





**ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE**

---

Fakulta dopravní

Ústav letecké dopravy

Bc. Sarah Van den Bergh

**Hodnocení výkonnosti pilotů v leteckém výcviku**

**Training Performance Evaluation of Pilots in flight Training**

Diplomová práce

Studijní program: Technika a technologie v dopravě a spojích

Studijní obor: Provoz a řízení letecké dopravy

Vedoucí práce: Ing. Bc. Vladimír Socha, Ph.D.

Ing. Andrej Lališ, Ph.D.

---

Praha 2018



**K621..... Ústav letecké dopravy**

## **ZADÁNÍ DIPLOMOVÉ PRÁCE**

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení studenta (včetně titulů):

**Bc. Sarah Van Den Bergh**

Kód studijního programu a studijní obor studenta:

**N 3710 – PL – Provoz a řízení letecké dopravy**

Název tématu (česky): **Hodnocení výkonnosti pilotů v leteckém výcviku**

Název tématu (anglicky): Training Performance Evaluation of Pilots in Flight Training

### **Zásady pro vypracování**

Při zpracování diplomové práce se řiďte osnovou uvedenou v následujících bodech:

- Analýza požadavků současných leteckých výcviků
- Identifikace možných datových zdrojů
- Návrh metodologie hodnocení výkonnosti ve výcviku
- Ověření metodologie na zkušebním vzorku
- Vyhodnocení navrženého řešení

- Rozsah grafických prací: dle pokynů vedoucího diplomové práce
- Rozsah průvodní zprávy: minimálně 55 stran textu (včetně obrázků, grafů a tabulek, které jsou součástí průvodní zprávy)
- Seznam odborné literatury: nař. EP a Rady (ES) č. 216/2008  
nař. Komise (EU) č. 1178/2011  
EASA Acceptable Means of Compliance and Guidance Material to Part-ORO  
ICAO Doc 9995 Manual of Evidence-based Training

Vedoucí diplomové práce: **Ing. Bc. Vladimír Socha, Ph.D.**  
**Ing. Andrej Lališ, Ph.D.**

Datum zadání diplomové práce: **28. července 2017**  
(datum prvního zadání této práce, které musí být nejpozději 10 měsíců před datem prvního předpokládaného odevzdání této práce vyplývajícího ze standardní doby studia)

Datum odevzdání diplomové práce: **29. května 2018**  
a) datum prvního předpokládaného odevzdání práce vyplývající ze standardní doby studia a z doporučeného časového plánu studia  
b) v případě odkladu odevzdání práce následující datum odevzdání práce vyplývající z doporučeného časového plánu studia



doc. Ing. Jakub Kraus, Ph.D.  
vedoucí  
Ústavu letecké dopravy



doc. Ing. Pavel Hrubeš, Ph.D.  
děkan fakulty

Potvrzuji převzetí zadání diplomové práce.



Bc. Sarah Van den Bergh  
jméno a podpis studenta

V Praze dne ..... 28. února 2018

## Abstrakt

---

S neustále se vyvíjející situací v oblasti letecké dopravy je žádoucí změnit i letecký výcvik tak, aby reflektoval potřeby a hrozby současnosti, neboť tradiční výcvik se téměř nemění již celá desetiletí. Reakcí na tuto potřebu je vznik alternativních výcvikových konceptů jakými jsou AQP, ATQP a zejména Evidence-based Training. Tyto koncepty ale nejsou aplikovány na výcvik začátečníků, což se jeví jako zásadní etapa výcviku pilota. Cílem je podchytit všechny špatné návyky, posílit výcvik manévrů, které pilot nezvládá, a naopak neztrácet čas nad manévry, které pilot již zvládá. To vše by mělo proběhnout na základě objektivního hodnocení. Takovéto hodnocení však v současné době není standardně dostupné a hodnocení jako takové je postavené pouze na subjektivním vyhodnocení výcviku instruktorem. Z tohoto důvodu je cílem této práce vytvořit prostředek pro objektivizaci výcviku, který by mohl sloužit jako podpora pro letové instruktory. Pro tyto účely byla použita data z letového zapisovače. Výstupem této práce je softvérový prostředek pro automatickou identifikaci letových manévrů.

Klíčová slova: hodnocení, přesnost pilotáže, letecký výcvik

## **Abstract**

---

Ever-changing situation in the aviation demands a change in flight training programs that would reflect present needs and threats in contrary to the traditional training that hasn't changed much for decades. Therefore, new alternative concepts like AQP, ATQP and in particular Evidence-based Training have been developed that cover these needs. However, these concepts do not apply to initial training which seem to be a crucial phase of a pilot training. The aim is to avoid bad habits, strengthen the training of manoeuvres that aren't performed well thus save time on manoeuvres that are performed already well. All this should be done based on an objective evaluation. Such evaluation is currently not applied and the evaluation itself is exclusively based on subjective assessment of the flight training instructor. From the measured data by flight data recorder, respective parameters were selected to assess the precision of flight manoeuvres.

Keywords: evaluation, piloting precision, flight training

## Čestné prohlášení

---

Prohlašuji, že jsem předloženou diplomovou prací s názvem „Hodnocení výkonnosti pilotů v leteckém výcviku“ vypracovala samostatně a že jsem uvedla veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

Nemám závažný důvod proti užívání tohoto školního díla ve smyslu § 60 Zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon).

V Praze dne 29. května 2018



.....

Podpis

# Obsah

---

1	Definice problému (bude úvod) .....	1
2	Koncept Evidence-based Training .....	2
2.1	Vývoj .....	2
2.2	Současný stav .....	3
2.2.1	Implementace EBT do norem EU .....	4
2.2.2	Zavádění EBT konceptu .....	5
2.2.3	Použitelnost, cíle a přínos ICAO EBT Manuálu .....	5
2.2.4	EBT Metodologie .....	6
2.2.5	Harmonizace.....	9
2.2.6	EASA vize .....	9
3	Současný stav provádění výcviků .....	10
3.1	Part-ORO.....	10
3.2	Part-FCL .....	10
3.2.1	Hodnocení .....	11
3.3	Objektivní vs. subjektivní hodnocení .....	13
3.4	Alternativní metody hodnocení výkonu pilota .....	14
4	Metodologie .....	17
4.1	Použité nástroje popisné statistiky .....	17
4.2	Standardizace .....	18
4.3	Statistické vyhodnocení souboru dat.....	18
4.3.1	Wilcoxonův dvouvýběrový test.....	18
4.3.2	Bonferroniho korekce .....	19
4.4	Machine Learning.....	20
4.4.1	Získávání nových znalostí - proces učení se .....	22
4.4.2	Používané metody machine learning .....	26



4.4.2.1	Shluková analýza .....	26
4.4.2.1.1	Používané vzdálenosti .....	26
4.4.2.1.2	Hierarchické shlukování.....	27
4.4.2.1.3	K-means .....	29
4.4.2.1.4	DBSCAN.....	29
4.4.2.2	Regresní stromy .....	30
4.4.2.3	SVM klasifikace .....	32
4.4.2.4	Naive Bayes .....	33
4.4.2.5	Rizika a omezení metod machine learning: overfitting a underfitting .....	34
4.4.3	Stavba softvéru.....	35
4.4.3.1	System .....	35
4.4.3.1.1	Přístup a načtení dat.....	37
4.4.3.1.2	Aplikace zvolených postupů .....	38
5	Výsledky .....	47
6	Diskuze.....	49
7	Závěr .....	50
	Seznam použité literatury: .....	52
	Seznam použité literatury u obrázků: .....	57

## Seznam obrázků

---

Obrázek 4.1 Boxplot [a].....	17
Obrázek 4.2 Propojení machine learning s dalšími vědními obory. [b] .....	21
Obrázek 4.3. Rozdíl mezi tradičním způsobem programování a strojovým učením [c] .....	22
Obrázek 4.4 Techniky strojového učení [d].....	23
Obrázek 4.5 Ukázka dendrogramu.....	28
Obrázek 4.6 Stavba algoritického stromu .....	31
Obrázek 4.7 SVM klasifikace .....	32
Obrázek 4.8 Problém generalizace [f] .....	34
Obrázek 4.9 Stavba softvérového řešení [g] .....	36
Obrázek 4.10 Harmonogram výcviku [h].....	38
Obrázek 4.11 Ukázka detekce šumu (černá) a jednotlivých shluků na základě náklonu a vertikální rychlosti .....	39
Obrázek 4.12 Ukázka rozdělení shluků definujících manévry na základě časové oblasti (čísla vzorku) s cílem rozdělení shluků na jednotlivé manévry. ....	42
Obrázek 4.13 Ukázka vykresleného průběhu letu s identifikovanými fázemi horizontálního přímočarého letu (červená) a dalších manévrů (zelená). ....	44
Obrázek 4.14 Ukázka výstupu popsaného skriptu pro automatickou detekci manévrů. ....	46
Obrázek 5.1 Distribuce kumulativní chyby pro testovaný vzorek subjektů v průběhu celého výcviku .....	47

## Seznam tabulek

---

Tabulka 3.1 Stupnice odstupňovaného hodnocení.....	12
Tabulka 5.1 Výsledky Wilcoxonova testu pro porovnání statistické podobnosti kumulativní chyby v jednotlivých fázích výcviku.....	48

## Seznam zkratek

---

AQP	Advanced Qualification Program	
ATO	Approved Training Organization	
ATQP	Alternative Training Qualification Programme	
CAA	Civil Aviation Authority	Letecký úřad
CASA	Civil Aviation Safety Authority	
CBT	Competency-based Training	
CRM	Crew Resource Management	
DBSCAN	Density-based spatial clustering of applications with noise	
EASA	European Aviation Safety Organization	Evropská agentura pro bezpečnost letectví
EBT	Evidence-based Training	
EEG	Electroencephalography	Encefalografie

EKG	Electrocardiography	Elektrokardiogram
EPAS	European Plan for Aviation Safety	Evropský plán pro bezpečnost letectví
FAA	Federal Aviation Authority	Federální letecký úřad
FC	Flight Crew	
FSTD	Flight Simulation Training Devices	
GM	Guidance Material	
GNSS	Global Navigation Satellite System	Globální družicový polohový systém
IATA	International Air Transport Association	Mezinárodní asociace leteckých dopravců
ICAO	International Civil Aviation Organization	Mezinárodní organizace pro civilní letectví
IFALPA	International Federation of Air Line Pilot's Associations	Mezinárodní asociace dopravních pilotů
IL-3	Interleukin 3	
IL-6	Interleukin 6	
Part-FCL	Part - Flight Crew Licencing	

Part-ORO

Part – Organisation  
Requirements for Air  
Operations

TAS

True Airspeed

Pravá vzdušná rychlost

VFR

Visual Flight Rules

Let za viditelnosti

HPL

Straight and Level Flight

Horizontální přímočarý let



## 1 Definice problému (bude úvod)

---

Změna. Vývoj. Pokrok. To jsou hesla, která globálně zaznívají ve všech odvětvích letectví, oblast výcvikových programů nevyjímaje. V současné době jsou výcvikové programy prováděny tradičním způsobem neměním se již několik desetiletí, a ač se začínají objevovat náznaky a dokonce pokusy o změnu způsobu provádění výcviků, stále tato snaha nereflektuje skutečné potřeby. Požadavky a hrozby při provádění letu v začátcích obchodní letecké dopravy se liší od nynějších požadavků a hrozeb. Tuto skutečnost je potřeba změnit, adaptovat se na neustále se proměňující a nově vznikající situace nastavením flexibilního výcviku uzpůsobeného každému pilotovi na základě jeho potřeb. Paradoxem současné situace jsou široké možnosti aplikace moderních technologií, které se nevyužívají vůbec, či jen částečně, určitě však ne v celém svém potenciálu.

Tato práce pojednává o trendech provádění a hodnocení výcviku v posledních letech. Zmiňuje koncepty ATQP, AQP a zejména Evidence-based Training, který z prvních dvou zmíněných vychází, a v myšlence flexibilních výcviků pokračuje ještě dál. Nevýhodou těchto konceptů je jejich nedostatečná implementace napříč celým spektrem výcvikových programů. Objevují se jen u velkých dopravců a pouze při obnovujícím výcviku. Zároveň je nastíněn současný způsob hodnocení provedení výcviku, zejména pak provedení jednotlivých letových manévřů, tedy hodnocení přesnosti pilotáže.

Na základě průzkumu současné situace vyvstává otázka, jak implementovat principy Evidence-based Training i na počáteční fázi letového výcviku. Za touto otázkou stojí myšlenka, proč odstraňovat zažité chyby pilotáže až v obnovovacích výcvicích, když je možné zamezit jejich rozvinutí již v samém počátku učení se. Dalším, a v této práci nejdůležitějším, argumentem pro aplikaci zmíněných konceptů je neschopnost instruktora o absolutní objektivitu hodnocení. Z toho vyplývá, že cílem práce je navrhnout řešení objektivního hodnocení v podobě softvéru, které by podepřelo instruktorovu evaluaci pilotáže.

Ve smyslu prvních slov je tato práce především krokem vpřed. Krokem z neznáma k určitosti. Představuje možnost jak přesnost pilotáže ohodnotit a ve výsledku ji případně zvýšit. Zdali se bude jednat o reálný způsob hodnocení, ukáže až čas.

## 2 Koncept Evidence-based Training

---

### 2.1 Vývoj

Výcvik pilotů založený na koncepci Evidence-based Training se zrodil z potřeby změnit rámec/standardy pilotního výcviku, který se, v podstatě od 60. let minulého století, téměř nezměnil. Co se ale změnilo, byla doba a technologie, které se za posledních 50-60 let změnili radikálně. Současné technologie nabízejí kromě možnosti zlepšení efektivity výcviku zároveň i zvýšení bezpečnosti provozu. EBT je metoda, která dopravcům poskytuje možnost restrukturalizovat a přizpůsobit výcvikový program na míru svým potřebám a přitom nesoustředit vzácný čas a finanční prostředky na hrozby existující v zmíněných 60. letech.

Program EBT staví na základech amerického Advanced Qualification Program (AQP) a na ICAO Alternative Training Qualification Programme (ATQP), které nabízejí dobrovolnou alternativu k tradičnímu pojetí výcviku od pilotů, přes letecký personál až po provozní personál. [1]

Myšlenka na vznik nových výcvikových programů přišla až koncem 80. a začátkem 90. let minulého století, a to v souvislosti se stoupajícím počtem nehod amerických dopravců, kde hlavní příčinou bylo selhání lidského činitele. FAA, Federal Aviation Administration, neboli nejvyšší americký úřad spravující oblast letectví, tehdy na konci 80. let povolil leteckému průmyslu flexibilní trénink s větší možností adekvátní reakce na tehdejší hrozby. FAA tento alternativní koncept převzala z tehdy používaného vojenského výcvikového přístupu založeného front-end analýze letových úloh, tedy úvaze nad tím, co vše se může stát, do jakých situací se pilot může při provádění manévrů dostat, a back-end analýze dat, tedy zpětné zhodnocení dat. Tento převzatý a upravený koncept pro obchodní leteckou dopravu byl pojmenován Advanced Qualification Program. Výrazným rysem AQP bylo a je, že účast v programu je pro dopravce dobrovolná a že lze program kdykoliv opustit a vrátit se k tradičnímu výcviku, že je nutné systém aplikovat na oblasti výcviku jako analýzu, strukturu, vývoj, implementaci, provoz a hodnocení a nakonec, že získaná a zpracovaná data musí dopravci sdílet s FAA pro zpětnou vazbu. Program je sice dobrovolný, ale jsou určité části výcviku, které jsou v právním řádu pevně zakotveny a jež je potřeba dodržovat. [2]

Po letitých zkušenostech FAA zjistila, že pokud mají dopravci na výběr ze dvou možností jak k výcviku přistupovat, tak čím dál častěji sahají po dobrovolném přístupu, kdy dokonce dochází



k tomu, že samotná společnost si zvedá a překračuje nároky na výcvik danými FAA. Zpětná vazba také poukazuje na fakt, že tento přístup i díky zvýšeným nárokům se stává mnohem bezpečnější. Ukazuje, že klíčem úspěšné implementace AQP jsou instruktoři a hodnotitelé. [2]

Odpovědí na americký alternativní přístup k výcviku bylo vytvoření evropského programu alternativního výcviku a kvalifikací, ATQP, k rigidně stanovenému výcviku v legislativě v roce 2006. Základní legislativní rámec byl popsán v nařízení/ustanovení JAR-OPS 1.978, které se později začlenilo pod Part ORO.FC.A.245 v rámci EASA. ATQP je opět odlišný způsob provádění základních i obnovovacích výcviků, který dopravcům umožňuje výcvik přizpůsobit svým specifickým potřebám, a tím zvýšit efektivitu. Podle ORO.FC.A.245 může provozovatel letounu mající dostatečnou praxi nahradit jeden nebo více typů výcviku a přezkoušení letové posádky právě programem alternativního výcviku a kvalifikací. Mezi typy výcviku, které lze nahradit ATQP patří:

- přeškolovací výcvik a přezkoušení;
- rozdílový a seznamovací výcvik;
- kurz velení;
- opakovací výcvik a přezkoušení a
- létání na více typech nebo variantách

U standardního výcviku se postupuje podle seznamů úkolů, tzv. checklistů, kdy proces postupu a plnění těchto úkonů se nazývá tzv. box-ticking. Tím, že se dopravce opět soustředí na to, co letecký personál potřebuje, nepostupuje podle rigidních seznamů, a tedy neopakuje to, co již člověk v zácviku může ovládat, je výcvik flexibilní, kratší a levnější. [3, 4]

## 2.2 Současný stav

Po letech praxe se však přišlo na to, že větší efektivity se nedosáhne pouze zaměřením na běžné operace dopravce a jejich perfektní provedení, ale vytvořením takového konceptu výcviku, který by stavěl na zkušenostech leteckého personálu. Proč nesčetně krát opakovat úkon, který pilot už dávno ovládá, a místo toho čas dedikovaný výcviku využít na to, co mu ještě nejde a potřebuje procvičit? Proto se důraz postupně přenáší z organizace jako celku na

jednotlivé piloty, přičemž cíle a potřeby organizace zůstávají zachovány. EBT koncept stojí na *evidence*, tedy na důkazech, na datech či předcházejících měřeních, a podle potřeby pilota se postup výcviku náležitě přizpůsobuje.

