

Primjena umjetne inteligencije u upravljanju zračnim prometom

Rakonić, Bruno

Graduate thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Economics and Business / Sveučilište u Zagrebu, Ekonomski fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:148:337438>

Rights / Prava: [Attribution-NonCommercial-ShareAlike 3.0 Unported/Imenovanje-Nekomercijalno-Dijeli pod istim uvjetima 3.0](#)

Download date / Datum preuzimanja: **2024-11-04**



Repository / Repozitorij:

[REPEFZG - Digital Repository - Faculty of Economics & Business Zagreb](#)



Sveučilište u Zagrebu
Ekonomski fakultet
Specijalistički diplomski stručni studij Menadžment i marketing maloprodaje

**PRIMJENA UMJETNE INTELIGENCIJE U UPRAVLJANJU
ZRAČNIM PROMETOM**

Diplomski rad

Bruno Rakonić

Zagreb, rujan 2024.

Sveučilište u Zagrebu
Ekonomski fakultet
Specijalistički diplomski stručni studij Menadžment i marketing maloprodaje

**PRIMJENA UMJETNE INTELIGENCIJE U UPRAVLJANJU
ZRAČNIM PROMETOM**

**THE APPLICATION OF ARTIFICIAL INTELLIGENCE IN
AIR TRAFFIC MANAGEMENT**

Diplomski rad

Student: Bruno Rakonić

JMBAG studenta: 0067612527

Mentor: Izv. prof. dr. sc. Dora Naletina

Zagreb, rujan 2024.



IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je diplomski rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija.

Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Zagreb, 9.9.2024.

(mjesto i datum)

Bruno Bakončić

(vlastoručni potpis studenta)

SAŽETAK

Umjetna inteligencija postaje sve bitniji aspekt svakodnevnog života. Svoju primjenu pronašla je u brojnim sferama pa tako i u upravljanju zračnim prometom. Ona dovodi do brojnih poboljšanja i olakšavanja zadataka o kojima u određenim trenucima ovise brojni životi. Umjetna inteligencija značajno smanjuje kašnjenje letova, povećava učinkovitost zračne plovidbe, omogućuje prediktivnu analitiku te sprječava nastanak potencijalnih tehničkih kvarova na zrakoplovima prije nego se oni i pojave. Također unaprjeđuje predviđanje vremenskih uvjeta i brojne druge prednosti. U ovom radu proučavaju se teorijski aspekti primjene umjetne inteligencije u upravljanju zračnim prometom i provest će se analiza kako ona poboljšava i olakšava ovu industriju. Cilj ovog rada je istražiti sve načine na koje umjetna inteligencija olakšava i poboljšava upravljanje zračnim prometom. Isto tako, cilj se ogleda i u proučavanju i objašnjavanju načina na koji ona djeluje i unaprjeđuje određeni sektor zračnog prometa.

Ključne riječi: umjetna inteligencija, zračni promet, automatizacija, tehnologija

ABSTRACT

Artificial intelligence is becoming an increasingly important aspect of everyday life. It has found applications in numerous fields, including air traffic management. AI brings about numerous improvements and facilitates tasks upon which many lives may depend at certain moments. It significantly reduces flight delays, enhances air navigation efficiency, enables predictive analytics, and prevents potential technical failures in aircraft before they occur. Additionally, it improves weather forecasting and offers many other advantages. This paper examines the theoretical aspects of AI application in air traffic management and will conduct an analysis of how it improves and facilitates this industry. The aim of this paper is to investigate all the ways in which AI eases and enhances air traffic management. Furthermore, the goal is to study and explain how AI operates and advances specific sectors of air traffic.

