

# Sledování pohybu očí pilota dopravního letadla

T. Těhan, K. Dvořáková, J. Kíni, T. Chalas  
Ústav letecké dopravy ČVUT, Horská 2040/3  
kinikuba@gmail.com

## Abstrakt

Rozložení pozornosti pilota při řízení letadla je jedním z klíčových atributů bezpečného provedení letu ve všech jeho fázích. Zrak je nejdůležitějším smyslem a na základě zrakového vnímání situace vně letadla, indikovaných hodnot přístrojů a situace uvnitř kokpitu, společně s dalšími smysly dovolují pilotovi kontinuálně vytvářet model letu. Na základě smyslově zrekonstruovaného modelu letu pilot řídí letoun v aktuální situaci a předvídá následný vývoj letu. Let může probíhat dle pravidel za vidu země, případně dle pravidel pro let podle přístrojů, reálně jde často z hlediska zrakového vnímání o kombinovaný přístup, zejména u lehkých letadel. Vyhodnocení pohybu očí pilota umožňuje definovat východiska pro uspořádání a technické řešení zobrazovacích a ovládacích prvků řízení letadla, definování letových postupů a předpokladů fyzické i psychické únavy pilota.

## 1 Úvod

Nedílnou součástí udržování situačního povědomí pilotů v letectví je vizuální situační povědomí a způsoby skenování palubních přístrojů. Vizuální situační povědomí označuje schopnost pilota shromažďovat a interpretovat vizuální informace z vnějšího prostředí. Zahrnuje vizuální vyhodnocení polohy letadla, ostatního provozu, terénu, povětrnostních podmínek a případných nebezpečí.

Piloti používají vzorce skenování k systematickému a efektivnímu skenování svého zorného pole, čímž zajišťují, že zachytí důležité informace a zároveň minimalizují riziko přehlédnutí důležitých informací.

Udržování efektivního vizuálního situačního povědomí a používání správných vzorců skenování je pro piloty zásadní, aby mohli včas odhalit kritické signály a reagovat na ně. Rozvíjením těchto dovedností piloti zvyšují svou schopnost přijímat informovaná rozhodnutí.

Sledování pohybu očí pilotů dopravních letadel je klíčovým prvkem výzkumu zaměřeného na zlepšení letecké bezpečnosti a efektivity. Porozumění tomu, jak piloti vnímají a reagují na vizuální informace během letu, má zásadní význam pro identifikaci oblastí, které lze vylepšit s cílem minimalizovat rizika a zvýšit výkonnost plotů.

Cílem naší práce je porovnání pohybů očí zkušeného pilota s lidmi, kteří nemají žádné předchozí zkušenosti s pilotováním dopravních letadel. Tímto srovnáním se snažíme odhalit rozdíly ve způsobu, jakým tyto dvě skupiny zpracovávají vizuální informace a jak se jejich pohledy liší v průběhu letu.