Rozdíl mezi EBT a alternativními programy popsanými výše platil v době, kdy program EBT vznikal. V současné době to vypadá, že se tento rozdíl mezi alternativními programy výcviku a EBT stírá, neboť ATQP se v současnosti také soustředí na zvyšování efektivity na základě sbíraných, analyzovaných a zhodnocených dat. Není tomu tak úplně pravda. Pořád platí, že koncept EBT se postupně vyvinul z konceptů ATQP/AQP, které představovaly první krok od „one size fits all“<sup>1</sup>, ale EBT se od nich liší svou strukturou. Hlavní rozdíl tkví v tom, že dopravce zavádějící EBT má zdarma k dispozici globální data. Aerolinie tedy mohou použít tato data/zkušenosti na např. různé typy letadel. Časem je dopravce schopen začlenit vlastní zpracovaná data a koncept opět upravit na míru svým vlastním potřebám.

### 2.2.1 Implementace EBT do norem EU

Podle definice v Part-ORO EBT znamená trénování a hodnocení založené na datech sbíraných v provozu. Tato data jsou charakteristické vývojem a hodnocením celkových schopností studenta ve výcviku napříč celým spektrem úloh. Dochází tedy k objektivnějšímu celkovému hodnocení namísto individuálního hodnocení jednotlivých manévřů. Základním dokumentem pro dopravce hledající informace pro implementaci EBT je ICAO Doc 9995, který již zohledňuje evropský právní rámec EBT. V současné době, pokud se dopravce rozhodne pro EBT musí tento koncept aplikovat na celou flotilu, avšak nemusí jej aplikovat na všechny typy výcviku. [5]

V evropském právním rámci je EBT začleněn do Part-ORO (Organization Requirements for Air Operations) což představuje Přílohu 3 k nařízení Komise (EU) č. 965/2012 ze dne 5. října 2012, kterým se stanoví technické požadavky a správní postupy týkající se letového provozu podle nařízení Evropského parlamentu a Rady (ES) č. 216/2008, jinak nazývaného „Air OPS Regulation“. Toto začlenění bylo provedeno o pár let později v roce 2015 formou rozhodnutí

---

<sup>1</sup> Koncept „one size fits all“ představuje ideu, že univerzální přístup je ten nevhodnější.

výkonného ředitele EASA, a to Rozhodnutím 2015/027/R ze dne 16. prosince 2015 s účinností rozhodnutí 20. prosince 2015. [6, 7]

Kromě požadavků začleněných do nařízení č. 965/2012, byla určitá část požadavků začleněna do nařízení Komise (EU) č. 1178/2011 ze dne 3. listopadu 2011, kterým se stanoví technické požadavky a správní postupy týkající se posádek v civilním letectví podle nařízení Evropského parlamentu a Rady (ES) č. 216/2008.

Podle dokumentu vydávaného EASA „Terms of Reference“ RMT.0696 byl vytvořen prozatímní Guidance Material (GM), plné začlenění EBT podle ICAO Doc 9995 do GM přišlo až se změnou RMT dokumentu RMT.0599. [7]

### 2.2.2 Zavádění EBT konceptu

Při aplikaci EBT na vlastní výcvikové programy se doprava řídí ICAO manuálem Doc 9995, který zatím poskytuje návod pro obnovovací výcvik na simulátorech. Další podklad poskytuje dokument vypracovaný IATA v součinnosti s IFALPA a ICAO Evidence-based Training Implementation Guide. V roce 2014 IATA organizace zveřejnila dokument s názvem Data Report for Evidence-based Training, který v sobě obsahuje dosud všechna sbíraná, zanalyzovaná a zhodnocená data. Jedná se o velmi přínosný dokument, neboť odráží letité zkušenosti mnoha aerolinií.

### 2.2.3 Použitelnost, cíle a přínos ICAO EBT Manuálu

ICAO Manuál implementace EBT je určen pro letecké úřady (CAA), provozovatele a schválené výcvikové organizace – Approved Training Organizations (ATO), a to pouze na obnovovací výcvik prováděný na simulátorech – Flight Simulation Training Device (FSTD) odpovídající proudovým letadlům s kapacitou minimálně 50 a více cestujících a turbovrtulovým letadlům s minimální kapacitou 30 a více cestujících. Kromě návodu, jak koncept EBT začlenit do svých výcvikových programů, slouží tento dokument i jako návod hodnocení pro instruktory provádějící výcvik podle EBT.

Na základě současného stavu letectví a konkrétně stavu výcvikových programů je cílem potřeba vyvinout takový nástroj k hodnocení výkonu posádky, který by nerozlišoval pouze mezi technickými a netechnickými schopnosti spolupráce v posádce (Crew Resource Management - CRM), které jsou považovány za základ bezpečného provozu, ale posuzoval by výkon jako celek.

Cílem EBT není kompletně nahradit sadu všech, mnohdy zastaralých, kritických úkonů novou sadou, ale použít události jako prostředek pro vývoj a hodnocení výkonu posádky přes celou řadu potřebných schopností a kompetencí. Navíc, EBT zaměří instruktorovu pozornost na analýzu základních operací/úkonů, které později s čím dál tím více kupíci znalostmi způsobují nežádoucí návyky a reakce. Vhodným způsobem reakce instruktora podle EBT je náprava ještě v raných začátcích. Obvykle se tyto situace totiž řeší tak, že instruktor požádá žáka manévr opakovat, aniž by postřehl či dokonce vysvětlil, proč byl manévr dříve neúspěšný.

Propagátoři myšlenek EBT si uvědomují, že dnešní simulátory, velmi technicky pokročilé, obsahují mnoho funkcí, které nejsou (efektivně) využívány, neboť legislativa tíhne k tzv. checking, tedy striktní odškrtávání seznamů – checklistů, kde není prostor pro analýzu provedení jednotlivých manévrů a případné zopakování nedostatečně provedeného úkolu nikoho již nezajímá, proč se některé věci dějí. Cílem EBT je tedy snaha o opravu nerovnováhy mezi skutečnou podstatou trénování a prostou kontrolou (checking). [8]

#### 2.2.4 EBT Metodologie

Koncept EBT je určen k vývoji a hodnocení všech oblastí schopností (orig. competency) letové posádky v obnovovacím výcviku. Za tím účelem byl vytvořen seznam hrozeb a možných chyb. Seznam je kategorizován podle generací letadla (generace 1-4, od nejstarších po nejnovější modely, možno vložit tabulku s výčtem generací letadel) a fází letu, ve které se uvedené hrozby a chyby mohou vyskytnout.

Aby bylo možné hodnotit schopnosti, je prvním krokem vytvoření úplného rámce hodnocených schopností, jejich popis, které zahrnují technické a netechnické znalosti, dovednosti a postoje, které umožňují bezpečný, efektivní a ekonomický provoz. Druhá část

metodiky vytvoření EBT výcviku je postavená na průzkumu kritických částí výcviku (orig. training criticality survey) identifikující hrozby a možné chyby v různých fázích letu. Tyto hrozby a chyby jsou rozděleny do 8 kategorií, fází letu, od předletové přípravy a pojiždění, přes vzlet, stoupání, let v cestovní hladině, klesání, fázi přiblížení, přistání a pojiždění a (post-flight).

Základním pilířem celého konceptu je sbírání dat, jehož smysl tkví v tom, že slouží jako referenční databáze událostí založená na zmíněných generacích letadel. Je nutné shromažďovat údaje nejen z výcviku/ze simulátorů, ale i data z reálného provozu, incidentů a nehod, neboť neustálou aktualizací dat zůstane výcvik aktuální. Za tímto účelem se data sbírají od provozovatelů, výrobců, orgánů vyšetřující nehody, mezinárodních leteckých organizací a leteckých úřadů. Provozovatel sbírá:

- a) Letecká data obsahující analýzu posledního vývoje v rámci své flotily. Pokud je to požadováno, data musí splňovat podmínky podle *Data Report for Evidence-based Training*
- b) Data z výcviků obsahující analýzu posledního vývoje v rámci své flotily. Pokud je to požadováno, data musí splňovat podmínky podle *Data Report for Evidence-based Training*
- c) SMS data, včetně *safety reports* s analýzou všech *safety* dat ze všech možných zdrojů, obzvláště těch, které mohou být zmírněny pilotním výcvikem.
- d) Data postihující specifické potřeby provozovatele – síť tras, používaná letiště, počasí apod.
- e) Globální data provozovatelů s podobnými rysy.

Kritickou částí výcviku pak je analýza dat. Na úrovni jednotlivého zdroje dat se provádí předběžná analýza dat, po níž následuje globální (potvrzující) analýza, která kombinuje všechny datové zdroje. Analýza probíhá zhruba tímto způsobem:

1. Analýza na globální úrovni všech generací letadel, která kombinuje i porovnává výsledky napříč různými generacemi
2. Specifická analýza pro každou generaci letadel

3. Důležitost jednotlivých schopností (váhové ohodnocení jednotlivých schopností?, jaké schopnosti jsou důležité u specifických hrozeb? Relevance of competencies)
4. Analýza trendu v čase
5. Analýza podle fáze letu
6. Zhodnocení, zdali je možné hrozbě a chybám z ní vyplývajícím, předejít výcvikem(?) (evaluation of „trainability“)
7. determination of priority of factors based on rates, risk and trainability. (Stanovení priorit faktorů založených na ..)

Následně se provede zmíněný průzkum kritických částí výcviku, neboli Training Criticality Survey, jehož výsledkem jsou matice hrozeb a chyb odpovídající jednotlivým fázím letu. Posléze se provede analýza těchto matic, která probíhá následujícím způsobem:

1. pro danou generaci se ve všech fázích zjišťuje medián distribuce výsledků pramenících z matice rizik (vycházející z pravděpodobnosti výskytu, závažnosti a přínosu úrovně výcviku). Všechno nad mediánem je zachováno za předpokladu, že úroveň přínosu výcviku byla alespoň 3 (moderate) a vyšší.
2. Medián distribuce rizika se zjišťuje ve všech fázích letu. Vše, co bylo vyřazeno podle bodu 1. ale zároveň s hodnotami stojícími nad mediánem distribuce rizika, bylo ponecháno.
3. Vše, co bylo vyřazeno, podle bodu 1. a 2. ale s přínosem výcviku ohodnoceným 4 (significant) a lepší, bylo zachováno.

Na závěr této části bylo stanoveno hodnocení přidělování vah jednotlivým výsledkům.

Jakmile je proces analýzy matic hotov, následuje tzv. *Evidence Table process*. Jedná se o tabulku obsahující výsledky různých zdrojů. *Evidence Table* proces probíhá následujícím způsobem:

1. Výsledky jsou identifikovány/popsány několika klíčovými slovy a
2. Zjištění určí soubor závěrů, na základě kterých je určena priorita výcviku.

Tam, kde to je vhodné, zjištění ovlivňují faktor nehody/incidentu. Tato Tabulka důkazů je součástí dokumentu *Data Report for Evidence-based Training*. [8]

### 2.2.5 Harmonizace

FAA plně podporuje celý koncept EBT. Zároveň se podílí na vývoji programu a podporuje americké dopravce, obzvláště ty, které již praktikují výcvik podle AQP, k začlenění EBT do výcvikových plánů. [7]

Australský úřad kompetentní v oblasti bezpečnosti letectví Civil Aviation Safety Authority (CASA) se myšlenkou zabývá od roku 2012, kdy byl schválen projekt možnosti alternativního výcvikového konceptu. V roce 2016 bylo cílem australským dopravcům podat jasné a konzistentní informace, jak data sbírat, hodnotit a poznatky aplikovat na vlastní výcvikové programy. V roce 2017 ICAO zdůraznilo potřebu implementace nového zdravého rámce pro výcvikové programy, který by umožňoval kontinuální analýzu a hodnocení schopností pilota. Na základě analýzy sesbíraných dat od dopravců Úřad zjistil, že existují významné rozdíly v očekáváních od pilotů lišící se mezi jednotlivými organizacemi poskytující výcvik. Zároveň bylo zjištěno, že jen několik málo dopravců sbírá a analyzuje svá data a nakonec podle nich i upravuje výcvikový program. Proto CASA zdůrazňuje potřebu sbírat tato data, neboť v plánu je vývoj takového výcvikového programu, který by odrazil požadavky dopravce s měnícím se vybavením, technologiemi, nově vznikajícími/vzniklými hrozbami nebo jen změnami v letových cestách. Tato data by sloužila jako databanka pro začleňující EBT výcvikové programy. [7, 9, 10]

### 2.2.6 EASA vize

EASA každý rok vydává a aktualizuje předcházející European Plan for Aviation Safety (EPAS), neboli Evropský plán bezpečnosti letectví. V současném Plánu vydaném na rok 2018-2022 je cílem kompletní přepracování ustanovení v části ORO oddíl FC. Z vize vyplývá, že EBT již nebude dobrovolnou možností, ale stane se povinným způsobem provádění výcviku. Fázi zavádění EBT je několik: v první fázi bude implementace EBT (i CBT) programu povinná pro všechny obnovující výcviky, ve druhé fázi se EBT bude rozšiřovat na další části výcviku jako je typový výcvik a ve třetí fázi se implementace dotkne i dalších typů letadel, kupříkladu menších letadel, vrtulníků apod. [11]

## 3 Současný stav provádění výcviků

---

V předešlých kapitolách bylo vysvětleno mnoho pojmů týkajících se pokročilých a alternativních výcvikových programů. Tato kapitola rozšiřuje teoretickou část práce o popis situace s ohledem na standardní výcvik.

### 3.1 Part-ORO

Zmíněná část ORO, oddíl Flight Crew (FC) představující Přílohu 3 k nařízení č. 965/2012 obsahuje obecné statě o poskytování výcviku. Konkrétní část zabývající se výcvikem je ORO.FC.145 Poskytování výcviku, kde je řečeno, že výcvik musí být v souladu s osnovami výcviku, které si dopravce stanoví, že výcvik provádějí adekvátně kvalifikovaní pracovníci a že programy základního i obnovující výcviku včetně osnov schvaluje příslušný letecký úřad. Zároveň je v části ORO.FC.145 řečeno, že simulátory, neboli Flight Simulation Training Devices (FTSD), se musí co nejvíce shodovat s letadlem, které provozovatel používá a že musí zavést systém monitoringu FTSD tak, aby se zabránilo vyvinutí změn, které by na program výcviku měly negativní dopad. Další částí, která se zabývá výcvikem, je část ORO.FC.230 Opakovací výcvik a přezkoušení, která stanovuje, že každý člen posádky musí absolvovat opakovací výcvik i přezkoušení na totožný typ letadla, na kterém létá. Při přezkoušení pilot musí prokázat odborné způsobilosti, traťové přezkoušení v letadle a přezkoušení v používání nouzového a bezpečnostního vybavení. [12]

### 3.2 Part-FCL

Základním dokumentem pro získání licencí a kvalifikací je Part-FCL (Flight Crew Licensing), Příloha 1 k nařízení Komise (EU) č. 1178/2011 (ze dne 3. listopadu 2011, kterým se stanoví technické požadavky a správní postupy týkající se posádek v civilním letectví podle nařízení Evropského parlamentu a Rady (ES) č. 216/2008). Podle tohoto dokumentu Approved Training Organization (ATO), neboli schválená výcviková organizace, vytváří vlastní interní postupy výcviků a přezkoušení za současného dodržení minim a postupů stanovených v části FCL.