Key words: artificial intelligence, air traffic, automation, technology

SADRŽAJ

1.	UVOD	1
1.1.	Predmet i cilj rada.....	1
1.2.	Metode i izvori prikupljanja podataka.....	1
1.3.	Sadržaj i struktura rada	2
2.	DEFINICIJA UMJETNE INTELIGENCIJE.....	3
2.1.	Povijest razvoja umjetne inteligencije.....	3
2.2.	Alati i tehnike umjetne inteligencije.....	5
2.3.	Primjena umjetne inteligencije u analizi podataka u zračnom prometu	10
2.4.	Automatizacija i autonomija umjetne inteligencije u zračnom prometu	15
3.	UMJETNA INTELIGENCIJA U UPRAVLJANJU ZRAČNIM PROMETOM .	25
3.1.	Prediktivna analitika i upravljanje rizicima.....	25
3.2.	Analiza podataka o letovima kroz umjetnu inteligenciju	28
3.3.	Sigurnost u zračnom prometu kroz umjetnu inteligenciju.....	35
3.4.	Primjena umjetne inteligencije u razvoju novih tehnologija u zračnom prometu	39
4.	EMPIRIJSKO ISTRAŽIVANJE PRIMJENE UMJETNE INTELIGENCIJE U UPRAVLJANJU ZRAČNIM PROMETOM	43
4.1.	Pregled postojećih istraživanja	43
4.2.	Metodologija istraživanja	44
4.3.	Rezultati istraživanja	44
4.4.	Ograničenja i preporuke za buduća istraživanja.....	48
5.	ZAKLJUČAK.....	50
	POPIS LITERATURE.....	51
	POPIS SLIKA	63
	POPIS GRAFIKONA.....	64
	POPIS PRILOGA.....	65
	Prilog 1. Anketni upitnik	65
	ŽIVOTOPIS STUDENTA	68

1. UVOD

Upravljanje zračnim prometom, ATM (Air Traffic Management) predstavlja složen i vitalan sustav koji zahtijeva preciznu koordinaciju brojnih letova svakog dana. Gledajući povijesne okvire i početak 20. stoljeća, ovaj segment je bio iznimno rudimentaran s naglaskom na vizualnu navigaciju i osnovnu radio komunikaciju. Prvi kontrolni tornjevi pojavljuju se 1920-ih godina, a daljnjim razvojem dolazi se do daleko sofisticiranijih i automatiziranih sustava za nadzor i kontrolu letenja. Rastućim brojem zrakoplovnih putovanja, tradicionalni sustavi upravljanja zračnim prometom suočavaju se s nizom izazova, uključujući povećanu gustoću prometa, nepovoljne vremenske uvjete i ograničene kapacitete zračnog prostora. U zračnom prometu svaka nepromišljena ili nedovoljno kvalitetna reakcija može dovesti do ugrožavanja ljudskih života. Razvojem umjetne inteligencije osigurane su u velikom omjeru kvalitetnije, složenije i preciznije radnje za koje čovjek nema kompetencije da ih dovoljno kvalitetno izvede.

1.1. Predmet i cilj rada

Predmet ovog diplomskog rada je analiza primjene umjetne inteligencije u upravljanju zračnim prometom, kao i analiza, pregled i evaluaciju tehnologija i postupaka koji se koriste. Osim toga, objasniti će se njihov utjecaj na sigurnost i učinkovitost zračnog prometa te će se nadalje istražiti sposobnost umjetne inteligencije za predviđanje i rješavanje potencijalnih problema. Rad će se baviti i procjenom operativne učinkovitosti umjetne inteligencije u stvarnim situacijama, a biti će razmotrena i pitanja regulative, etike i sigurnosti u kontekstu primjene kako bi se uključio i holistički pristup ovom kompleksom području istraživanja. Cilj rada je identificirati karakteristike učinkovite primjene umjetne inteligencije u područjima poput analize podataka o letovima, automatizacije i autonomije, prediktivne analitike i upravljanja rizicima, ali i njene primjene s ciljem razvoja daljnjih tehnologija i korisnih alata koji će u još većoj mjeri osigurati da se zračni promet odvija neometano.

1.2. Metode i izvori prikupljanja podataka

U ovom radu koristit će se razne metode istraživanja i prikupljanja podataka kako bi se što bolje istražila sva dostupna literatura i informacije vezane za ulogu umjetne inteligencije u upravljanju zračnim prometom. Neke od njih su metoda analize koja se temelji na sustavnom proučavanju podataka, tekstova, dokumenata, statističkih podataka kako bi se što bolje raščlanili rezultati i razumijeli osnovni elementi i struktura. Osim toga, koristit će se i

metoda sinteze na način da se opći zaključci donesu integracijom različitih elemenata i analiza tijekom prikupljanja. Metoda usporedbe će se također koristiti na način da se uspoređuju razni podaci, fenomeni sa svrhom uočavanja sličnosti ili razlika. Preostale metode koje će se koristiti biti će induktivna i deduktivna metoda s ciljem da se na temelju specifičnih podataka donesu opći zaključci. Također će biti korištena i metoda deskripcije. Situacije, slučajevi, razni fenomeni će biti objašnjeni ovom metodom. Prikupljat će se primarni i sekundarni podaci. Sekundarni podaci bit će prikupljeni iz stručnih i znanstvenih članaka, priručnika, knjiga, publikacija te web stranica vezanih za proučavanu temu. U primarnom istraživanju kao instrument bit će korišten anketni upitnik, dok će ispitanici biti stručnjaci zaposleni u Hrvatskoj kontroli zračne plovidbe.

