

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

Predspracovanie dát na palube UAV

¹Matúš BARTKO, ²Peter FECILAK

Katedra počítačov a informatiky, Fakulta elektrotechniky a informatiky, Technická univerzita v Košiciach

¹matus.bartko@student.tuke.sk, ²peter.fecilak@tuke.sk

Abstrakt – Článok sa zaoberá analýzou a implementáciou predspracovania dát na palube UAV pomocou hlbokého učenia. Na základe analýzy zbieraných dát na palube UAV boli zvolené dáta z kamery a mikrofónu. V rámci práce bola použitá metóda hlbokého učenia na mikroprocesoroch ARM, ktorá umožňuje efektívne predspracovanie dát pri nízkej spotrebe energie. Platforma pre hlboké učenie bola použitá Edge Impulse, a ako mikroprocesorová doska bola zvolená doska Arduino Portenta H7. Komunikácia medzi zariadením a serverom bola realizovaná prostredníctvom technológie LoRaWAN a MQTT. Experimentálne overenie navrhnutého riešenia bolo vykonané prostredníctvom rôznych meraní a analýzy dopadov na komunikačnú infraštruktúru.

Kľúčové slová – Deep Learning, Edge Impulse, LoRa, UAV

I. ÚVOD

Používanie bezpilotných lietadiel (UAV) sa stáva čoraz populárnejšie vďaka ich všestrannosti a dostupnosti. So zvyšovaním kvality a množstvom senzorov dostupných na palube UAV sa zvyšuje aj veľkosť dát. Preto je potrebné preskúmať rôzne možnosti a techniky predspracovania údajov, ktoré dokážu znížiť množstvo prenášaných údajov pomocou bezdrôtových komunikácií. Predbežné spracovanie údajov na palube UAV dokáže znížiť množstvo údajov, čo môže ušetriť šírku pásma a znížiť čas a náklady spojené s prenosom údajov. To je dôležité najmä pri aplikáciách, kde sú údaje v reálnom čase kritické, napríklad pri pátracích a záchranných operáciách alebo pri reakcii na katastrofy. Bepilotné lietadlá sú schopné prenášať údaje do pozemných staníc a iných zariadení pomocou rôznych komunikačných protokolov. Jedným z takýchto protokolov, ktorý získava na popularite v IoT, je LoRaWAN. LoRaWAN umožňuje komunikáciu na veľké vzdialenosti s nízkou spotrebou energie. Implementácia LoRaWAN spolu so strojovým učením, okrem vylepšenia schopností, otvára dvere do rôznych sektorov v aplikáciách UAV.

II. ANALÝZA DÁT

V systémoch bezpilotných lietadiel sa zhromažďujú a spracúvajú rôzne typy údajov na podporu širokej škály aplikácií, ktorým slúžia. Tieto typy údajov možno všeobecne rozdeliť do niekoľkých kľúčových skupín.

A. Telemetrické údaje

Tieto údaje poskytujú informácie v reálnom čase o stave, polohe a výkone UAV. Umožňujú operátorom monitorovať správanie UAV a prijímať vhodné rozhodnutia na základe aktuálnej situácie. Príklady telemetrických údajov: stav batérie, nadmorská výška, súradnice GPS a rýchlosť. Veľkosť týchto dát je malá pretože sú to väčšinou len číselné hodnoty.

B. Údaje zo snímačov

Bepilotné lietadlá sú vybavené viacerými snímačmi, ktoré zhromažďujú údaje o prostredí alebo konkrétnych cieľoch. Príklady takýchto senzorov zahŕňajú LiDAR, infračervené senzory, multispektrálne a hyperspektrálne senzory, magnetometre a mnoho iných. Zozbierané údaje sa môžu použiť na aplikácie, ako je mapovanie, monitorovanie poľnohospodárstva, inšpekcia a dohľad. Veľkosť týchto dát je väčšia ako pri telemetrických pretože okrem číselných hodnôt môžu byť prenášané aj iné údaje.

C. Obrazové a video údaje

Bezpilotné lietadlá s kamerami a obrazovými snímačmi zaznamenávajú obrázky a videá v rôznych formátoch a rozlíšeniach, ktoré sa môžu využiť na letecké fotografovanie, videografu a monitorovanie v reálnom čase. Podľa typu kamery môžu byť snímky zachytené vo viditeľnom svetle či v infračervenom spektre. Obrazové a video údaje sú hlavnými formami vizuálnej informácie, zachytávajúce scény a objekty. Veľkosť obrazových dát je veľká kvôli množstvu údajov ktoré je potrebné zobraziť.