Základní osnova výcviku podle části FCL vypadá následovně:

- Výuka
  - Součástí získání pilotní licence je určitý počet absolvované teorie (počet hodin stoupá s každou vyšší úrovní licence).
- Výcvik v létání
  - Kromě získání teoretických znalostí musí uchazeč získat i nezbytné pilotní dovednosti. Požadavek na počet hodin výcviku a rozsah se liší typem licence.
- Praxe
  - U některých typů licence je nezbytné absolvovat i praxi do určitého počtu hodin a rozsahu.
- Zkouška
  - Následně musí uchazeč o licenci znalost teoretických znalostí doložit u zkoušky.
- Zkouška dovednosti
  - Poslední součástí získání pilotní licence je prokázat pilotní dovednosti.

### 3.2.1 Hodnocení

Standardní formy výcvikových programů pracují pouze s dvěma možnými výstupy hodnocení, a to prošel/neprošel. Instruktoři samozřejmě také prochází výcvikem, jehož součástí je zvládnutí metodiky hodnocení. Kromě přípravy materiálů, vytváření prostředí pro výcvik, je součástí výcviku i vyškolení k tomu, aby dokázali správně zhodnotit výkonnost účastníka výcviku. [13]

V šesté kapitole příručky pro letecké instruktory vydané novozélandským leteckým úřadem je popsán způsob hodnocení žadatele o průkaz. Tam je hodnocení popsáno slovy: *comprehensive, systematic and objective*. Z toho vyplývá, že instruktor musí k žadateli o průkaz přistupovat s všímavým, systematickým a objektivním způsobem, a to při ústním dotazování, písemném zkoušení či testování výkonu v leteckém zařízení. Součástí náplně práce leteckého instruktora je pozorování dovedností a schopností žadatele a jeho zaznamenávání. Toto zaznamenávání výkonu studenta je známo jako *anecdotal record*, volně přeloženo jako stručný, leč výstižný záznam výkonu mající určitou strukturu a pravidla vyplňování, a který je čistě subjektivního charakteru. Novozélandská příručka vyzdvihuje pozitiva tohoto záznamu,

zejména proto, že dokáže zachytit chování v přirozených situacích. Manuál uvádí příklad studenta, který sice oplývá vynikajícími znalostmi minim VFR, ale v opakovaně a vědomě je porušuje, což takový záznam může odhalit. Pro hodnocení jiných soft parametrů, což jsou dovednosti v oblasti chování, tedy představující sociální a emoční inteligenci, je lepším záznamem strukturalizovaný *rating scale*. Novozélandská univerzita Massey vyvinula hodnotící stupnici poskytující systematický postup zaznamenávání instruktorova pozorování. Stupnice (viz tabulka 3.1) sice má opět výstup prošel/neprošel, ale objevuje se náznak odstupňovaného hodnocení. [13, 14]

Tabulka 3.1 Stupnice odstupňovaného hodnocení

NEPROŠEL	PROŠEL	
1. Student používá nevhodné výkonnostní tabulky a další zdroje dat.	1. Používá správné výkonnostní tabulky a další zdroje dat.	1. Používá správné výkonnostní tabulky a další zdroje dat.
2. Užívá neadekvátní vstup ke kalkulaci vzdálenosti vzletu či přistání, a to tak, že by byla ohrožena bezpečnost.	2. Počítá s adekvátním vstupem pro kalkulaci vzdálenosti potřebné k vzletu či přistání.	2. Přesně a rychle počítá s vhodnými podmínkami pro kalkulaci vzdálenosti potřebné k vzletu a přistání.
3. Nevládne se ujistit o použitelné délce dráhy k vzletu či přistání.	3. Ujistí se, že je k dispozici dostatečná délka dráhy pro vzlet a přistání s využitím znalostí místního prostředí.	3. Ujistí se, že k dispozici je dostatečná délka dráhy pro vzlet a přistání, a to tak porovnáním potřebné a dostupné vzdálenosti.

Snaha o jemnější hodnotící kritéria je vidět v části FCL u jazykových schopností. Hodnocení jazykových schopností je dáno úrovněmi, kdy tři z nich, 4, 5 a 6 a jejich slovní ekvivalenty *provozní, rozšířená a odborná úroveň*, dávají více možností úspěšného složení zkoušky než pouze prošel/neprošel. Pořád však neřeší problém nedostatečné objektivity. [13]

### 3.3 Objektivní vs. subjektivní hodnocení

Hard skills, neboli odborné znalosti a dovednosti se na základě své podstaty měří snadněji než měkké dovednosti. V části FCL je jasně popsáno co, a jakým způsobem se při letových úlohách hodnotí. V současné době, ve světle pokročilých výcvikových programů, se ukazuje, že prosté hodnocení prošel/neprošel je nedostatečné.

Příručky a manuály jsou napsány velmi jasně. Při jejich pročitání lze nabýt dojmu, že žákův výkon bude hodnocen správně a spravedlivě. Po hlubším zamyšlení však vyvstane myšlenka, že neomylného a objektivního hodnocení instruktor nemůže dosáhnout, neboť se jedná o lidskou bytost s city a emocemi.

Ale školení a manuály pro instruktory už takovou jistotou neoplývají. Tato školení instruktora nabádají k objektivnímu hodnocení. A to, že instruktor výcvikem projde a získá FI licenci, ještě nezajišťuje stoprocentní objektivitu či správnost rozhodnutí. Existuje tisíc a jeden důvodů, které mohou narušit instruktorovu objektivitu. Mezi takové důvody mohou patřit neovlivnitelné fyzické příčiny, od hladu, žízně, únavy či nemoci, které snižují vnímání provedení letové úlohy, psychofyziologické jako stres, nebo psychické od silných emocí až po sympatie či antipatie k žákovi. Následkem subjektivního vyhodnocení, ať už cíleného nebo nikoliv, je evaluace, která neodpovídá skutečnému výkonu. Z toho vyplývá potřeba objektivního nástroje hodnocení.

Je těžké a nejspíše i nemožné přijít s objektivním přístupem k hodnocení soft parametrů. Je zcela nemyslitelné, že by člověk byl schopen naprosto objektivní evaluace v této oblasti a věda prozatím také s žádným řešením nepřišla.

Co však dnes možné je, je hodnocení tvrdých dovedností pomocí vědy a techniky. Budoucností se mohou zdát automatické hodnotící nástroje s implementovanou umělou inteligencí. Ale omezení umělé inteligence tkví v tom, že člověk musí softvéru tuto inteligenci dodat. Jenže inteligence se skládá ze znalostí, ale také ze zkušeností a lidských schopností, tedy jak z hard parametrů, tak i soft parametrů. Není problém stroj naučit, že při vzletu musí pilot držet kurz shodný s osou dráhy s maximální tolerancí  $\pm 5^\circ$ , že zatáčet má povoleno až v určité výšce či držet konstantní hladinu výšky. Těžké, ale ne nemožné, je naučit stroj rozeznat například jazykové schopnosti. Ale co je v této chvíli nemožné, je softvér naprogramovat tak, aby dokázal

správně vyhodnotit problematickou, nepřehlednou či jinak náročnou situaci. V mnoha situacích, a přitom se nemusí jednat o kritické situace, nemusí být vhodné jen jedno možné řešení. V takových situacích se totiž projeví instruktorovy zkušenosti jako truhlice přetéající zlatem. Nejcennější devizou instruktorů je totiž jejich *know-how*, *knowledge*, nebo jinak řečeno expertní znalost.

Z toho vyplývá, že vhodným a prozatím ideálním východiskem by bylo vymyslet takové řešení, které by kombinovalo automatický a objektivní způsob hodnocení hard parametrů s expertní znalostí instruktora. Objektivní softvér by podpořil názor instruktora a naopak instruktor by validoval výstup softvéru. Jednalo by se tak o komplementární řešení.

Hodnocení na základě analýzy dat je prozatím možné a dostupné jen pro provozovatele letecké dopravy, větší aerolinie, a jen pro obnovovací či typový výcvik. Z toho, co zatím bylo popsáno, plyne, že cílem práce bude nalézt takové řešení, automatický evaluátor, který by v reálném čase vyhodnocoval výkon pilota a který by sloužil jako objektivní doplněk hodnocení letového instruktora i pro menší podniky, v tomto případě pro letecké školy. Výstup takového systému založeného na nástrojích statistiky by mohl odhalit mnoho věcí, od úkonů, se kterými student-pilot má těžkosti přes úkony, které instruktor nemusí postřehnout až po úkony, které student-pilot zvládá natolik dobře, že je ztrátou času je neustále opakovat, když čas (a finance) věnovaný výcviku se dá využít právě k procvičení problematických úkonů, tudíž mnohem efektivněji. Použití evaluátoru by bylo nejefektivnější, pokud by jej bylo použito hned na začátku, v raném stádiu výcviku.

Takový prostředek by vyjadřoval nejen esenci EBT, tedy výcviku založeného na analýze dat, ale zároveň by naplnil ideu EASA vize 2022.

### 3.4 Alternativní metody hodnocení výkonu pilota

ICAO, IATA, další mezinárodní organizace či dopravci nezveřejňují způsob, na co se zaměřují, jakým letecká data zpracovávají, ani jaké parametry jsou evaluovány. V rámci akademické obce je toto téma řešeno jen velmi málo, ale z relativně mnoha úhlů.

Z hlediska hodnocení leteckých dat se přínosné ukazují být výzkumy zaměřené na měření psychofyzilogických reakcí jedinců na různé podněty. Existuje relativně mnoho studií, zaměřené na měření stresu, únavy a dalších reakcí, ale jen málo studií bylo publikováno přímo o psychofyzilogickém stavu pilotů. Obecně, podněty se měří z rozborů krve a slin, kdy nejčastější zkoumané podněty jsou saturace tepenné krve kyslíkem, hladina krevního cukru, hladina kortizolu, IL-3 a IL-6. Nejčastější měřené reakce na dané podněty jsou frekvence srdeční činnosti - EKG, dechová frekvence, myopotenciál – svalové napětí, teplota těla, měření mozkové aktivity - EEG, galvanická kožní reakce, krevní tlak. [15] Ukazuje se, že nejspolehlivějším ukazatelem stresu je tepová frekvence. [16] Budoucnost měření biosignálů tkví v následné implementaci do leteckých simulátorů. V praxi by to znamenalo, že by instruktorovi byl k dispozici další datový zdroj, ze kterého by bylo vidět, jaké manévry dělají pilotovi potíže.

S implementací moderních technologií do letadel se nabízí otázka, jak tento přechod piloti zvládají, zdali je potřeba to nějakým způsobem ošetřit a konečně jak jim tento přechod usnadnit. Přechodem z analogového zobrazení budíků na Glass Cockpit se zabývá několik studií.

Bylo zjištěno, že piloti bez předchozích či nevelkých zkušeností dosahují lepšího výkonu na letadlech s mechanickými analogovými zobrazovacími jednotkami než nováčci na letadlech s elektronickými displeji. Na druhou stranu dotazník odhalil silnou subjektivní preferenci skleněných kokpitů nad tradičním uspořádáním kokpitu. [17] Pokud se při přechodu z analogového zobrazení navigačních a motorových dat na LCD-displeje věnuje více času teorii zobrazení Glass Cockpit a výcviku na simulátoru se stejným zobrazením dat, piloti vykazují mnohem nižší hladinu stresu než ti, kteří absolvovali jen krátkou teoretickou přípravu a žádný výcvik na simulátoru. [18] Další studie měřila rozdíl reakčního času pilotů při na jednotkách s analogovým výstupem a LCD-displejem. Reakční čas byl měřen od nastalé kritické situace po učinění rozhodnutí, jak kritickou situaci vyřešit. Z tohoto souboje lépe vychází mechanické zobrazení leteckých dat. Tento fakt ale poukazuje na problém skleněných kokpitů, které se v letadlech objevují čím dál častěji. Skutečnost, že pilotovi trvá delší dobu zpracování informace z elektronických displejů, dělá ze skleněných displejů nebezpečnou technologii, obzvláště v případech, kdy rozhodují sekundy. [19] Při zachování současných výcvikových

sylabů u pilotů-začátečnicků u změny z analogového zobrazení na Glass Cockpit bylo zjištěno, že výkon u většiny subjektů poklesl. Naopak skupina subjektů, která prošla pozměněným výcvikem, vykazovala u všech subjektů vyšší výkon. [20]

Z předcházejícího odstavce jasně vyplývá, že je potřeba změny ve výcvikových programech, které by byly více zaměřené na Glass Cockpit coby představitele moderní technologie v současné době velmi rozšířené.

Po změně výcviků volají samotní piloti. Ze studie [20] vyplývá, že největší potřebu přetvoření výcvikových sylabů cítí v počátečním výcviku a výcviku nouzových postupů. Změnu výcviku je dále potřeba provést v oblasti komunikace, přistání a u typových výcviků. Nejnižší subjektivní potřebu změnit výcvik, neboť se jednalo o dotazník, respondenti cítí u letu v cestovní hladině, pojíždění, stoupání a klesání. 30 až 40% pozornosti by si zasloužily výcviky zaměřené na obnovovací trénink, transition training, brífinky a vzlety.

S narůstajícím množstvím moderních způsobů zobrazení navigačních a motorových informací (nejen Glass Cockpit, ale např i Head-Up Display) souvisí i přijímač GNSS signálu. Dopad je největší v segmentu všeobecné letectví, kde implementace nových technologií probíhá v kratším časovém horizontu než u velkých letadel určených k obchodní dopravě. Problém je, že současné výukové sylaby vydávaných EASA rozšířenou implementaci přijímačů GNSS signálů nereflektují. Na Žilinské univerzitě v Žilině, v Leteckém výcvikovém a vzdělávacím centru proběhl dvouletý pokus zahrnující návrh změny výcvikových sylabů odrážející potřeby současného moderního letectví a jeho hodnocení. Program ukázal, že navrhované změny by představovaly přínos k současným výcvikovým programům. [21]

Všechny výsledky dosavadních výzkumů zabývajících se změnou provádění výcviku se shodují, že změna výcviku v rané fázi je v první řadě žádoucí. Studie, v rámci kterých došlo k návrhu změny a dokonce k jejich ověření, se shodují na pozitivním dopadu navrhovaných změn.

## 4 Metodologie

---

Tato část práce se zabývá návrhem zpracování a hodnocení vícerozměrných statistických dat tak, aby výsledkem bylo vytvoření softvérového prostředí, který naměřená data dokáže zpracovat. To znamená, že kromě použitých nástrojů popisné statistiky obsahuje tato kapitola i části zabývající se strojovým učením a jednotlivými technikami strojového učení založených na robustních statistických metodách. Převážná část těchto metod je založená na klasické statistice, přesto se ve výběru představených metod objeví i jedna, naive Bayes, založená na nástrojích tzv. bayesovské statistiky, která v porovnání s klasickou statistikou mnohem jemněji, ač je potřeba přiznat, stále nedokonalým způsobem, pracuje se statistickými daty.

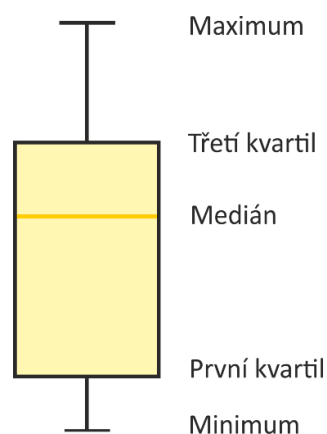
### 4.1 Použité nástroje popisné statistiky

Pro tuto práci bylo použito nástrojů popisné statistiky. Popis statistických dat je důležitým nositelem vlastností datového souboru. Základní používané nástroje jsou charakteristiky popisující polohu, rozptýlení, symetrii a špičatost rozptýlení.

Základní charakteristiky umístění jsou aritmetický průměr  $\bar{x}$ , popřípadě jeho modifikace vážený aritmetický průměr, dále pak medián  $\tilde{x}$  a modus  $\hat{x}$ .

Mezi charakteristiky rozptýlení patří rozptyl  $\sigma^2$ , směrodatná odchylka  $\sigma$ , popřípadě mezikvartilové rozpětí IQR (interquartile range).

