

DIPLOMOVÁ PRÁCA

DETEKCIA OBJEKTŮ Z KAMERY DRONA V OUTDOOR PROSTŘEDÍ S VYUŽITÍM DEEP LEARNINGU

Bc. Jakub Nilabovič

Vedúci práce: RNDr. Ľubomír Antoni, PhD.


MOTIVÁCIA

- drony považujem za užitočné „počítače vo vzduchu“, preto v tom vidím veľký potenciál
- strojové učenie je oblasť, ktorá vždy otvára nové možnosti v autonómií robotiky
- spojenie dvoch veľmi aktuálnych tém
- inšpirácia - môže dron autonómne sledovať cyklistu a bez pomoci pilota ho nahrávať popri tom ako jazdí?

ÚVOD

- DRON - diaľkovo alebo autonómne riadené bezpilotné vozidlo, teda dynamický bod „počítač“ v priestore
- KAMERA - prístroj na snímanie obrazu okolia
- STROJOVÉ UČENIE - podoblasť umelej inteligencie umožňujúca programu učiť sa a následne adekvátne reagovať

Využitie drona, ktorý kamerou sníma obraz okolia, pomocou strojového učenia deteguje osobu človeka (a iné objekty v okolí) a v reálnom čase autonómne ovláda drona tak, aby sa k osobe v kruhovom okolí približoval.




CIELE

- Spracovať prehľad metód na detekciu objektov z kamery drona
- Navrhnúť a implementovať kombináciu metód na detekciu objektov z kamery drona s využitím deep learningu
- Porovnať dosiahnuté výsledky s ďalšími dostupnými štúdiami

I. SLEDOVANIE OBJEKTOV

OBJECT TRACKING

PALUBNÝ SYSTÉM GPU





DÁTA

--- ZÍSKAVANIE DÁT POMOCOU VIDEO ZÁZNAMOV ---

- videá (fotky) lesného prostredia pomocou kamery umiestnenej na osobe alebo na drone, ktorý je ovládaný človekom
- pre doplnenie dát sú použité datasety z internetu




ČO JE DETEKCIA OBJEKTOV?




METÓDY NA DETEKCIU OBJEKTOV Z OBRAZU

Konvolučné neurónové siete



Štandardná konvolúcia s
batch normalizáciou a ReLU




MobileNet architektúra,
využívajúca hĺbkovú a bodovú
konvolúciu nasledovanú
batch normalizáciou a ReLU


2. PLÁNOVANIE CESTY

PATH PLANNING

VYUŽITIE DETEKCIE OBJEKTOV




TRANSFORMÁCIA OBRAZU DO PLÁNU




3. AKČNÉ MANÉVROVANIE

ACTION MANEUVERING

- 4 manévrovacie stupne
- Reagovať na zmeny pohybu sledovanej osoby
- Schopnosť reagovať na zmeny prostredia - napr. vyhnutie sa nepredvídaným prekážkam alebo zachovať naplánovanú trajektóriu v prípade zmeny vetra




GENEROVANIE TRAJEKTÓRIE




HARDWARE

JETSON

- vývojová platforma Jetson Nano alebo Jetson Xavier NX, ktorá má výkonný a zároveň optimalizovaný grafický procesor spoločnosti NVIDIA a je vytvorená práve pre podobné účely



Jetson Nano



Jetson Xavier NX


JETSON NANO

- GPU: 128-core NVIDIA Maxwell™ architecture-based GPU
- CPU: Quad-core ARM® A57
- Video: 4K @ 30 fps (H.264/H.265) / 4K @ 60 fps (H.264/H.265) encode and decode
- Camera: MIPI CSI-2 DPHY lanes, 12x (Module) and 1x (Developer Kit)
- Memory: 4 GB 64-bit LPDDR4; 25.6 gigabytes/second
- Connectivity: Gigabit Ethernet
- OS Support: Linux for Tegra®
- Module Size: 70mm x 45mm
- Developer Kit Size: 100mm x 80mm
- Weight: 250g



JETSON XAVIER NX

- 384-core Volta GPU @ 1100MHz with 64 Tensor Cores
- Dual Deep Learning Accelerator (DLA) engines
- 7-way VLIW Vision Accelerator
- 8GB 128-bit LPDDR4x @ 1600MHz (51.2GB/s)
- 16GB eMMC 5.1
- (2x) 4Kp30 H.264/H.265 video encoder
- (2x) 4Kp60 H.264/H.265 video decoder



Model	Jetson Nano		Jetson TX2 series		Jetson Xavier NX		Jetson AGX Xavier	
	FPS (limited latency)	FPS (max throughput)	FPS (limited latency)	FPS (max throughput)	FPS (limited latency)	FPS (max throughput)	FPS (limited latency)	FPS (max throughput)
Inception V4 (299x299)	11*	13	24*	32	320	405	528	704
VGG-19 (224x224)	10*	12	23*	29	67*	313	276	432
Super Resolution (481x321)	15*	15	33*	33	164	166	281	302
Unet (256x256)	17*	17	39*	39	166	166	240	251
OpenPose (256x456)	15*	15	34*	35	238	271	439	484
Tiny YOLO V3 (416x416)	48*	49	107	112	607	618	1100	1127
ResNet-50 (224x224)	37*	47	84	112	824	1100	1946	2109
SSD Mobilenet-V1 (300x300)	43*	48	92	109	909	1058	1602	1919
SSSD Resnet34 (1200x1200)	1	1	3	2	29	29	55	55

VÝSLEDKY VÝKONNOSTI MEDZI PALUBNÝM A MIMO PALUBNÝM SYSTÉMOM

	TX1	TX2	Xavier AGX	GPU-Based Ground Station: Gtx 1080
YOLOv2	2.9 FPS	7 FPS	26~30 FPS	28 FPS
YOLOv2 tiny voc	6~7 FPS	15~16 FPS	29 FPS	30+ FPS
YOLOv3	—	3 FPS	16~18 FPS	15.6 FPS
YOLOv3 tiny	9~10 FPS	12 FPS	30 FPS	30+ FPS
SSD	8 FPS	11~12 FPS	35~48 FPS	32 FPS
DeepLab-v3 Semantic Segmentation	—	2.2~2.5 FPS	10 FPS	15~16 FPS
Faster R-CNN		0.9 FPS	1.3 FPS	—
Mask R-CNN	—	—	—	2~3 FPS
YOLOv3 + Deep SORT	—	2.20 FPS	10 FPS	13 FPS

SIMULÁCIA V PROSTREDÍ UNITY

DIGITÁLNE PROSTREDIE LESA V UNITY



ZDROJE

- 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.
- 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.
- HOWARD, Andrew G., et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*, 2017.
- <https://umelainteligencia.sk>
- **Drones can autonomously follow forest paths with new software**

Shane McGlaun - Feb 11, 2016, SlashGear.com

ĎAKUJEM ZA POZORNOST