D. Zvukové údaje

Niektoré bezpilotné drony môžu byť vybavené zvukovými senzormi, teda mikrofónmi, ktoré snímajú zvuk. Zvuk je dôležitý pri vnímaní sveta, skúmaní možností či monitorovaní udalostí vydávajúcich zvuk. V bojových podmienkach, kde môže ísť o záchranu ľudských životov, môžu byť okrem obrazových údajov užitočné aj mikrofóny zachytávajúce netradičné zvukové signály. Veľkosť dát je menšia ako pri obrazových údajoch, ale aj tieto dáta môžu mať veľkú veľkosť pri zvolení vyššej kvality.

III. KOMUNIKAČNÉ TECHNOLOGIE

Efektívna komunikácia a prenos údajov sú kľúčové pre úspešnú prevádzku bezpilotných lietadiel. V posledných rokoch sa začali objavovať bezpilotné lietadlá (UAV) ktoré využívajú svoju vysokú mobilitu na zlepšenie alebo umožnenie nových funkcií pomocou LoRaWAN. Konkrétne Tanaka a spol. [1] používajú UAV na zber údajov zo senzorov LoRa a LoRaWAN. Sharma a kol. v [2] skúmajú, ako môže brána založená na dronoch zlepšiť spoľahlivosť komunikácie LoRaWAN v mestských scenároch.

LPWAN prekonávajú obmedzenia bezdrôtových sietí krátkeho dosahu technológií, ako sú Bluetooth a Wi-Fi, a stali sa vhodnou voľbou pre komunikačné siete v mestskom meradle aplikácií internetu vecí. Je to preto, že môžu dodávať signál s dlhým dosahom komunikáciu rôznym zariadeniam pri nízkych nákladoch a s minimálnymi energetickými nákladmi. Momentálne najpoužívanejším riešením pre spoľahlivé komunikačné systémy dronov je rádiový frekvenčný komunikačný systém.

IV. PREDSPRACOVANIE DÁT METÓDAMI HLBOKÉHO UČENIA

Technológia hlbokého učenia (Deep Learning) sa v súčasnosti stala dosť používaným slovom vďaka špičkovým výsledkom dosiahnutým v oblasti klasifikácie obrazu, detekcie objektov a spracovania prirodzeného jazyka. Dôvody popularity hlbokého učenia sú dva, a to veľká dostupnosť súborov údajov a výkonné grafické procesory. Pri predspracovaní dát metódami hlbokého učenia vieme vyextrahovať z údajov len užitočné informácie ktoré hľadáme. Existuje mnoho aplikácií použitia hlbokého učenia. Medzi hlavné patria detekcia objektov na obrázku a extrahovanie alebo detekcia špecifického zvuku zo záznamu.

V kontexte detekcie zvukových signálov sa metódy hlbokého učenia ukázali ako veľmi efektívne, a to najmä vďaka svojej schopnosti automaticky extrahovať relevantné črty zo surových dát bez potreby manuálnej extrakcie črt. Konvolučné neurónové siete (CNN) a rekurentné neurónové siete (RNN) sú dva hlavné typy neurónových sietí používaných v tejto oblasti [3].

Konvolučné neurónové siete (CNN) sa osvedčili pri extrakcii lokálnych a hierarchických črt zvukových spektrogramov. Tieto siete využívajú konvolučné vrstvy na detekciu vzorcov v dátach a následne tieto vzorce kombinujú na vyššej úrovni abstrakcie. CNN sa často používajú na úlohy, ako je klasifikácia zvukových udalostí, rozpoznávanie reči alebo analýza hudby. [4]

CNN (konvolučná neurónová sieť) sa vo veľkej miere používa aj na detekciu objektov. CNN je typ neurónovej siete s posunom vpred a funguje na princípe zdieľania váh. Je to proces hľadania a klasifikácie objektov v obraze. CNN spočíva v tom že na obrázku sa nájdu také oblasti, ktoré môžu obsahovať objekt. Takýmto oblastiam hovoríme navrhované regióny. Následne sa extrahujú príznaky z navrhovaných regiónov. V poslednom kroku sa klasifikujú objekty na základe príznakov.

Taktiež existuje aj "You Only Look Once" alebo "pozri sa len raz" jednoduchý detektor objektov, ktorý dokáže predpovedať konkrétny objekt na každom oblasti mapy prvkov zbavenej kaskádovej fázy klasifikácie polohy. YOLO využíva konkrétnu sieť CNN a na klasifikáciu a lokalizáciu objektu používa ohraničujúce boxy.