Názornou ukázkou uvedených charakteristik je jejich grafická podoba ve formě tzv. boxplotů, neboli krabicových diagramů, viz obr. 4.1. [22]



Obrázek 4.1 Boxplot [a]

## 4.2 Standardizace

Standardizace dat je důležitou technikou prvotního zpracování naměřených veličin. Díky tomu lze získat výsledky, které budou moci být použity k výpočtu dalších souhrnných parametrů.

Standardizace je technika, která má zajistit validitu měření. Proměnné jsou díky standardizaci převedeny na stejné měřítko, díky čemuž nezáleží na původním rozměru, tzn., zajistí se shodné podmínky vyhodnocení pro veškerá opakující se měření. Nejčastější způsob provádění standardizace je přes směrodatnou odchylku, označováno také jako z-score. Vzorec výpočtu z-score je (1):

$$y_j = z = \frac{x_i - \bar{x}}{s},$$

kde  $y_j$  je hledaná proměnná,  $x_i$  je původní hodnota hledané proměnné,  $s$  je její směrodatná odchylka a  $\bar{x}$  je průměr hodnot. Konečná standardizovaná hodnota má ve výsledku průměr roven nule a rozptyl jedné. Toto zobecnění sebou přináší problém při výskytu odlehlých hodnot či při nenormálním rozdělení, neboť může způsobit problém při následném zpracovávání veličin, proto je důležité uvědomit si, kdy lze tuto metodu použít. Mezi další techniky standardizace, používané především ve shlukové analýze, jsou výpočet celkového součtu sloupce nebo řádku, maxima sloupce nebo řádku a převod vektoru řádku na jednotkovou délku. [33, 34]

## 4.3 Statistické vyhodnocení souboru dat

### 4.3.1 Wilcoxonův dvouvýběrový test

Neparametrické testy se využívají, pokud mají naměřená data jen ordinální charakter, či když se jedná o malý soubor dat s nenormálním rozložením.

Pokud je potřeba určit statistickou podobnost dvou nezávislých náhodných statistických měření s nenormálním rozdělením využívá se dvouvýběrového Wilcoxonova neparametrického testu. Tento test předpokládá, že oba výběry se spojitými distribučními



funkcemi mají stejné rozdělení pravděpodobnosti. Daný test je ekvivalentem parametrického dvouvýběrového t-testu, kde se však porovnává rozptyl a střední hodnota.

Pokud se ověřuje daná hypotéza o shodnosti distribuční funkce, je potřeba uspořádat hodnoty v obou výběrech od nejmenší po největší, následně se provede součet těchto hodnot u každého výběru samostatně. Vyjdou tedy součty  $T_1$  a  $T_2$ . Pomocí těchto součtů se dopočítají statistiky  $U_1$  a  $U_2$  následovně:

$$U_1 = n_1 n_2 + \frac{n_1(n_1 + 1)}{2} - T_1,$$

$$U_2 = n_1 n_2 + \frac{n_2(n_2 + 1)}{2} - T_2,$$

kde  $n_1$  a  $n_2$  jsou rozsahy vybraných souborů. Pokud je jedna z hodnot  $U_1$ ,  $U_2$  menší nebo rovna kritické hodnotě dle stanovené hladiny významnosti, je možné hypotézu o stejné distribuční funkci obou výběrů zamítnout. [35]

#### 4.3.2 Bonferroniho korekce

Bonferroniho korekce se použije v případě, kdy je potřebné porovnat tři a více skupin a dostat signifikantní rozdíl celého testu (jakého). B. korekce poukáže na dvojice, kde se nachází statisticky signifikantní rozdíl.

Za signifikantní je považován výsledek, kdy

$$p < \frac{\alpha}{\text{počet skupin}}$$

kde  $p$  je vypočítaná p-hodnota a

$\alpha$  je zvolená hladina významnosti. [36]

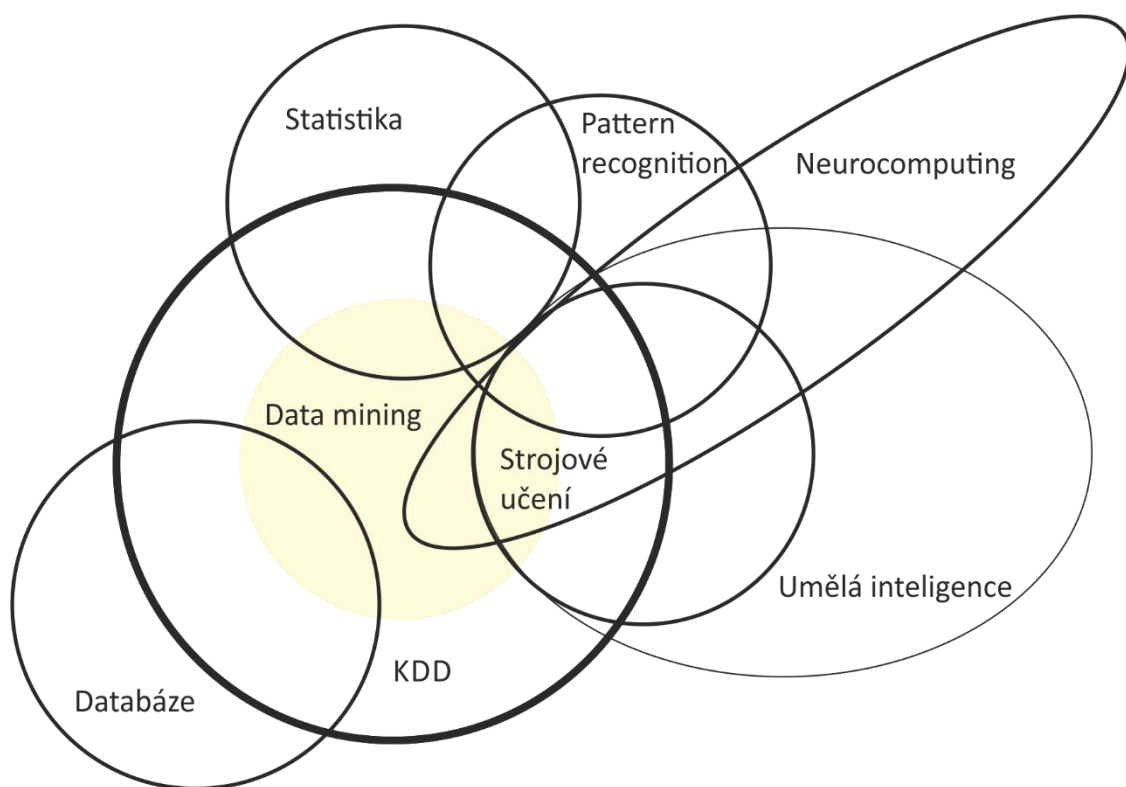
#### 4.4 Machine Learning

Tato část práce představuje základní nastínění problematiky machine learning neboli strojového učení, otázku vstupujících dat a jakým způsobem je ošetřit, jaké existují způsoby měření vzdáleností mezi jednotlivými daty, jak zvolit správnou vzdálenost k vytvoření skupin a podskupin s podobnými vlastnostmi.

Machine learning je vědní obor spadající pod obor matematické informatiky, nebo jinak nazývané počítačové vědy. Protože se jedná o učení stroje, je důležité nalézt takový zdroj dat a odpovídající metodu zpracování, na jehož základě stroj získá schopnost “učení se” aniž by musel být důkladně a do nejmenšího detailu naprogramován. V mnoha případech totiž nelze napsat program tak, aby podchytil vše. Techniky oplývající touto schopností “naučit se” jsou statistické techniky a postupy zpracování dat. [23]

Podle [24] je machine learning o dodání správných vlastností k vybudování správného modelu dosahující správných úkolů. Vlastnosti popisují objekty příslušné domény. Je nesmírně důležité popsat doménu správně, neboť nesprávně popsaná doména by později způsobila chyby ve zpracování. Úkol představuje abstraktní reprezentaci problému, který je potřeba vyřešit. Modelů zpracování dat je mnoho, ale jsou určeny ke zpracování malého počtu úkolů a ještě méně vlastností. Proto je velmi důležité najít takový model, který by data zpracoval odpovídajícím způsobem.

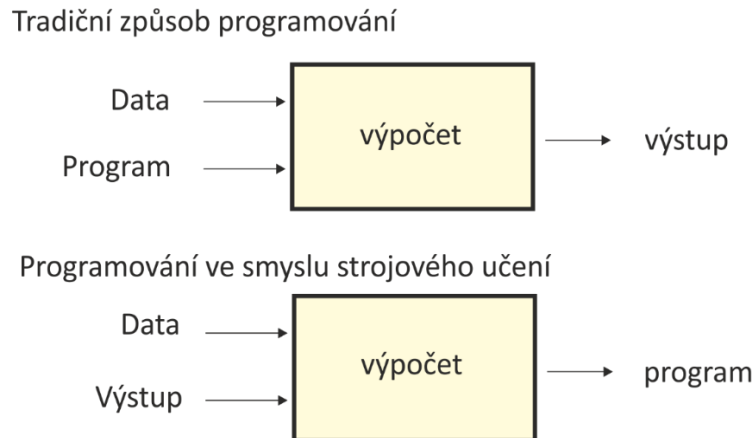
Z pojmů jako pattern recognition, volně přeloženo jako rozpoznávání vzorců, a computational learning theory, tedy teorie učení založeného na výpočtu, které patří pod vědní obor artificial intelligence, v českém jazyce uváděn jako umělá inteligence, se obor zabývající strojovým učením postupně a logicky vyvinul od pouhých teorií až s nástupem technologií. Se vznikem a rozvojem dalších vědních disciplín je machine learning, dle obrázku 4.2, propojujícím článkem spojující jak databáze skrze data mining, statistické metody s hledáním vzorců či umělou inteligenci s hledáním vztahů a zákonitostí. [23]



Obrázek 4.2 Propojení machine learning s dalšími vědními obory. [b]

Co tedy přesně je machine learning? Podle [24] je machine learning systematické hledání algoritmů a vzorců, které zlepšují znalosti nebo výkon s narůstající zkušeností.

Tradiční způsob programování spočívá v tom, že jsou nějakému médiu, uživatelskému prostředí, dodána data a program zpracování. Výsledkem takového počínání je určitý výstup. Kdežto myšlenkou machine learning je vytvoření programu, na základě dodaných a výsledných dat. [23] Základní schéma je zobrazeno na obrázku 4.3.



Obrázek 4.3. Rozdíl mezi tradičním způsobem programování a strojovým učením [c]

Je potřeba se zamyslet nad vlastnostmi dat a úkolem, který je od stroje vyžadován, podle toho je vybrán algoritmus zpracování. Poté jsou do algoritmu dodána data, výcviková data, na jejichž základě dojde ke krystalizaci správného algoritmu. Poté je algoritmu dodána další sada dat, na nichž se prokáže, zda byl algoritmus, popřípadě zvolené (a evaluované) parametry dat, zvoleny správně.

#### 4.4.1 Získávání nových znalostí - proces učení se

Stroje byly vytvořeny k provádění určitých úkolů, které provádějí mnohem rychleji a přesněji v porovnání s lidmi. Ale základním rozdílem mezi člověkem a strojem je inteligence. Neboť ta vzniká až interpretací předchozích již roztríděných a porovnaných zkušeností, které člověk zpracováním získal vjemy z pěti smyslů. Stroji tyto vstupní data chybí, proto je potřeba mu je dodat.

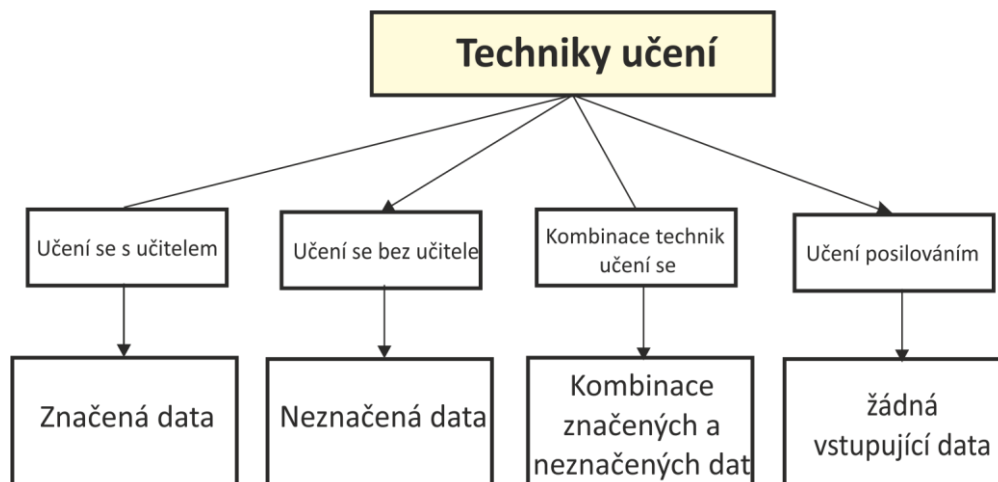
K čemu takový algoritmus vytvořit? K čemu je to dobré? Největší využití je pro zpracování velkého množství dat. A to takových dat, které člověk sám již zpracovat nezvládá ať už svým množstvím, přítomností či absencí expertní znalosti (apriorní data), požadavkem na schopnost predikce, nárokem na čas zpracování, tedy, zdali je potřebné zpracovat data okamžitě, či po skončení měření, anebo v případě, že měření nekončí, situace se každou chvílí mění a

jednoduše není v možnostech člověka algoritmus neustále přepisovat vzhledem k aktuální situaci.

Správně zvolený algoritmus dodává stroji schopnost zpracovat vstupující data takovým způsobem, že z nich získá informace, aniž by se důsledně musel držet rigidně popsaného modelu. Algoritmus tak významně zvyšuje svou vlastní výkonnost s narůstajícím množstvím vstupů.

Existují dva základní přístupy k machine learning, a to učení s učitelem (*supervised learning*) a učení bez učitele (*unsupervised learning*), další *semisupervised learning* je kombinací již zmíněných dvou přístupů a čtvrtý přístup, *reinforcement learning*, tzv. zpětnovazební učení.

[23]



Obrázek 4.4 Techniky strojového učení [d]

Z obrázku 4.4 lze vyčíst požadavky na data zmíněných technik učení stroje. [23]

### *Supervised learning*

Techniky učení se s učitelem fungují, pokud jsou trénovací data označená, respektive vstupní část trénovacích dat je neoznačená a naopak výstupní data jsou určitým způsobem označená. Z toho vyplývá, že výstupní část trénovacích dat určují, jakým způsobem vstupní data zpracovat, tedy co musí algoritmus provést, aby zpracováním vstupních dat byla výstupní data.

Technika učení s učitelem je pojmenována na základě logiky přidělování značek - jen učitel (ať už se jedná o lidskou bytost či stroj) mohl datům značku přidělit. [23]

Z obrázku 4.4 je vidět, že konkrétními technikami pro učení s učitelem jsou klasifikace a regrese. [23]

### *Unsupervised Learning*

Metoda učení bez učitele je postavena na absenci učitele, tzn., že k dispozici jsou pouze neoznačená data. Základem techniky je proto hledání skrytých vazeb mezi jednotlivými daty, a to na základě specifického znaku datového souboru. Princip je možné připodobnit cestě bez nutnosti jít určitým směrem. Při technice učení se bez učitele není jasné, jak zpracování dat dopadne, protože vstupní data nelze porovnat s výstupními daty. Základní technikou zpracování dat v případě učení bez učitele je *clustering*, neboli shlukování. [23]

### *Semisupervised Learning*

Tato kombinace dvou předcházejících technik v sobě snoubí označená i neoznačená data. Protože označení dat je zdlouhavý a náročný proces, a tedy finančně nákladný, tak je označených dat málo, kdežto neoznačených dat bývá mnohonásobně více. Kombinace technik se využívá k nastavení počátečního základního modelu podle označených dat a k vylepšení stávajícího modelu neoznačených dat. [23, 24]

### *Reinforcement Learning*

Učení posilováním je založeno na pozorování a interakci s okolním prostředím, a to bez přítomnosti jakýchkoli dat. Hlavní myšlenka tkví v pozorování prostředí tak, aby se model v situaci orientoval tak, aby dopad případného rozhodnutí bylo buď minimální z hlediska rizika, nebo maximální z hlediska zisku. Výsledkem tedy je predikce. Tato práce se již nebude více věnovat posledním dvěma technikám, kombinace technik učení ani učení posilováním, protože jejich aplikace v této práci se nezvažuje. [23,24]

Principy strojového učení nás obklopují prakticky kamkoliv se podíváme, a to aniž bychom si to vůbec uvědomovali. Hojně a v různých podobách se skrývají na internetu, na letištích a

veřejných prostranstvích, v oblasti dopravy, v domech či našich kapsách. Machine learning technologie jsou kromě komerčních a bezpečnostních důvodů používány i v jiných oblastech.