## 2 Metodika experimentu

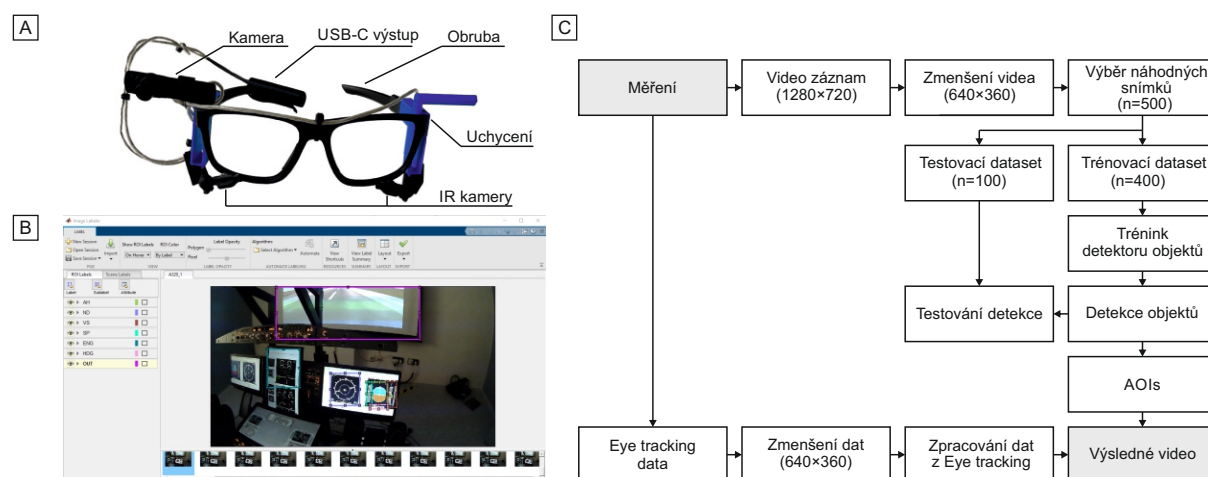
### 2.1 Participanti

Naše skupina participantů zahrnovala zkušeného kapitána letadel pracujícího pro společnost Qatar Airways. Vedle něho se nacházeli čtyři začátečníci, kteří se poprvé chopili řízení dopravního letadla.

### 2.2 Sběr dat

Pro sběr dat o pohybu očí jsme využili speciální brýle s 3D vytisknutými obrubami, které byly vybaveny kamerami z brýlí Pupil Core od společnosti Pupil Labs. Tyto brýle společně s programem umožňují přesné sledování pohybu očí a zaznamenávání dat v reálném čase, viz obrázek 1-A.

Před každým letem jsme provedli důležitou kalibraci brýlí pro sledování pohybů očí. Pomocí kalibračního programu v Pupil Core Software se na obrazovce počítače zobrazili body, které jsme postupně zaměřovali svým pohledem. Tímto způsobem jsme umožnili brýlím propojit naše oční pohyby s okolním prostředím a zajistili přesnost a spolehlivost zaznamenaných dat.



Obrázek 1: A) hardware pro sledování pohybu očí. B) Značení referenčních oblastí zájmu. C) Schéma zpracování dat.

Po úspěšné kalibraci jsme spustili nahrávání okolí a současně zaznamenávali pohyb očí pilota. Sbíraná data byla pro Eye tracking ve formátu CSV, který obsahoval data ve formátu: *snímekVideo;poziceX;poziceY;poziceZ;*

Během simulace dopravního letadla Airbus A320 jsme provedli několik fází letu, zahrnujících: Vzlet z Letiště Václava Havla Praha; Stoupání do nadmořské výšky 5000 ft; Pravotočivá 180° zatáčka; Krátký horizontální let; Levotočivá 360° zatáčka; Klesání na volnoběh při rychlosti 250 kt do nadmořské výšky 3500 ft; Pravotočivá zatáčka při rychlosti 220 kt; Přiblížení k letišti a Přistání na letišti.

### 2.3 Zpracování dat

Objektový detektor bylo potřebné vytvořit pro přímou adresaci zaznamenané polohy očí ve scéně vzhledem k oblastem zájmu. Oblasti zájmu jsou v případě řešení této proble-

matiky letové přístroje, v jejichž rámci je hodnocení pohledu na ně klíčové vzhledem k hodnocení rozdělení pozornosti.

Pro tvorbu objektového detektoru bylo využito prostředí Matlab 2021a. V rámci tvorby detektoru byl využit přístup založený na R-CNN (z angl. Region Based Convolutional Neural Networks), konkrétně pak Faster RCNN. Pro učení samotného detektoru byla použita architektura Alexnet [1], která se skládá z pěti konvolučních a tří plně propojených vrstev.