V. NÁVRH PROSTREDIA A EXPERIMENTÁLNE OVERENIE

Návrh riešenia zahŕňa viacero kľúčových komponentov a procesov, čo je treba zohľadniť pri návrhu systému. Základným komponentom je výber správnych senzorov a návrh spracovania týchto údajov, ktoré budú zberané v reálnom čase. Následne, tieto dáta je potrebné predspracovať

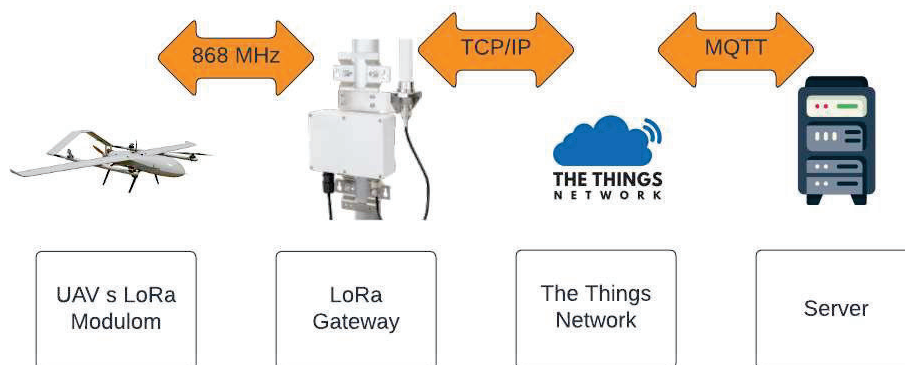


Fig. 1 Návrh modelu predspracovania údajov a odosielanie

na mikrokontroléry, ktorý musí mať dostatočne výkonný procesor pre vykonávanie rôznych algoritmov a metód predspracovania dát. Predspracovanie dát bude spočívať v použití strojového učenia, ktorý bude mať na starosti predspracovanie dát zo senzorov. Po úspešnom predspracovaní sa výsledok odošle cez komunikačné zariadenie, ktoré umožní spoľahlivé prepojenie medzi UAV a serverom. Po prijatí predspracovaných dát na server, sa budú tieto dáta vizualizovať užívateľovi pre ďalšie spracovanie. Celkový koncept ma zohľadniť adaptabilitu, rozšíriteľnosť, energetickú efektívnosť a dopad na komunikačnú štruktúru.

A. Experimentálne overenie

Experiment sa uskutočnil v dvoch hlavných scenároch: testovanie predspracovania zvuku a testovanie predspracovania obrazu. Pre testovanie bolo použité zariadenie Arduino Portenta H7 spolu s Arduino Vision Shield LoRa. Vzdialenosť medzi zariadením a bránou bola približne 1 km. Keďže boli k dispozícii len dve brány v celom meste, tak sa vybrali 4 lokality okolo brány, kde bola rôzna vzdialenosť, aby sa simulovali viaceré scenáre. Pre odosielanie správ pomocou LoRaWAN bola použitá dátová rýchlosť 5 a časový rozstup medzi správami bol nastavený na 13 sekúnd kvôli reguláciám. Prenos správy priemerne trval 0,15 sekúnd.

B. Testovanie predspracovania obrazu

Metodológia testovania predspracovania obrazu zahŕňala simulovaný snímok pred kamerou, na ktorom mal model identifikovať naučený objekt auto a odoslať cez sieť iba ten snímok, na ktorom sa nachádzal daný objekt. Následne sa obraz uložil do medzipamäte a výrez auta sa odoslal. Obraz bol následne rozdelený na menšie polia ktoré sa postupne odosieli. Jedno pole bolo o veľkosti 55 bajtov, ktoré sa následne odoslalo pomocou LoRaWAN. Kvôli časovej náročnosti procesu bol počet iterácií obmedzený na päť.

Meranie	Veľkosť obrázku pred predspracovaním [px]	Veľkosť obrázku po predspracovaním [px]	Istota modelu	Ušetrenie [%]
1	320x320	64x78	0.72	95.12
2	320x320	80x35	0.82	97.27
3	320x320	90x78	0.72	93.15
4	320x320	35x68	0.42	97.68
5	320x320	120x128	0.52	85
Priemerné ušetrenie				93.64

Table 1
Ušetrenie dát predspracovaním obrazu

C. Testovanie predspracovania zvuku

Metodológia testovania pre predspracovanie zvuku zahŕňala simulované prehrávanie zvuku z reproduktora, pričom model mal zachytiť a odoslať iba časť zvukového signálu, obsahujúcu zvuk výstrelu. Analyzovať sa bude dĺžka záznamu pred predspracovaním, dĺžka záznamu po predspracovaní a priemerné ušetrenie dát.