Takovým příkladem budiž využití v medicíně. Strojového učení se využívá jako pomocného nástroje doktorům k detekci patologických změn na snímcích z rentgenů, magnetické rezonance, ultrazvuků (a podobných snímacích zařízeních). Tisíce označených snímků byly stroji dodány, aby rozlišil snímek zdravé tkáně od tkáně, na níž se objevují změny. Dnes je tímto způsobem možné diagnostikovat patologické změny na mozku, na srdci a mnoho druhů rakoviny.

V současnosti je velmi diskutované téma autonomních dopravních prostředků, obzvláště osobních aut. Počítačové vidění, kterým oplývají první roboti napodobující člověka, je dnes již na tak sofistikované úrovni, že se vývojáři jej nezděhají implementovat i do dopravních prostředků. Tento trend je vidět především u výrobců aut, neboť se ustavičně předhánějí, kdo přijde s lepším řešením.

Výše bylo zmíněno, že strojové učení je využíváno i pro bezpečnostní účely, takovým příkladem je zejména rozpoznávání tváří z fotografických a video záznamů. Zejména v letectví se tohoto začíná využívat na letištích jako jednoho z prostředků ochrany letectví před protiprávními činy.

A nakonec se principy machine learning objevují na internetu, od třídění e-mailů (zpráva/spam), přes sociální sítě, kde se také využívá rozpoznávání tváří, doporučeních na základě předchozího vyhledávání až po virtuální asistenty typu Siri.

Z výše uvedeného výčtu je patrné, že technologie machine learning jsou značně pokročilé a využívané v celém spektru oblastí, proto pokud existují možnosti, proč je nevyužít a nezačlenit do výcvikových programů. Koneckonců stroje existují právě proto, aby lidem ulehčili práci, a zároveň ji provedou objektivně, protože nejsou zatíženy emocemi, tak jako lidé.

#### 4.4.2 Používané metody machine learning

Tato práce krátce přibližuje následující techniky učení: shlukování a tři možnosti provedení shlukové analýzy, K-means, hierarchické shlukování a DBSCAN, dále SVM klasifikace, naivní Bayesův klasifikátor či techniku regresních stromů.

##### 4.4.2.1 Shluková analýza

V případě unsupervised machine learning je nejrozšířenějším způsobem zpracování dat, ve smyslu nalézání vzorců. Cílem shlukování je získat prvotní ideu o datech, a to roztríděním n objektů do k skupin podle podobných vlastností. Jak proces shlukování probíhá? Každý objekt je popsán p znaky (anglicky features) a na základě jejich podobnosti, která je dána vzdáleností jednotlivých znaků objektů, jsou tvořeny skupiny. Řekněme, že je k dispozici datová sada od  $x_1, x_2$  až po  $x_m$ , kterou je potřeba rozdělit do skupin. Rozdělení proběhne na základě vzdáleností mezi znaky<sup>2</sup> (features). Některé znaky si však mohou být vzdálenostně podobné, a přitom se ve skutečnosti lišit, což vytváří problém, když se oba znaky ocitnou v jednom shluku. Proto existuje několik způsobů měření vzdáleností. Výsledkem shlukování by měly být skupiny s daty uvnitř co nejpodobnější a přitom se navzájem maximálně odlišovat. [25]

##### 4.4.2.1.1 Používané vzdálenosti

Existuje několik metrik měření vzdáleností pro rozlišení podobnosti či rozdílnosti objektů. Základem je Minkowského metrika měření vzdáleností a její mutace Euklidovská, Manhattanská a Čebyševova vzdálenost. Nejčastěji používaným způsobem měření vzdáleností je právě Euklidovská vzdálenost. Jedná se o přímou vzdálenost mezi dvěma body. Vzdálenost je určena jako druhá odmocnina sumy čtvercových vzdáleností mezi souřadnicemi objektů. Používá se pro měření vzdálenosti kvantitativních proměnných. Další používanou metodou měření vzdálenosti je Manhattanská vzdálenost pojmenovaná podle pravouhlého systému newyorských ulic. V tomto případě je vzdálenost vyjádřena sumou horizontálních a

---

<sup>2</sup> Znaky jsou charakteristické vlastnosti datové sady, podle kterých algoritmus porovnává vzájemnou vzdálenost. Nejedná se o označená data jak je tomu v případě supervised learning.



vertikálních cest z bodu A do bodu B, tedy neexistuje přímá vzdálenost. Dále pak existují méně používané Canberrova vzdálenost či Bray-Curtisova vzdálenost. [26]

Způsoby určování Euklidovské vzdálenosti jsou tři, a to:

- single-linkage v českém jazyce označováno jako metoda nejbližšího souseda. To znamená, že nejkratší vzdálenost se počítá od nejbližšího bodu jednoho shluku k nejbližšímu bodu dalšího shluku. Tedy nejkratší vzdálenost mezi dvěma shluky,
- complete-linkage označováno jako metoda nejvzdálenějšího souseda napovídá, že vzdálenost, se kterou se zde počítá, je maximální, tedy mezi dvěma nejvzdálenějšími body dvou shluků a třetí způsob
- average-linkage, tedy metoda průměrné vazby. Jedná se o vzdálenost mezi dvěma shluky, která představuje průměr všech vzdáleností mezi jejich členy. [25]

Ke shlukové analýze lze přistupovat několika způsoby, jak je patrné z obrázku (strom technik pro machine learning z matlab webu). V této práci budou dále vysvětleny metody hierarchického shlukování a K-means.

#### 4.4.2.1.2 Hierarchické shlukování

Jedná se o postupné klastrování objektů využívané v případě, že nevíme, kolik skupin chceme vytvořit. Princip spočívá ve shlukování nejprve nejbližších objektů a v každém dalším kroku vzdálenějších objektů. Postup uvedeného aglomerativního<sup>3</sup> hierarchického principu lze uvést na následujících bodech:

1. na začátku je každý objekt považován za samostatný shluk.
2. v dalším kroku najdeme dva shluky, jejichž vzdálenost je nejkratší.
3. poté tyto dva shluky jsou spojeny v nový shluk. Po vzniku nové skupiny opět je potřebné přepočítat vzdálenost skupin od dalších objektů.


---

<sup>3</sup> Aglomerativní postup je takový, kdy postup směřuje od spodu směrem nahoru, tzv. *bottom-up*.

Protože se jedná o deterministický algoritmus, což znamená, že za stejných vstupních podmínek vytvoří stejné výsledky, velmi záleží na výběru měření vzdálenosti. Hierarchický algoritmus je tzv. greedy algorithm neboli hladový algoritmus, což je označení pro algoritmus, který v každém bodě hledá lokální optimum, které může a nemusí představovat i optimum v globálním měřítku. Aby se tomuto problému předešlo, zvolí se v každém kroku způsob určení vzdálenosti. Tím bude zachována flexibilita algoritmu a zamezí se tím nepravdivým výsledkům. V případě použití Euklidovské vzdálenosti, tedy přímé vzdálenosti, je důležité určit, jak bude tato vzdálenost určována (single-linkage, complete-linkage, average-linkage).

Bylo již zmíněno, že hierarchické klustrování se hodí v případě, že nevíme, kolik shluků je potřeba. Výhodou tohoto způsobu shlukování je samotný postup, na kterém je průběžně vidět kolik shluků již bylo vytvořeno a tedy proces shlukování kdykoliv zastavit v případě, že počet shluků se zdá být dostatečný. Nevýhodou tohoto postupu je, že se jedná o pomalý způsob určování skupin. Postup hierarchického shlukování je vhodné aplikovat na menší počet dat. Zároveň, díky možnosti výběru způsobu určování vzdálenosti, se jedná o flexibilní algoritmus.

Výsledky aglomerativního hierarchického postupu se nejčastěji znázorňují pomocí dendrogramů, protože se podobají stromům. Dendrogram se skládá z kořene představující celou datovou sadu, větví a uzlů, kde probíhá měření vzdáleností v již vzniklém shluku, který je potřeba ještě zúžit, a listů reprezentující konečné shluky. [24,27]



Obrázek 4.5 Ukázka dendrogramu

#### 4.4.2.1.3 K-means

Nejběžnější nehierarchický algoritmus používaný pro potřeby klastrování je k-means (v českém jazyce nemá překlad). Jedná se o způsob shlukování v případě, že je znám k počet shluků. Princip je následující:

1. Vytvoření tzv. centroidů. Jedná se o náhodně zvolené body, které v prvním kroku kopírují objekty určené ke klastrování. Počet centroidů odpovídá počtu zvolených shluků. Objekty se zařazují do toho shluku, jehož centroidu jsou nejbližší.
2. Ve druhém kroku dojde k přemístění centroidů tak, aby se nacházely uprostřed vybraných bodů.
3. Kvůli přemístění centroidů dojde (nemusí) i ke změně vzdálenosti objektů k nejbližšímu centroidu. To znamená, že po přemístění centroidů, dojde k přepočítání vzdáleností objektů vzhledem k centroidům a v případě, že se objekt nalézá blíže jinému centroidu než byl původně, tak se stane součástí jiného shluku.
4. Následně se proces přemístění těžiště a změny shluku opakuje do té doby, dokud centroidy nenaleznou optimální polohu, kdy už se další pohyb centroidů ani objektů mezi shluky nekoná.

Tento způsob opakování stejného procesu se nazývá iterace. Tedy aplikování stejného principu na měnící se situaci. [23,24]

#### 4.4.2.1.4 DBSCAN

Density-based Algorithm for Discovering Clusters in Large Spatial Databases with Noise (DBSCAN), je další z rodiny shlukovacích algoritmů. Anglický název algoritmu prozrazuje, že se jedná o algoritmus, který vytváří shluky na základě hustoty rozložení objektů v prostředí, kde se nachází i šum. Přednostmi tohoto algoritmu jsou, že nachází shluky nepravidelných tvarů a především eliminuje šum. Což je jiný přístup v porovnání s předcházejícími uvedenými přístupy, které shlukovaly objekty podle stejné vzdálenosti od určitého bodu. DBSCAN funguje s jakoukoliv použitou metrikou měření vzdálenosti a v mnohorozměrném prostoru. Shlukovací algoritmy jsou využívány k identifikaci tříd. Nicméně, aplikace shlukovacích algoritmů na obsáhlé databáze zvyšuje následující nároky:

1. k dispozici je málo informací ohledně analyzované domény k určení vstupních parametrů,
2. nalézání shluků s nepravidelným tvarem, např. lineární, protáhlý atp.,
3. značné efektivity na tyto velkorozměrné databáze.

Většina ostatních shlukovacích algoritmů pokrývá jeden, či dva body uvedených nároků, ale žádný, až na DBSCAN, nekombinuje všechny tři dohromady.

Hlavní idea DBSCAN spočívá v tom, že kolem každého bodu shluku je oblast daná poloměrem, ve které se musí nacházet určitý minimální počet objektů, tzn., že hustota objektů v sousedství musí překročit určitý práh. Touto podmínkou je eliminován šum. Tvar sousedství, shluku, je ovlivněn použitou metrikou měření vzdálenosti – v případě použití Manhattanské vzdálenosti ve dvourozměrném prostoru bude mít shluk tvar obdélníku. [32]

#### 4.4.2.2 Regresní stromy

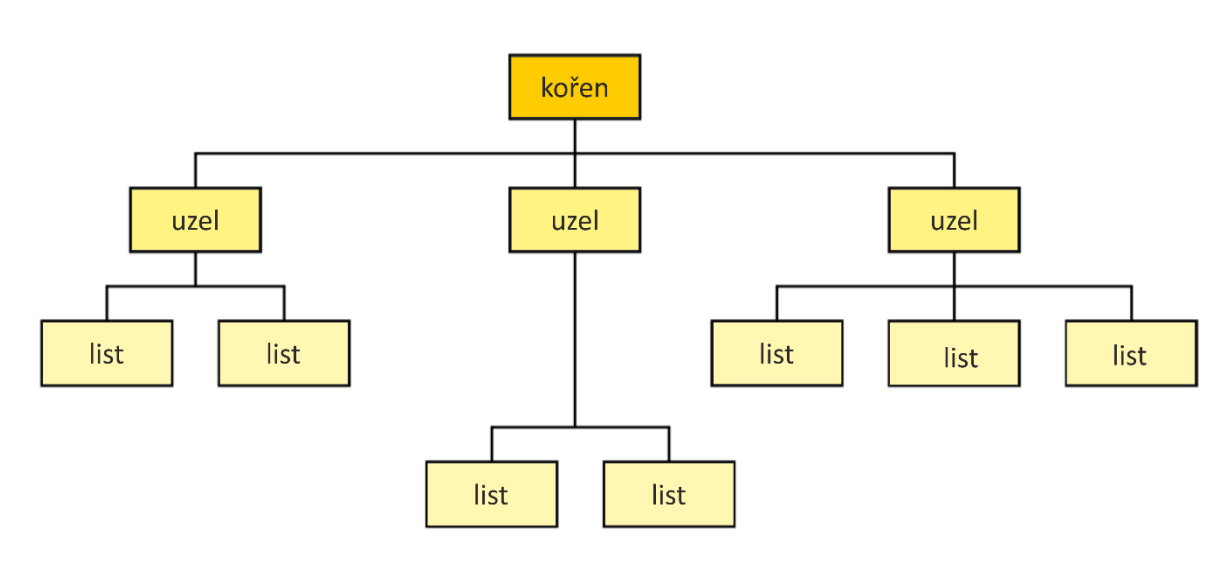
Regression trees patří mezi regresní metody učení s učitelem. Základní komponentou regresních stromů je regrese neboli regresní analýza. Jedná se o statistickou metodu, která se zabývá predikcí. Na základě spojitých nezávislých proměnných (také označovaných jako predictors) lze odhadovat chování na nich závislých proměnných. Výsledkem regresního stromu je reálné číslo, např. cena domu (podle města, podle čtvrti, podle ulice.. či počet dní strávených na pooperačním oddělení).

Protože se jedná o stromy, tak se skládá, stejně tak jako dendrogram, z kořenů, větví a listů. Přejechy mezi kořeny, větvemi a listy se nazývají uzly.

Uzly jsou místa, kde se algoritmus rozhoduje, jakou větev bude následovat. Existují neterminální a terminální uzly. Představitelem neterminálních uzlů jsou větve, to znamená, že po rozhodnutí existuje cesta, kam dále pokračovat. Z toho vyplývá, že listy jsou terminální uzly. Co si pod tím představit? V případě regresních stromů větve reprezentují výsledek testování v předešlém uzlu a jednotlivé listy představují hodnotu target value, tedy cílové hodnoty odpovídající vstupní kořenové nezávislé proměnné.

Stromy se dále dělí na binární a nebinární stromy. Z pojmenování vyplývá, že v případě binárních stromů z jednoho uzlu vyrůstají právě dvě větve, kdežto nebinárním stromům z uzlů vyrůstá 3 a více větví.

Příkladem takového algoritmického stromu je následující obrázek 4.6.



Obrázek 4.6 Stavba algoritmického stromu

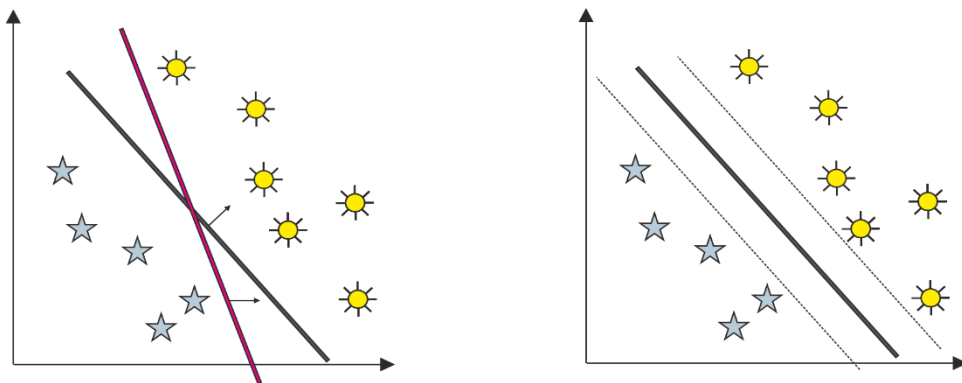
Uzly reprezentují zastavovací kritéria. Kritickým problémem zastavovacích kritérií je jejich nastavení - rozhodují totiž o velikosti stromu. Cílem je však optimální velikost. Pokud by byla kritéria příliš přísná, tak bude strom malý, a tudíž nebude moci věrně zobrazit vztahy mezi závislými a nezávislými proměnnými. Na druhou stranu lze kritéria nastavit velmi mírně, to však bude mít za následek příliš velký strom, tzv. bude přeučení - overfitted. V takovém případě se používá metoda tzv. pruning, opět doslova použito zahradnického pojmu - prořezávání, čímž se postupně odřezávají jednotlivé větve stromu. V případě regresních stromů se odstraňuje taková funkce, která po odstranění způsobí nejmenší nárůst nepřesností stromu. Takovou pilou pro prořezávání stromů v hájích informatické matematiky je tzv. prořezávací algoritmus.