Dataset pro učení detektoru se skládal ze snímků s označenými oblastmi zájmu, které byly definovány částmi přístrojové desky letadla typu A320. Tyto obrázky byly poríženy náhodným výběrem z celkového počtu snímků zaznamenaných videí. Takovým způsobem bylo poríženo 500 snímků, ve kterých byly označeny oblasti zájmu. Rozlišení snímků vstupního datasetu bylo  $1280 \times 720 \times 3$ , a tedy, jednalo se o RGB snímky.

V každém snímku byly označeny oblasti zájmu s využitím aplikace Image Labeler, která je součástí Computer Vision toolboxu v prostředí Matlab 2021a. Tyto oblasti byly charakterizovány konkrétními letovými, navigačními a motorovými přístroji, případně označovaly charakteristickou oblast kokpitu zahrnující několik přístrojů. Těmito oblastmi byly umělý horizont (AH), růžice gyrokompasu, respektive indikátor kurzu spolu s indikátorem trati (HDG), oblast sdružující indikátory výšky, vertikální rychlosti a sestupové roviny (AT), rychloměr (SP), navigační display (ND), združený panel motorových ukazatelů (ENG) a oblast výhledu z kokpiu (OUT). Způsob označování oblastí zájmu prostřednictvím výše uvedené aplikace spolu s vyznačením jednotlivých oblastí základní přístrojové desky A320 je zobrazen na obrázku 1-B.

Tento dataset byl dále rozdělen na trénovací (400 snímků) a testovací (100 snímků). Proto, aby bylo dosaženo rychlejší detekce objektů v obraze, byl popisovaný dataset zmenšen na rozlišení  $640 \times 360 \times 3$ .

Pro trénování samotného detektoru byl použit optimalizační algoritmus SGDM (z angl. Stochastic Gradient Descent with Momentum) využívaný pro trénování algoritmu strojového učení, zejména umělých neuronových sítí používaných v hlubkovém učení [2]. Výsledné nastavení s ohledem na přeučení (tzv. overfitting), případně podučení (tzv. underfitting), bylo zjištěno empiricky. Konkrétně byl využit „mini-batch gradient descent“ algoritmus učení, a tedy s postupným dávkováním vzorků, a to vzhledem k využití paměti. Hyperparametr „minibatchSize“ ( $mbs$ ) byl v těchto konkrétních případech nastaven na hodnotu 2 a definoval počet trénovacích vzorků, které je třeba zpracovat před aktualizací parametrů interního modelu. Celkový počet iterací  $i$ , potřebných pro zpracování trénovacího datasetu při definovaných nastaveních trénovacího algoritmu, byl:

$$i = \frac{n \cdot Ep}{mbs}, \quad (1)$$

kde  $n$  je celkový počet vzorků trénovací množiny ( $n = 400$ ),  $Ep$  je počet epoch ( $Ep = 100$ ) pro  $mbs = 2$ . Celkový počet iterací pro natrénování modelu byl 20 000. Pro akceleraci trénovacího procesu byl tento vykonávaný na GPU, konkrétně na NVIDIA GeForce RTX 3070 s podporou CUDA. Pro schématické znázornění procesu zpracování dat a trénování detektoru viz obrázek 1-C.

Ukázka detekovaných objektů na snímku z videa spolu se znázorněním očního fokusu je zobrazena na obrázku 2.



Obrázek 2: Ukázka detekovaných objektů

### 3 Výsledky a diskuse

Z výsledků naší práce jsme zjistili, že profesionální piloti se více soustředí na specifické navigační prvky, přistávací dráhy a vzletové body, zatímco začátečníci mají tendenci se zaměřovat na širší okolí a vizuálně výrazné objekty. Tento rozdíl v zaměření může mít vliv na strategie a rozhodování během letu. Diskutuje se o možnosti vzdělávat a trénovat začátečníky tak, aby se naučili efektivněji zaměřovat na klíčové aspekty letu a minimalizovali rizika. Tento poznatek je důležitý při vývoji výcvikových programů a zlepšování dovedností pilotů v oblasti letectví.