Meranie	Dĺžka záznamu pred predspracovaním [s]	Dĺžka záznamu po predspracovaní [s]	Istota modelu	Ušetrenie [%]
1	60	2	0.91	96.67
2	49	3	0.95	93.88
3	32	1.15	0.95	96.41
4	45	2.2	0.95	95.11
5	22	6	0.94	72.73
6	5	3	0.93	40
7	22	8	0.97	63.64
8	10	2	0.92	80
Priemerné ušetrenie				73.56

Table 2
Ušetrenie dát predspracovaním zvuku

D. Súhrn experimentu

Výsledky experimentu ukazujú významné úspory dát v dôsledku predspracovania. Spôsobilosť detekcie objektu bola nižšia, avšak bolo možné to predpokladať, keďže Arduino Portenta H7 má obmedzenú veľkosť RAM, čo znemožňuje použitie veľkého modelu s veľkou úspešnosťou detekcie objektu. Naproti tomu, úspešnosť detekcie zvuku bola lepšia, pretože zvukový model nevyžaduje tak veľké množstvo voľnej pamäte RAM.

Taktiež výsledky ukazujú, že pre prenášanie zvuku aj obrazu je potrebné zvoliť aj výraznú kompresiu, ktorá musí zredukovať počet dát. Pretože trvanie prenosu dát trvá dlho, a je takmer nepoužiteľné na vyhodnocovanie týchto záznamov v reálnom čase. Taktiež, posielanie obrazu cez LoRaWAN trvá dosť dlho v jednotkách minút, čo je dosť pomalé. Hlavnou príčinou sú regulácie, ktoré dovoľujú využiť len 1% časového okamžiku, za ktorým nasleduje 99% čakania. Taktiež je potrebné spomenúť, že niektoré pakety môžu byť chybné a priemerná chybovosť správ je priemerne 10%.

VI. ZÁVER

Výsledkom tejto publikácie bolo navrhnuť, implementovať a experimentálne overiť riešenie pre predspracovanie dát získaných z kamery a mikrofónu na palube bezpilotného lietadla (UAV). Hlavným problémom, ktorý sa riešil, bolo neustále posielanie dát z paluby UAV do pozemnej stanice. Navrhnutý systém na predspracovanie zvuku spočíval v snímaní zvukov z mikrofónu a následnom vyhodnocovaní prostredníctvom strojového učenia a neurónových sietí. Model bol natrénovaný na detekciu výstrelu zo zbrane. V prípade detekcie takéhoto zvuku sa poslala len tá časť, kde bol zaznamenaný výstrel, na server pre ďalšie spracovanie. Navrhnutý systém na predspracovanie obrazu zahŕňal spracovanie údajov z kamery prostredníctvom strojového učenia, ktoré umožnilo detekciu naučených objektov na snímkach, v tomto prípade áut. Ak bol na snímke detekovaný objekt, poslala sa daná snímka cez LoRaWAN na server pre ďalšie spracovanie a vizualizáciu pre používateľa.

Experimentálne overenie ukázalo, že navrhnuté riešenie je validné, avšak vyžaduje si lepšie vybavenie. Potrebovali by sme lepšiu kameru pre vyššiu kvalitu snímok a výkonnejší mikroprocesor s väčším množstvom RAM pre implementáciu väčších modelov. V rámci tejto práce sme úspešne dosiahli stanovené ciele, avšak existujú aj otázky, ktoré by mohli byť predmetom ďalšieho výskumu. Jednou z možností, ako by sme mohli riešenie vylepšiť, je implementácia lokalizácie dronu, takže spolu so snímkou by sa odosielala aj poloha dronu, napríklad s využitím GPS. Tieto výsledky otvárajú nové možnosti pre ďalší výskum a vývoj v oblasti predspracovania a prenosu údajov z dronov, čo by mohlo mať pozitívny dopad na efektívnosť a škálovateľnosť budúcich UAV aplikácií.

VII. POĎAKOVANIE

Táto publikácia bola podporená z operačného programu Integrovaná infraštruktúra v rámci projektu: Inteligentné operačné a spracovateľské systémy pre UAV, kód ITMS2014+: 313011V422 a spolufinancovaná Európskym fondom regionálneho rozvoja.

LITERATÚRA

- [1] R. Tanaka, "Report on SAR imaging," internal Report, Oct. 2003.

- [2] V. Sharma, I. You, G. Pau, M. Collotta, J. D. Lim, and J. N. Kim, "Lorawan-based energy-efficient surveillance by drones for intelligent transportation systems," *Energies*, vol. 11, no. 3, p. 573, 2018.
- [3] M. Ashraf, F. Abid, I. U. Din, J. Rasheed, M. Yesiltepe, S. F. Yeo, and M. T. Ersoy, "A hybrid cnn and rnn variant model for music classification," *Applied Sciences*, vol. 13, no. 3, 2023. [Online]. Available: <https://www.mdpi.com/2076-3417/13/3/1476>
- [4] Y. M. Costa, L. S. Oliveira, and C. N. Silla, "An evaluation of convolutional neural networks for music classification using spectrograms," *Applied Soft Computing*, vol. 52, pp. 28–38, 2017. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1568494616306421>