Těchto stromů se využívá v případě potřeby klasifikovat dosud neznámé případy, kdy cílem je popsat vztahy mezi těmito neznámými případy, a předvídat budoucí vývoj. [24, 28]

#### 4.4.2.3 SVM klasifikace

SVM classification neboli Support Vector Machines je opět jedna z metod učení se s učitelem. Jedná se o způsob modelování a analýzy dat, které jsou určeny ke klasifikaci či regresní analýze. SVM klasifikace vytváří hyperplanes, nadroviny, jednu či více, ve více či nekonečně rozměrném prostoru. Nadroviny jsou vektory roztínající tento prostor. Hlavní charakteristikou těchto nadrovin je, že rozdělují prostor právě ke klasifikaci či regresi dat. Platí, že čím dále se nadrovina nachází od nejbližší třídy, tedy trénovacích dat nacházejících se nejbližší k nadrovině, tím lepší separaci vytváří.

Na uvedeném obrázku 4.7 jsou dvě ukázky grafů. Oba grafy představují důležitost umístění nadroviny. Na levém grafu je ideální nadrovina zobrazovaná černou barvou. Přímka má přibližně stejně daleko k nejbližší třídě kruhů i hvězd. Další možností konstrukce nadroviny je červená přímka. V tomto případě má přímka sice daleko od nejbližšího kruhu, ale relativně velmi blízko se nachází vzhledem k nejbližší hvězdě. Důležité je nadrovině najít takovou polohu, aby vzdálenost byla optimální pro všechny shluky.



Obrázek 4.7 SVM klasifikace

Proč je vzdálenost tak důležitým parametrem? Řekněme, že kdyby se objevil další bod určitých charakteristik, tak se tento bod bude přibližovat k bodům s podobnými charakteristikami, a tudíž čím vzdálenější nadrovina je, tím spíše se nově vzniklý bod nachází ve stejné třídě bodů s podobnými charakteristikami.

Pravý obrázek vyjadřuje pásmo kolem nadroviny. Toto pásmo mezi přerušovanými čarami kromě důležitosti vzdálenosti nejbližších bodů vyjadřuje i necitlivost přerušované čáry k hraničním bodům, neboť tento pruh by měl být bez bodů, prázdný, a ideálně co nejširší. Toto

pásmo se v angličtině nazývá maximum-margin. Problém nastane, pokud se nový bod/vektor ocitne v pásmu. V takovém případě algoritmus neví, do jaké skupiny bod patří (od toho se nazývá necitlivé pásmo), a tudíž je nutné jej porovnat s vektorem, o kterém je známo, že patří do určité skupiny, zde například do třídy hvězd. Myšlenkou, která stojí za rozhodnutím, zda objekt patří do skupiny hvězd či kruhů, je navzájem oba vektory pronásobit a porovnat výsledek, zdali je větší nebo rovno zvolené konstantě.

Tento algoritmus patří mezi jeden z nejběžněji používaných machine learning algoritmů ke klasifikaci a regresní analýzy, a to i díky možnosti aplikace na data uložená ve vícerozměrném prostoru. [25]

#### 4.4.2.4 Naive Bayes

Další metoda klasifikace dat algoritmem strojového učení s učitelem je naivní Bayesův algoritmus. Tato metoda je postavena na bayesovské statistice, která oproti klasickému pojetí statistiky přistupuje k analýze dat jiným způsobem. Umožňuje kompletnější záznam o všech zdrojích nejistoty. K analyzovaným datům bayesovská statistika přistupuje mnohem subjektivněji. [29] Klasická statistika se při odhadech parametrů a testech hypotéz, na rozdíl od bayesovského přístupu, neopírá o pravděpodobnosti vycházející z daného konkrétního výběru, ale o množinu všech možných výběrů z dané populace. [30]

Důvod, proč se bayesovská statistika opírá o pravděpodobnost vycházející z konkrétního výběru je tzv. apriorní znalost neboli prvotní či původní informace, která se každým dalším datovým vstupem (tzv. aposteriorní znalost) proměňuje. Toto je v podstatě krátké vysvětlení Bayesova vzorce:

$$f = (B|A, C) = \frac{f(A|B, C)(B|C)}{f(A|C)}$$

Hlavní význam Bayesova vzorce spočívá v tom, že přepočítává apriorní hp  $f(B|C)$  z čitatele na pravé straně vzorce na aposteriorní hp  $f(B|A, C)$  na levé straně. Apriorní hp popisuje náhodnou veličinu B jen v závislosti na náhodné veličině C, zatímco aposteriorní hp využívá

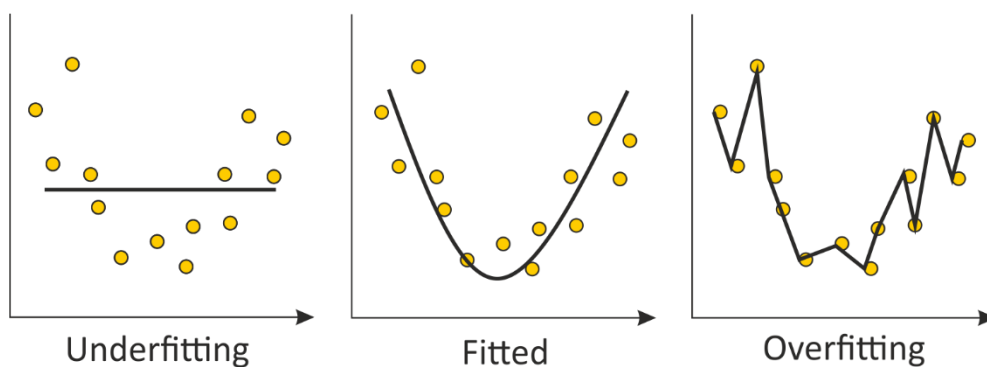
informaci také z náhodné veličiny A, a to prostřednictvím  $f(A|B, C)$ .  $f(A|C)$  označuje pravděpodobnost jevu A v závislosti na výskytu náhodné veličiny C. [31]

#### 4.4.2.5 Rizika a omezení metod machine learning: overfitting a underfitting

Při navrhování systému a vybírání vhodného učenlivého algoritmu bývá jednou z nejčastějších chyb problém generalizace, tzv. overfitting či underfitting. Snahou každého tvůrce softvéru je co nejdůkladnější zachycení reality. Při vytváření modelu se tvůrce může příliš zaměřit na vytváření algoritmu, který by na míru seděl již vybraným datům. Leč tímto si tvůrce vytváří past pro sadu nových dat mající jiné charakteristiky. Model tvořen na míru trénovacím datům je tzv. overfitted.

Chybou je i přílišná snaha vyhnout se problému overfitting. Tzn., když se tvůrce při snaze rozšířit aplikovatelnost algoritmu snaží o co největší generalizaci. Tímto si opět vytváří past jménem underfitting.

Názornou ukázkou modelů s vlastnosti overfitted a underfitted v porovnání s optimálně navrženým algoritmem slouží následující obrázek ().



Obrázek 4.8 Problém generalizace [f]

V grafech jsou body rozmístěné do tvaru pomyslného u. Tento tvar je kopírován v prostředním grafu a vyjadřuje optimální mez přesnosti.

Graf na levé straně je názorným případem underfitted modelu. V tomto případě je model navržen velmi obecně a nekopíruje realitu dat.



A nakonec, pravý graf představuje model, kde se tvůrce dopustil přílišného zaměření na trénovací data. Tento model je overfitted.

V praxi tzn., že jsou k dispozici určitá výcviková data, která jsou zpracována modelem. Snem každého tvůrce je co nejvěrnější zobrazení reality, tedy 100% přesnost. V případě overfitted modelu, 100% přesnosti bude dosaženo na trénovacích datech, ale na nových datech tato přesnost může rapidně klesnout. Pokud se tvůrce chce vyhnout tomuto problému, tak nastaví citlivost modelu nízko ve snaze postihnout co nejvíce dat. Problém je, že tímto způsobem přesnost také nezvýší. Řešením je najít takovou hranici citlivosti i s vědomím, že část přesnosti bude obětována na úkor/ ve jménu větší obecnosti/aplikovatelnosti modelu. [23,24]

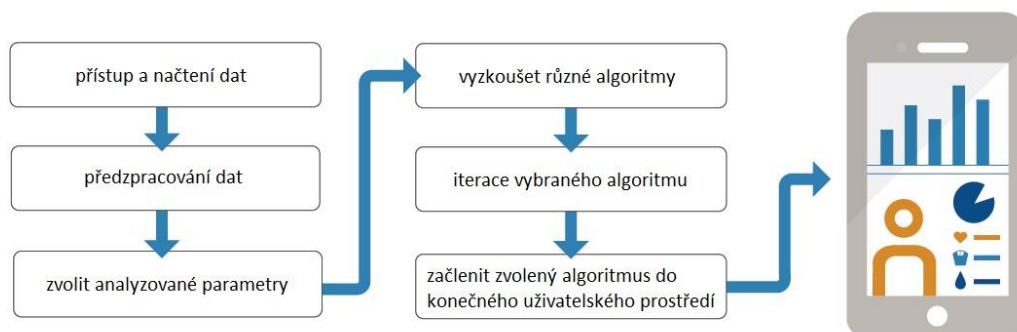
#### 4.4.3 Stavba softvéru

Při vytváření modelu je potřeba brát v úvahu všechny jeho složky. Takový systém je tvořen vstupem, externím vstupem, výstupem, a protože se jedná o stochastický model, tak i šumem.

Systém reprezentuje vybraný algoritmus zpracování dat. Všechny procesy, které se kromě samotného algoritmu machine learning podílejí na zpracování, jsou popsány dále. Vstup představuje data vstupující do systému. Jedná se o veličinu, kterou lze nastavit a která má vliv na výstup. Další vstupující veličina je externí vstup, což je veličina, kterou je možno měřit, ale kterou nelze měnit a má vliv na výstupní hodnoty. Nelze opomenout šum, neboť reprezentuje neurčitost systému, kterou nelze měřit a už vůbec ne předpovídat. A nakonec po zpracování dat ze systému vychází výstup, který představuje systémem modelovanou veličinu, jež v okamžiku měření neznáme. Výstup je realizován na základě všech vstupujících složek. [31]

##### 4.4.3.1 Systém

Systém představuje komplexní soubor úkolů, které určitým způsobem zpracovávají vstupující elementy tak, aby bylo dosaženo výstupů optimálním způsobem. Názorným příkladem všech jednotlivých komponent systému na fungování systému jako celku je názorně ukázáno na obrázku (blabla, upraveno z [d]).



Obrázek 4.9 Stavba softvérového řešení [g]

Každý bod postupu práce je pro lepší přehlednost nejdříve krátce vysvětlen a poté je jednotlivě rozvinut.

#### 1. Přístup a načtení dat

Při navrhování systému je dopředu potřeba promyslet jaká data do systému budou vstupovat. Důležitou roli hraje informace, zdali bude datový zdroj napojen na systém či budou data dodávána zvlášť.

#### 2. Předzpracování dat

Datový soubor získán z databází většinou není ve stavu přímého zpracování. Cílem předzpracování je sjednotit data do jednotného formátu zápisu, popřípadě je normalizovat či standardizovat, aby došlo k vyloučení extrémních hodnot z datového souboru.

#### 3. Zvolit analyzované parametry

Správné fungování modelu a míra přesnosti odpovídající skutečnosti z velké míry záleží na zvolených parametrech. Rizikem je jak zvolení nízkého počtu hodnocených parametrů, které by realitu nevyobrazily přesně, tak i příliš mnoho parametrů, které by na testovacích datech nemusely fungovat. Toto je jedno z dilemat optimalizace více přiblížené v kapitole () Rizika a omezení: overfitting a underfitting.

#### 4. Vyzkoušet různé algoritmy

V této části konstrukce systému je nutno zvážit jaká data jsou k dispozici a co je kýženým výsledkem. Po důkladné analýze potenciálně vhodných metod, následuje jejich testování.

#### 5. Iterace vybraného algoritmu

Cílem je přesvědčit se, že byla vybrána správná metoda zpracování dat. Opakování je důležitým prvkem procesu, neboť je potřeba akurátně nastavit citlivost algoritmu, aby opět nedošlo k problému generalizace.

#### 6. Začlenit zvolený algoritmus do uživatelského prostředí.

Posledním krokem návrhu systému je zvážit potřeby koncového uživatele. Implementace může být provedena v různých programovacích jazycích a na různých platformách.

#### 4.4.3.1.1 Přístup a načtení dat

Data vstupující do systému se rozdělují na kvantitativní a kvalitativní

Kvantitativní data v této práci představují výstupy z letových zapisovačů. Data zpracována v této práci pocházejí z letových zapisovačů značky Garmin G1000 ze simulátoru TRD40 a letadla Cirrus.


Zdrojem kvalitativních dat jsou v této práci checklisty, poznámky a závěrečná hodnocení instruktorů. Cílem je spojit výstup kvantitativních a kvalitativních dat tak, aby vzniklo celkové hodnocení, které se opírá oba uvedené datové zdroje.

Pro účely této práce byly k dispozici dva datové soubory. Jeden soubor byl měřen na simulátorech a měl striktně daný průběh letu. Druhý datový soubor pochází z letového zapisovače reálného letadla, který byl získán v průběhu výcviku.

Testované subjekty splňují podmínky zdravotní způsobilosti pro letovou posádku danými předpisem JAR-FCL 3.105. Průměrný věk subjektů je  $23 \pm 4$  let. Měření proběhlo na simulátoru TRD40 za účasti instruktora. Simulovaný let měl předem daný scénář, skládající se ze vzletu,

sady manévrů opakující se třikrát a přistání. Sada manévrů se skládá z horizontálního přímočarého letu (HPL), 360° horizontální zatáčky s náklonem 30°, 180° stoupavé zatáčky s náklonem 15° a 180° zatáčky s 15° náklonem. Výběr manévrů byl proveden z hlediska komplexnosti pilotáže, kterou subjekty musely prokázat.

Měření probíhalo následovně: Subjekty absolvovaly 11 hodin na тренаžeru. V rámci těchto 11 hodin druhá a poslední hodina byla měřená. Vzápětí následoval první výcvik v letadle, při kterém proběhlo měření také. Poté následovaly tři hodiny výcviku na simulátoru a dvě hodiny v letadle, přičemž druhá z těchto dvou hodin byla měřena. Na konec proběhla další dvě měření, jedno na тренаžeru a poslední v letadle, kde součástí výcviku byla změna zobrazovaných údajů z analogového zobrazení na skleněný kokpit, viz obr. 4.8.



Obrázek 4.10 Harmonogram výcviku [h]

Subjekty splňují podmínky zdravotní způsobilosti pro letovou posádku danými předpisem JAR-FCL 3.105. Reálné lety neměly předem daný scénář manévrů, pouze bylo zadáno, že subjekty musí provést standardní vzlet v kurzu shodném s osou dráhy do výšky minimálně 500ft. Stejně výškové omezení bylo zadáno i u přistání, tzn., že od výšky 500ft nad zemí až do přistání, musel pilot držet kurz shodný s osou dráhy.


Načtení a zpracování dat probíhá na matematicko-programovací platformě Matlab.

#### 4.4.3.1.2 Aplikace zvolených postupů

Pro hodnocení přesnosti pilotáže byly vybrány následující parametry: náklon, barometrická výška, vertikální rychlost, *heading* a magnetický kurz. Tyto parametry byly zvoleny s ohledem na fakt, že dostatečně popisují spektrum prováděných manévrů.

Pro účely automatické detekce manévrů v průběhu letu byl vytvořen skript v programovém prostředí Matlab, který je dále popsán. Pro identifikaci jednotlivých manévrů byla nejprve využita metoda strojového učení a dolování dat, konkrétně shluková analýza. S ohledem na charakter dat byla zvolena shluková analýza na základě hustoty pro aplikace s šumem - Density-based spatial clustering of applications with noise (DBSCAN), která se ukázala být vhodná pro dané účely, a to právě s ohledem na jeho schopnost detekce šumu. Ostatní metody strojového učení, uvedené v předchozí části práce, nebyly schopné věrohodně identifikovat manévry, protože šum vyskytující se v datech byl vždy přiřazen k nějakému shluku (clusteru).