V rámci našeho výzkumu jsme zaznamenali další zajímavý aspekt rozdílu mezi profesionálním pilotem a začátečníkem. Profesionální piloti projevovali důkladnější kontrolu a sledování přístrojů a sekvenčních postupů. Měli přesně stanovené priority a sledovali specifické informace na palubní desce. Naopak začátečníci spíše přistupovali k sledování objektů náhodně a reaktivně, zaměřovali se na to, co se jim zdálo momentálně důležité. Tento rozdíl naznačuje, že profesionální piloti vykazují vyšší schopnost organizovat a řídit svou pozornost na základě priorit, zatímco začátečníci se spoléhají na okamžitou reakci na aktuální podněty. Tento poznatek může vést ke zdokonalení výukových metod pro začátečníky a posílení jejich schopnosti systematicky sledovat důležité informace v kokpitu.

Výše popsané vyhodnocení výsledků bylo provedeno subjektivně, z vytvořených videozáznamů, které mají zvýrazněné oblasti na palubní desce (i mimo kokpit) podle vizuálního fokusu. I při tomto přístupu však bylo možné rozeznat rozdíly ve vzorcích chování zúčastněných subjektů. Převážná část práce je tedy založena na vizualizaci zájmové oblasti, přičemž související data lze následně využít pro robustní analýzy zahrnující statistické vyhodnocení.

## 4 Závěr

Provedli jsme podrobné srovnání letů mezi profesionálním pilotem a námi, jako začátečníky, v kontextu sledování přístrojů v kokpitu během letu. V rámci naší práce jsme se zaměřili na identifikaci hlavních faktorů, na které se piloti nejvíce soustředí, jako jsou přistávací dráhy, vzletové body, navigační prvky a ostatní letadla.

Během našeho výzkumu jsme identifikovali několik oblastí, ve kterých bychom mohli provést zlepšení a rozšířit naše poznání. Jednou z těchto iniciativ je provedení více letů, což by nám umožnilo získat větší množství dat a rozšířit náš soubor informací. Dále bychom mohli zvýšit objem obrázků použitých pro trénování neuronových sítí, což by přispělo k jejich lepšímu výkonu a přesnosti. Další možností je rozšíření detekce sledovaných objektů, abychom získali podrobnější informace o tom, na co se piloti zaměřují během letu. Toto by nám umožnilo lépe porozumět jejich vizuálním preferencím a rozhodovacím procesům.

Přínosy této práce jsou však značné. Nejenže jsme získali hlubší pochopení leteckého průmyslu a jeho specifik, ale také jsme identifikovali klíčové rozdíly mezi zkušenými piloty a úplnými začátečníky. To nám umožnilo provést důkladné porovnání jejich přístupu k letectví, způsobu rozhodování a strategií při létání. Díky tomu jsme si uvědomili význam praktické zkušenosti a jaký vliv má na kvalitu a efektivitu letu.

Představujeme si, že tento výzkum by mohl být aplikován na jakéhokoliv řidiče v různých dopravních prostředcích, nejenom ve vzdušném prostoru. Tímto způsobem bychom mohli získat cenné poznatky o tom, na co se řidiči při řízení zaměřují nejvíce, a identifikovat klíčové oblasti soustředění pozornosti. Například, zjistit, zda je lepší řídit bez předešlého spánku v noci nebo zda je vhodnější řídit v noci s lehkým odpočinkem. Taková data by mohla sloužit jako podklad pro formulaci bezpečnostních opatření a směrnic v oblasti silniční dopravy.

## Poděkování

Naše hlavní poděkování si zaslouží Vladimír Socha, Viktor Valenta, Martin Novotný a Lenka Hanáková za odbornou pomoc při naší práci na Ústavu letecké dopravy ČVUT.

## Reference

- [1] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25:1097–1105, 2012.
- [2] Ning Qian. On the momentum term in gradient descent learning algorithms. *Neural Networks*, 12(1):145–151, 1999.