-0470749647.
- [2] MOHANA; ARADHYA, HV Ravish. Object Detection and Tracking using Deep Learning and Artificial Intelligence for Video Surveillance Applications. International Journal of Advanced Computer Science and Applications. 2019, roč. 10, c. 12. Dostupné z DOI: 10.14569/IJACSA.2019.0101269.
- [3] MANE, Shradha;MANGALE, Supriya. Moving Object Detection and Tracking Using Convolutional Neural Networks. In: 2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS). 2018, s. 1809–1813. Dostupné z DOI: 10.1109/ICCONS.2018.8662921.
- [4] BOHUSH, Rykhard;ABLAMEYKO, Sergey;CHEN, Huafeng. Formalization of People and Crowd Detection and Tracking in Video. In: 2021.
- [5] SHALINI, G; MARGRET, M; NIRAIMATHI, M; SUBASHREE, S. Social Distancing Analyzer Using Computer Vision and Deep Learning. Journal of Physics: Conference Series. 2021, roc. 1916, s. 012039. Dostupné z DOI: 10.1088/1742-6596/1916/1/012039.
- [6] SOYDANER, Derya. Rolling in the Deep Convolutional Neural Networks. International Journal of Intelligent Systems and Applications in Engineering. 2019.
- [7] GÉRON, Aurélien. Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems. Sebastopol, CA:O'Reilly Media, 2017. ISBN 978-1491962299.
- [8] LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning.Nature.2015, roč. 521, c. 7553, s. 436–444. ISSN 1476-4687. Dostupné z DOI: 10.1038/nature14539.
- [9] NILSSON, Nils J. The Quest for Artificial Intelligence. Cambridge University Press, 2009. Dostupné z doi: 10.1017/CBO9780511819346
- [10] GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. Deep Learning. MIT Press, 2016. <http://www.deeplearningbook.org>
- [11] BHARATI, Puja; PRAMANIK, Ankita. Deep Learning Techniques—R-CNN to Mask R-CNN:ASurvey. In:DAS, Asit Kumar;NAYAK, Janmenjoy;NAIK, Bighnaraj; PATI, SoumenKumar; PELUSI, Danilo (ed.). Computational Intelligence in Pattern Recognition. Singapore: Springer Singapore, 2020, s. 657–668. ISBN 978-981-13-9042-5.
- [12] HINNEBURG, Alexander; KEIM, Daniel A. An Efficient Approach to Clustering in Large Multimedia Databases with Noise. In: Knowledge Discovery and Data Mining. 1998.
- [13] GERA, Marek. Detekcia skupín ľudí vo videu. 2022. Dipl. pr. Technická univerzita v Košiciach 1040 104009.
- [14] VENESS, Chris. Calculate distance, bearing and more between Latitude/Longitude points. 2002-2022. Dostupné tiež z: <http://www.movable-type.co.uk/scripts/latlong.html>.