V prvním kroku bylo potřeba zvolit vhodná data, na něž byla DBSCAN aplikována. Jako vhodné parametry z hlediska detekce manévrů byl zvolen náklon a vertikální rychlost. Kombinace těchto dvou parametrů dostatečně slouží pro základní rozdělení manévrů letadla, které byly dále precizně rozděleny na základě dalších zvolených parametrů (viz popis dále). Pro účely analýzy byla data nejprve standardizována s využitím z-score. Následně byla uvedená data rozdělena na jednotlivé shluky a šum, viz zdrojový kód 1 a obr. 4.11. Jako shluk, byla označena skupina bodů obsahující minimálně 30 vzorků dat. Uvedená hodnota minimální velikosti shluku byla zvolena s ohledem na vzorkovací frekvenci zapisovače letových údajů.



Obrázek 4.11 Ukázka detekce šumu (černá) a jednotlivých shluků na základě náklonu a vertikální rychlosti

```

function [IDX, isnoise]=DBSCAN(X,epsilon,MinPts)
    C=0;
    n=size(X,1);
    IDX=zeros(n,1);

    D=pdist2(X,X);
    visited=false(n,1);
    isnoise=false(n,1);

    for i=1:n
        if ~visited(i)
            visited(i)=true;

            Neighbors=RegionQuery(i);
            if numel(Neighbors)<MinPts
                isnoise(i)=true;
            else
                C=C+1;
                ExpandCluster(i,Neighbors,C);
            end
        end
    end

function ExpandCluster(i,Neighbors,C)
    IDX(i)=C;
    k = 1;
    while true
        j = Neighbors(k);

        if ~visited(j)
            visited(j)=true;
            Neighbors2=RegionQuery(j);
            if numel(Neighbors2)>=MinPts
                Neighbors=[Neighbors Neighbors2];
            end
        end
        if IDX(j)==0
            IDX(j)=C;
        end

        k = k + 1;
        if k > numel(Neighbors)
            break;
        end
    end

function Neighbors=RegionQuery(i)
    Neighbors=find(D(i,:) <= epsilon);
end
end

```

Zdrojový kód 1: Algoritmus pro shlukovou analýzu DBSCAN, programovací jazyk Matlab.

S pomocí DBSCAN byly identifikovány shluky, které vykazují obdobné chování z hlediska dvou zvolených parametrů, ale bez ohledu na časový průběh letu. V praxi to tedy znamená, že byli v průběhu provedeno několik shodných manévrů, budou detekovány jako jeden shluk. Z tohoto důvodu proběhla druhá klasifikace, opět pomocí DBSCAN, viz zdrojový kód 2, a to z důvodu odstranění zbytkového šumu a rozdělení detekovaných shluků na jednotlivé manévry, viz obr. 4.12. Z tohoto důvodu byla vstupními daty pro DBSCAN data obsahující informaci o shluku z prvního kroku shlukové analýzy a dále informace o časovém rozložení jednotlivých dat zahrnutých ve shluku. Tímto způsobem byla data definitivně rozdělena na jednotlivé manévry.

```
IDXsep=NaN(length(IDX2),length(IDX2));

count=1;

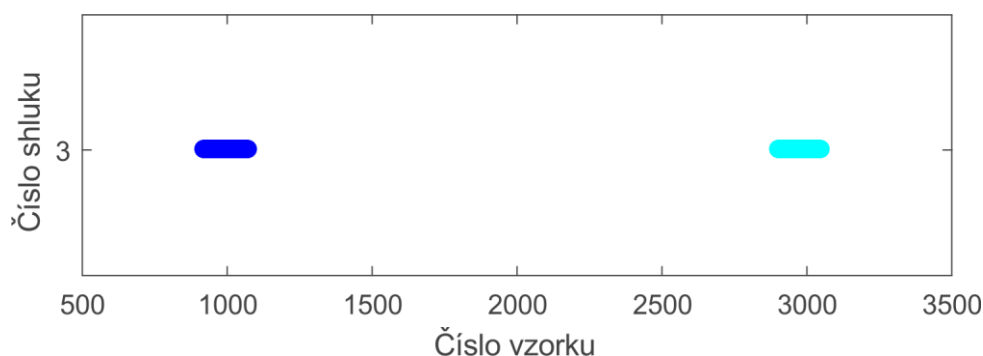
for i = 1: length(C)
    IDX=[];
    IDX3=[IDX2(IDX2==i),I(IDX2==i)];
    [IDXxx, isnoise]=DBSCAN(IDX3,20,20);

    map=jet(max(IDXxx));

    for jj=1:max(IDXxx)
        line=[];

        line=linspace(min(IDX3(IDXxx==jj,2)),max(IDX3(IDXxx==jj,2)), ...
            max(IDX3(IDXxx==jj,2))-min(IDX3(IDXxx==jj,2))+1);
```

Zdrojový kód 2: Separace jednotlivých manévrů pomocí DBSCAN na základě předchozího rozdělení na jednotlivé shluky s ohledem na náklon a vertikální rychlost, programovací jazyk Matlab.



Obrázek 4.12 Ukázka rozdělení shluků definujících manévry na základě časové oblasti (čísla vzorku) s cílem rozdělení shluků na jednotlivé manévry.

Identifikovaná data byla dále interpolována tak, že na základě znalosti okrajových bodů shluku (v časové oblasti), byla doplněna ostatní data nacházející se mezi těmito hranicemi. Rozdělená data byla dále rozdělena na dva typy letových úloh – horizontální přímočarý let a ostatní manévry. Identifikace horizontálního letu proběhla na základě prahování. V separovaných datech byla nejprve identifikována data, při nichž byl náklon v rozsahu hodnot  $<-5; 5>^\circ$ , resp. na indexy, na nichž se nacházejí data mimo tento interval, byla přidělena hodnota NaN (Not-a-Number). Stejným způsobem byla identifikována data, při nichž vertikální rychlost nespádala do intervalu  $<-100; 100>$  ft/min a označena hodnotou NaN. Následně byla vytvořená matice rozdělena binárně – datům s hodnotou NaN byla přidělena nula, datům s číselnou hodnotou byla přidělena hodnota 1. Poté byly znásobeny sloupce pro náklon a vertikální rychlost. Byla-li výsledkem součinu hodnota 1, pak byl identifikován horizontální přímočarý let. V případě, že výsledkem součinu byla hodnota 0, byl identifikován jiný manévr, viz zdrojový kód 3 a obr. 4.13.



```

B=data(:,9);
B(B>5 | B<-5)=NaN;

VS=data(:,5);
VS(VS>100 | VS<-100)=NaN;

HPLidx=[];

HPLidx=(1:length(VS))'.*(~isnan(B).*~isnan(VS));
HPLidx(HPLidx==0)=NaN;

[IDXhpl, isnoise]=DBSCAN(HPLidx,25,25);

map=jet(max(IDXhpl));

IDXhplNew=NaN(length(IDXhpl),length(IDXhpl));

count=1;
for i = 1:max(IDXhpl)
    hold on
    line=[];
    line=linspace(min(HPLidx(IDXhpl==i,1)),max(HPLidx(IDXhpl==i,1)),...
        max(HPLidx(IDXhpl==i,1))-min(HPLidx(IDXhpl==i,1))+1);

    IDXhplNew(1:length(line),count)=line;

    count=count+1;
end
IDXhplNew(~any(~isnan(IDXhplNew),2),:)=[];
IDXhplNew(:,~any(~isnan(IDXhplNew)))=[];


clear HPLidx

MANidx=IDXsep;
HPLidx=IDXhplNew;

```

Zdrojový kód 3: Separace dat rozdělených pomocí shlukové analýzy na horizontální přímočarý let a ostatní manévry, programovací jazyk Matlab.

Jednotlivé manévry byly dále hodnoceny na základě jejich letových údajů. V případě headingu bylo třeba ošetřit přechod přes 0°, příp. přes 360°. Pro tyto účely byly identifikovány etapy přechodu a na základě informace o změně hodnot před tímto přechodem, byla data upravena tak, aby nedocházelo při přechodu k „přeskočení“, ale aby byl vyhodnocený manévr plynulý tak, jak je tomu v reálné situaci viz Zdrojový kód 4.



Obrázek 4.13 Ukázka vykresleného průběhu letu s identifikovanými fázemi horizontálního přímočarého letu (červená) a dalších manévrů (zelená).

```
[row]=find(diff(HDG2)>100 | diff(HDG2)<-100);
HDG1=HDG2;

rowPone=0;
rowPone(2:1+length(row))=row;
rowPone(end+1)=length(HDG);

for i=length(rowPone)-1

    if mean(diff(HDG1(rowPone(1)+1:rowPone(2))))>0
        if mod(i,2)==0
            HDG1(rowPone(i)+1:rowPone(i+1))=...
            HDG2(rowPone(i)+1:rowPone(i+1))+360;
        else
            HDG1(rowPone(i)+1:rowPone(i+1))=...
            HDG2(rowPone(i)+1:rowPone(i+1));
        end
    end
    if mean(diff(HDG1(rowPone(1)+1:rowPone(2))))<0
        if mod(i,2)==0
            HDG1(rowPone(i)+1:rowPone(i+1))=...
            HDG2(rowPone(i)+1:rowPone(i+1))-360;
        else
            HDG1(rowPone(i)+1:rowPone(i+1))=...
            HDG2(rowPone(i)+1:rowPone(i+1));
        end
    end
end
end
```

Zdrojový kód 4: Úprava parametru heading při průchodu přes 0°, příp. přes 360°, programovací jazyk Matlab.

Při popisu jednotlivých manévrů byla kromě headingu použita také data nesoucí informaci o náklonu, výšce, vertikální rychlosti a magnetickém kurzu. V případě výšky, vertikální rychlosti a náklonu je vypisována informace o průměrných hodnotách těchto parametrů a jejich směrodatné odchylce v průběhu manévru. Dále byl určen čas trvání manévru a na základě této znalosti a informace o průměrném náklonu byla vypočtena informace o velikosti zatáčky, viz zdrojový kód 5 a obr. 4.14. Na základě průměrné hodnoty vertikální rychlosti byla rozlišena zatáčka v horizontu, stoupavá a klesavá zatáčka. Na základě informací o průměrném náklonu byla dále odlišena zatáčka vlevo a vpravo, viz zdrojový kód 5 a obr. 4.14.

```
sH=H(1);
eH=H(end);
meanH=mean(H);
medH=median(H);
stdH=std(H);

dHDG=diff(HDG1);
meandHDG=mean(dHDG/(1/fvz));
stdHDG=std(dHDG)/(1/fvz);

otocka=meandHDG*dT;

meanB=mean(B);
medB=median(B);
stdB=std(B);

meanVS=mean(VS);
medVS=median(VS);
stdVS=std(VS);

if meanVS<-50
    cd='descending';
elseif meanVS>50
    cd='climbing';
elseif meanVS>=-50 && meanVS<=50
    cd='horizontal';
end

if meanB<0
    lp='to the left';
elseif meanB>0
    lp='to the right';
else
    lp='';
end
```

Zdrojový kód 5: Výpočet hodnot pro popis jednotlivých manévrů, programovací jazyk Matlab.

Obdobným způsobem, jakým byly popsány jednotlivé manévry, byl popsán i dříve identifikovaný horizontální přímočarý let. Vzhledem k tomu, že tento manévr byl identifikován pouze na základě vertikální rychlosti a náklonu, lze předpokládat, že tato data obsahují také taxiing, tedy pohyb po letišti. Z tohoto důvodu byla, na základě výšky letu, rozdělena tato kategorie manévrů na dvě části – taxiing a skutečný horizontální přímočarý let, viz obr.4.14.

```
6×1 cell array

'taxiing (airport) '
'mean Alt (AMSL): 758 ft (+/- 0) '
'mean VS: 1.1826 ft/min (+/- 7.5377) '
'mean Bank: 0.088696 ° (+/- 0.13096) '
'mean diff HDG: -0.04386 °/s (+/- 1.5594) '
'Maneuver duration: 45.6 s'

5×1 cell array

'104 ° climbing turn to the left'
'mean Alt (AMSL): 1403.4444 ft (+/- 62.556) '
'mean VS: 694.3556 ft/min (+/- 43.3978) '
'mean Bank: -24.9178 ° (+/- 0.87731) '
'Maneuver duration: 17.6 s'

6×1 cell array

'Straight and level flight'
'mean Alt (AMSL): 2514.3535 ft (+/- 9.6693) '
'mean VS: 3.3232 ft/min (+/- 104.4333) '
'mean Bank: -0.029293 ° (+/- 1.0148) '
'mean diff HDG: 0.05102 °/s (+/- 0.94838) '
'Maneuver duration: 39.2 s'

5×1 cell array

'320 ° horizontal turn to the right'
'mean Alt (AMSL): 2607.6065 ft (+/- 6.547) '
'mean VS: 1.0581 ft/min (+/- 115.0484) '
'mean Bank: 28.4742 ° (+/- 0.68706) '
'Maneuver duration: 61.6 s'

5×1 cell array


'131 ° climbing turn to the left'
'mean Alt (AMSL): 2903.5909 ft (+/- 103.2065) '
'mean VS: 451.6182 ft/min (+/- 102.8085) '
'mean Bank: -15.09 ° (+/- 0.85959) '
'Maneuver duration: 43.6 s'
```

Obrázek 4.14 Ukázka výstupu popsaného skriptu pro automatickou detekci manévrů.

## 5 Výsledky

Pomocí výše popsaného postupu softvérového prostředí vytvořeného v rámci této práce byly identifikovány jednotlivé manévry. Následně byly v identifikovaných úsecích letu určeny kumulativní chyby subjektů. Chyby v jednotlivých parametrech byly nejprve standardizovány tak, že bylo získáno z-score z celého výcviku každého subjektu pro chybu v daném parametru. Kumulativní chyba byla získána sumarizací chyb v jednotlivých letových parametrech, tj. náklon, magnetický kurz, vertikální rychlost a výška, respektive z jejich z-score. Tímto způsobem byly sjednoceny údaje o chybě v každém časovém okamžiku, respektive v identifikovaných manévrech.

Distribuce výše popsaných kumulativních chyb v průběhu celého výcviku jsou prezentovány pomocí boxplotu, viz obr. (), s vyznačenými odlehlými hodnotami, které jsou definované jako hodnoty větší než 1.5 násobek mezikvartilového rozpětí. Určení statistické podobnosti jednotlivých letových fází navzájem bylo provedeno pomocí Wilcoxonova testu s Bonferroniho korekcí z důvodu 15 párových testů. Získané p-hodnoty jsou prezentovány v tab. 5.1.



Obrázek 5.1 Distribuce kumulativní chyby pro testovaný vzorek subjektů v průběhu celého výcviku

Tabulka 5.1 Výsledky Wilcoxonova testu pro porovnání statistické podobnosti kumulativní chyby v jednotlivých fázích výcviku.

	T2M	T11M	L12M	L17M	T18M	L19M
T2M	1	1,32E <sup>-23</sup>	9,32E <sup>-10</sup>	0,53261*	7,91E <sup>-24</sup>	1,50E <sup>-13</sup>
T11M		1	1,78E <sup>-33</sup>	1,32E <sup>-23</sup>	0,54622*	2,28E <sup>-33</sup>
L12M			1	9,32E <sup>-10</sup>	2,79E <sup>-33</sup>	0,00683
L17M				1	7,91E <sup>-24</sup>	1,50E <sup>-13</sup>
T18M					1	2,61E <sup>-33</sup>
L19M						1

\* Hodnoty, které neoznačují statisticky signifikantní rozdíl.

Z grafu na obr. 5.1 je zřejmé, že v průběhu trenažérového výcviku došlo ke snížení chybovosti, tj. došlo k poklesu mediánu kumulativní chyby mezi T2M a T11M. Na základě výsledku Wilcoxonova testu (viz tab. 5.1) s Bonferroniho korekcí je zřejmé, že tento pokles je statisticky signifikantní. Následně je zřejmý nárůst chybovosti mezi T11M a L12M, tj. při přestupu z trenažérového výcviku do letadla. S ohledem na p-hodnotu testované statistiky je tento přechod signifikantní. Dále je zřejmý pokles při přechodu mezi L12M a L17M. Na základě p-hodnoty pro daný přechod je tato změna statisticky signifikantní. Poté dochází k dalšímu poklesu, tj. mezi L17M a T18M, který je opět statisticky signifikantně odlišný. Na závěr výcviku je zřejmý statisticky signifikantní přechod mezi trenažérem a letadlem, tj. T18M a L19M.

Z tab. 5.1 je patrné, že při párovém testování jednotlivých fází výcviku navzájem nelze na testované hladině významnosti 5 % odlišit pouze dvojice T11M a T18M.

## 6 Diskuze

---

V této práci byl navržen softvérový prostředek pro objektivizaci hodnocení výkonnosti pilotů v leteckém výcviku. Pro hodnocení výkonnosti je nejprve třeba označit manévry v datech z letového zapisovače. Ačkoli je možné manévry ručně označit v průběhu měření, nelze s jistotou tvrdit, že označení manévrů je precizní. Chceme-li hodnotit výkonnost, je vhodné využít data, jejichž průběh je předem definován. Právě z těchto důvodů se jeví jako vhodné využít data z precizně detekovaných manévrů. Tudíž aby nebylo nutné manévry zpětně ručně selektovat, byl vytvořen představený softvérový prostředek.

Pro účely automatické detekce letových manévrů byla zvolena metoda shlukovací analýzy patřící do metod strojového učení bez učitele. Tato metoda byla zvolena s ohledem na schopnosti detekovat šum, které se v průběhu realizace diplomové práce ukázaly jako zásadní pro automatickou identifikaci letových manévrů. Ostatní, v práci představené, metody strojového učení se ukázaly jako nevhodné, právě s ohledem na jejich neschopnost detekovat šum.

Navržený softvérový prostředek byl testován na dostupných datech, která pocházela z výcviku se striktně definovaným průběhem letu. Vzhledem ke znalosti postupnosti jednotlivých manévrů bylo možné ověřit funkčnost navrženého programu.

S cílem hodnocení výkonnosti byla získána kumulativní chyba právě v detekovaných manévrech. Z výsledků vyplývá, že kumulovaná chyba poklesla v průběhu simulátorového výcviku. Tento fakt byl předpokládán vzhledem k tomu, že subjekty po dobu 10 hodin létaly stejně nedefinovaný let. Následný nárůst chyby lze přisuzovat přestupu z trenažérového výcviku na letadlo. Z výsledků vyplývá, že i při poslední měřené hodině došlo k nárůstu chybovosti. Tento fakt lze přisuzovat skutečnosti, že subjekty opět přestoupily z trenažéru do letadla a zároveň zobrazení letových údajů bylo odlišné oproti předchozím fázím výcviku.

Na základě prezentovaných výsledků lze tvrdit, že trend chybovosti v průběhu výcviku sleduje předpokládaný vývoj. Z uvedených výsledků je patrné, že zvolený přístup pro hodnocení výkonnosti pilotů by mohl poskytnout potřebné údaje pro podporu instruktorovy expertní znalosti.

## 7 Závěr

---

Primárním zaměřením prezentované závěrečné práce je řešení problematiky týkající se zvýšení efektivity výcviku leteckého personálu s primárním zaměřením na piloty formou Evidence-based Tréninku. Tento typ tréninku je postaven na důkazech získaných v průběhu výcviku daného subjektu. Aktuálně je tento typ tréninku všeobecně podporován, avšak dostupné metody jsou založeny zejména na subjektivním hodnocení průběhu výcviku instruktorem. Ačkoli je expertní znalost instruktora nezbytná pro daný typ výcviku, efektivitu EBT je možno dále podpořit naměřenými daty získanými v průběhu výcviku, čímž může být hodnocení částečně objektivizováno. V důsledku toho tato data mohou podpořit instruktorovo rozhodnutí o dalším průběhu výcviku, příp. poukázat na situaci, kterou instruktor přehlédl. Mezi získávaná data lze řadit letové parametry získané v průběhu simulovaného tréninku nebo výcviku prováděného v reálném provozu, sloužící pro hodnocení přesnosti pilotáže.

Hlavním přínosem práce je vytvořený softvérový prostředek pro automatickou identifikaci letových manévřů. Tento program je založen na metodě strojového učení, konkrétně shlukové analýze beroucí v potaz hustotu okolí. Tímto způsobem bylo možné identifikovat jednotlivé manévry. V identifikovaných úsecích byla určena kumulativní chyba. Takto bylo možné získat informaci o progresu v průběhu výcviku podloženou naměřenými daty.

Limitací práce je, že data nepocházejí z reálného výcviku, ale z výcviku s přesně definovanými lety, který byl nutný pro ověření funkčnosti navrženého řešení. Avšak i s ohledem na tuto limitaci, lze na základě výsledků této práce tvrdit, že představený koncept je správným krokem v tomto směru. Lze tedy předpokládat, že v budoucím výzkumu dojde k odstranění uvedené limitace, tj. prostředek bude implementován do reálného provozu letecké školy.

V dohledném časovém horizontu je možné uvažovat implementaci tohoto řešení do mobilních aplikací, které by po každém letu poskytly instruktorovi automatickou identifikaci všech fází a manévřů letu se základní evaluací. Posléze by instruktor mohl tuto evaluaci využít jako objektivní vstup do celkového vyhodnocení pilota. Tuto evaluaci je také možné využít pro sledování celkového progresu nebo degresu ve výcviku a posléze zvážit eventuální reorganizaci celého výcvikového programu.



V dlouhodobém horizontu je budoucností tohoto řešení rozšíření evaluace na všechny fáze letu a výcviku zahrnující i výcvik na větších typech letadel používaných v obchodní letecké dopravě, zároveň o rozšíření hodnocení hard a eventuálně i soft parametrů.

## Seznam použité literatury:

---

- [1] VOSS, William. Evidence-Based Training. Flight Safety Foundation. Dostupné z: <https://flightsafety.org/asw-article/evidence-based-training/>
- [2] The Advanced Qualification Program: Lessons Learned From 20 Years of AQP. In: ICAO - International Civil Aviation Organization. 2010. Dostupné z: <https://www.icao.int/Meetings/AMC/NGAP/Documentation/The%20Advanced%20Qualification%20Program.pdf>
- [3] Capitan Mark LINNEY. Alternative Training Qualification programme (ATQP). AIRCRAFT IT MRO. 2013. Dostupné z: <http://www.evoke-systems.aero/wp-content/uploads/2013/02/ATQP-Article-Feb-2013.pdf>
- [4] Alternative Training and Qualification Programme (ATQP): Industry Guidance. Civil Aviation Authority [online]. Dostupné z: [https://publicapps.caa.co.uk/docs/33/sarg\\_Its\\_ATQP%20Stds%20Doc80%20v1\\_July%2013.pdf](https://publicapps.caa.co.uk/docs/33/sarg_Its_ATQP%20Stds%20Doc80%20v1_July%2013.pdf)
- [5] *Acceptable Means of Compliance (AMC) and Guidance Material (GM) to Annex III – Part-ORO*. EASA. Dostupné také z: [https://www.easa.europa.eu/sites/default/files/dfu/Consolidated%20unofficial%20AMC&GM\\_Annex%20III%20Part-ORO.pdf](https://www.easa.europa.eu/sites/default/files/dfu/Consolidated%20unofficial%20AMC&GM_Annex%20III%20Part-ORO.pdf)
- [6] *Rozhodnutí výkonného ředitele EASA*. DOPRAVNÍ ÚŘAD. Dostupné také z: <http://nsat.sk/legislativa-legislativa-sk-a-eu/legislativa-civilne-letectvo-2/rozhodnutia-vykonneho-riaditeľa-europskej-agentury-pre-bezpecnost-letectva/>
- [7] *Terms of reference for a rulemaking task: Evidence-based and competency-based training* [online]. In: Dostupné z: <https://www.easa.europa.eu/sites/default/files/dfu/ToR%20%26%20Concept%20Paper%20RMT.0599%20Issue%201.pdf>
- [8] ICAO - INTERNATIONAL CIVIL AVIATION ORGANIZATION. *Manual of evidence-based training*. 2013. ISBN 978-929-2492-427

[9] Project OS 12/30 - CAAP 217-1(0) - CAR 217 Training and checking systems. Civil Aviation Safety Authority - CASA [online]. Dostupné z: <https://www.casa.gov.au/standard-page/project-os-1230-caap-217-10-car-217-training-and-checking-systems>

[10] Project OS 12/30 - CAAP 217-1(0) - CAR 217 Training and checking systems. Civil Aviation Safety Authority - CASA [online]. Dostupné z: <https://www.casa.gov.au/standard-page/project-os-1230-caap-217-10-car-217-training-and-checking-systems>

[11] The European Plan for Aviation Safety 2018-2022 [EASA]. Str. 29. Dostupné z: [https://www.easa.europa.eu/sites/default/files/dfu/EPAS\\_2018-2022%20v2.2.8%20for%20MB.pdf](https://www.easa.europa.eu/sites/default/files/dfu/EPAS_2018-2022%20v2.2.8%20for%20MB.pdf)

[12] *Acceptable Means of Compliance (AMC) and Guidance Material (GM) to Part-ORO*. In: EASA - European Aviation Safety Agency, 2012.]

[13] *Part - FCL*. In: EASA - European Aviation Safety Agency, 2016. Dostupné také z: <https://www.easa.europa.eu/sites/default/files/dfu/Part-FCL.pdf>

[14] Civil Aviation Authority of New Zealand. *Flight Instructor's Guide*. 2003. Dostupné také z: <http://www.caa.co.za/Flight%20Instructor%20Guides/New%20Zealand%20Flight%20Instructor%27s%20Guide.pdf>

[15] LEVITT, M.Andrew a George R. DERRICK. An evaluation of physiological parameters of stress in the emergency department.

[16] REGULA, Marek, Vladimir SOCHA, Patrik KUTILEK, Lubos SOCHA, Karel HANA, Lenka HANAKOVA a Stanislav SZABO. Study of heart rate as the main stress indicator in aircraft pilots. Proceedings of the 16th International Conference on Mechatronics - Mechatronika 2014.

[17] WRIGHT, Stephen a David O'HARE. Can a glass cockpit display help (or hinder) performance of novices in simulated flight training?. *Applied Ergonomics*. 2015, 47, 292-299. DOI: 10.1016/j.apergo.2014.10.017. ISSN 00036870. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S0003687014002130>

- [18] SOCHA, Vladimír, Jakub SCHLENKER, Peter KAL'AVKSY, Patrik KUTILEK, Lubos SOCHA, Stanislav SZABO a Pavel SMRCKA. Effect of the change of flight, navigation and motor data visualization on psychophysiological state of pilots. 2015 IEEE 13th International Symposium on Applied Machine Intelligence and Informatics (SAMI). IEEE, 2015, 2015, 339-344. DOI: 10.1109/SAMI.2015.7061900. ISBN 978-1-4799-8221-9. Dostupné také z: <http://ieeexplore.ieee.org/document/7061900/>
- [19] HIREMATH, Vishal, Robert W. PROCTOR, Richard O. FANJOY, Robert G. FEYEN a John P. YOUNG. Comparison of Pilot Recovery and Response Times in Two Types of Cockpits. Human Interface and the Management of Information. Information and Interaction. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009, 2009, 766-775. Lecture Notes in Computer Science. DOI: 10.1007/978-3-642-02559-4\_83. ISBN 978-3-642-02558-7. Dostupné také z: [http://link.springer.com/10.1007/978-3-642-02559-4\\_83](http://link.springer.com/10.1007/978-3-642-02559-4_83)
- [20] KALAVSKY, Peter, Robert ROZENBERG, Luboš SOCHA, Vladimír SOCHA, Jindrich GAZDA a Monika KIMLICKOVA. Methodology of Pilot Performance Measurements. MAD - Magazine of Aviation Development. 2017, 5(2), 25-. DOI: 10.14311/MAD.2017.02.04. ISSN 1805-7578. Dostupné také z: <https://ojs.cvut.cz/ojs/index.php/mad/article/view/4146>
- [21] ŽIŽKA, Jan, Štefan DÚHA a František JŮN. The Proposition and Evaluation of Amendments to Current Flight Training Curricula Regarding Global Navigation Satellite Systems. Transportation Research Procedia. 2017, 28, 201-206. DOI: 10.1016/j.trpro.2017.12.186. ISSN 23521465. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S2352146517311067>
- [22] PUŠ, Vladimír. *Popisná statistika*. Vyd. 2. Praha: Česká zemědělská univerzita v Praze, 2007. ISBN 978-80-213-1662-1.
- [23] MOHAMMED, Mohssen, Muhammad Badruddin KHAN a Eihab Bashier Mohammed BASHIER. *Machine learning: algorithms and applications*. Boca Raton: CRC Press, 2017. ISBN 978-149-8705-387.
- [24] FLACH, Peter A. *Machine learning: the art and science of algorithms that make sense of data*. New York: Cambridge University Press, 2012. ISBN 978-1-107-09639-4.

[25] SHALEV-SHWARTZ, Shai. a Shai. BEN-DAVID. *Understanding machine learning: from theory to algorithms*. New York, NY, USA: Cambridge University Press, 2014. ISBN 978-1-107-05713-5.

[26] DEZA, M. a Elena. DEZA. *Encyclopedia of distances*. New York: Springer Verlag, c2009. ISBN 978-3-642-00234-2.

[27] BUDÍKOVÁ, Marie, Tomáš LERCH a Štěpán MIKOLÁŠ. *Základní statistické metody*. Brno: Masarykova univerzita v Brně, 2005. ISBN 80-210-3886-1.

[28] KOMPRDOVÁ, Klára. *Rozhodovací stromy a lesy*. Brno: Akademické nakladatelství CERM, 2012. ISBN 978-80-7204-785-7

[29] WESTERN, BRUCE. *Bayesian Analysis for Sociologist: An Introduction*. Sociological Methods & Research. 1999, 28 (1), 7-34.

[30] HEBÁK, PETR. Srovnání klasické a bayesovské pravděpodobnosti a statistiky (1.). In: ACTA OECONOMICA PRAGENSIA. Praha: VŠE, 2012, 69-87. Dostupné z: <http://www.vse.cz/aop/abstrakt.php3?IDcl=359>

[31] NAGY, Ivan. Stochastické systémy [online]. Dostupné také z: <http://staff.utia.cas.cz/suzdaleva/pdfka/StSysTexty.pdf>

[32] Ester, Martin; Kriegel, Hans-Peter; Sander, Jörg; Xu, Xiaowei (1996). Simoudis, Evangelos; Han, Jiawei; Fayyad, Usama M., eds. *A density-based algorithm for discovering clusters in large spatial databases with noise*. Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD-96). AAAI Press. pp. 226–231. ISBN 1-57735-004-9.

[33] HARUŠTIAKOVÁ, Danka. *Vícerozměrné statistické metody v biologii*. Brno: Akademické nakladatelství CERM, 2012. ISBN 978-80-7204-791-8.

[34] RNDr. Eva Janoušová a doc. RNDr. Ladislav Dušek, Dr. *Pokročilé metody analýzy dat v neurovědách*. Institut biostatiky a analýzy LF MU, 2016. Dostupné také z: <http://slideplayer.cz/slide/12803948/>

[35] WHITLEY, Elise a Jonathan BALL. *Statistics review 6: Nonparametric methods*. 2002. Dostupné také z: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC153434/>

[36] Keppel G, Wickens TD. *Design and analysis: a researcher's handbook*. 4th ed. New Jersey: Pearson Education Inc.; 2004

## Seznam použité literatury u obrázků:

---

[a] PUŠ, Vladimír. *Popisná statistika*. Vyd. 2. Praha: Česká zemědělská univerzita v Praze, 2007. ISBN 978-80-213-1662-1.

[b] MOHAMMED, Mohssen, Muhammad Badruddin KHAN a Eihab Bashier Mohammed BASHIER. *Machine learning: algorithms and applications*. Boca Raton: CRC Press, 2017. ISBN 978-149-8705-387.

[c] *Traditional Programming vs. Machine Learning* [Data Science Central]. Dostupné také z: <https://www.datasciencecentral.com/profiles/blogs/traditional-programming-versus-machine-learning-in-one-picture>

[d] MOHAMMED, Mohssen, Muhammad Badruddin KHAN a Eihab Bashier Mohammed BASHIER. *Machine learning: algorithms and applications*. Boca Raton: CRC Press, 2017. ISBN 978-149-8705-387.

[e] *Dendrogram*. [Mathworks]. Dostupné také z: <https://www.mathworks.com/help/stats/dendrogram.html>

[f] *Problém generalizace* [The Shape of Data]. Dostupné také z: <https://shapeofdata.wordpress.com/2013/03/26/general-regression-and-over-fitting/>

[g] *Stavba softvérového řešení* [Mathworks]. Dostupné také z: <https://www.mathworks.com/help/stats/machine-learning-in-matlab.html>