1.3. Sadržaj i struktura rada

Rad je podijeljen u pet poglavlja. Tako se u uvodnom poglavlju objašnjava predmet i cilj rada, izvori i metode prikupljanja podataka, kao i sadržaj i struktura rada.

Drugo poglavlje odnosi se na definiranje osnovnih pojmova vezanih za umjetnu inteligenciju i podijeljeno je na četiri potpoglavlja. Proučava se povijesni razvoj umjetne inteligencije, razni alati i tehnike koje se primjenjuju kod uporabe, njezin utjecaj na područje analize podataka u zračnom prometu te prikaz i istraživanje sustava automatizacije i autonomije.

Treće poglavlje započinje glavnom problematikom i ulazi u srž ovog diplomskog rada. Podijeljeno je također na četiri potpoglavlja. U prvom potpoglavlju se obrađuje tema prediktivne analitike i upravljanje rizicima, a u narednim se analiziraju načini na koje umjetna inteligencija prikuplja podatke o letovima, kako djeluje na sigurnost u zračnom prometu i u konačnici njen utjecaj na razvoj novih tehnologija.

Četvrto poglavlje predstavlja empirijsko istraživanje primjene umjetne inteligencije u upravljanju zračnim prometom. Za početak se daje pregled postojećih istraživanja, potom se objašnjava metodologija istraživanja, rezultati i u konačnici se iznose ograničenja i preporuke za buduća istraživanja.

Rad će se privesti kraju konačnim petim poglavljem gdje će se kroz zaključak iznijeti završne misli vezane za primjenu umjetne inteligencije u upravljanju zračnim prometom.

2. DEFINICIJA UMJETNE INTELIGENCIJE

Glede definiranje pojma umjetne inteligencije (engl. artificial intelligence; UI), najučesstalije se kaže kako je to grana računalnih znanosti koja se bavi razvojem sustava sposobnih za obavljanje zadataka koji obično zahtijevaju ljudsku inteligenciju. Ovi zadaci uključuju razumijevanje prirodnog jezika, prepoznavanje obrazaca, rješavanje problema i donošenje odluka (Bharadiya, 2023).

Za potrebe shvaćanja kako UI funkcionira, nužno je dobro poznavati i razumijeti ove pojmove primijene. Teško je izolirati i osvrnuti se na jednu glavnu granu sustava umjetne inteligencije. S druge strane, kao takav, jedan od ključnih koncepata su autonomni sustavi. Ranije definirano, može se reći da su takvi sustavi dizajnirani isključivo radi toga da se utjecaj ljudskog faktora svede na minimum. Danas postoje brojni autonomni sustavi, od autonomnih vozila do robota u industrijskoj proizvodnji. Način funkcioniranja takvih sustava je da se odluke donose temeljem preciznih senzorskih pokreta, ali i prethodnog iskustva, što im omogućuje djelovanje i prilagođavanje raznim uvjetima (Degas i sur., 2022). Kako vrijeme odmiče, UI evoluirala od osnovnih algoritama do naprednih sustava koji koriste strojno učenje za analizu i obradu velikih količina podataka i autonomno prilagođavanje novih informacija. Strojno učenje (engl. machine learning - ML) također je iznimno bitan pojam kada se spominje koncept umjetne inteligencije. Način rada strojnog učenja je razvoj algoritama koji omogućuju računalima da uče i memoriraju stavke iz podataka. Umjesto da budu eksplicitno programirani za svaki zadatak, strojevi koriste podatke za prepoznavanje obrazaca i poboljšanje svojih performansi kroz iskustvo (Liu i sur., 2019).

2.1. Povijest razvoja umjetne inteligencije

Gledajući kroz povijesne okvire, umjetna inteligencija seže unatrag do sredine 20. stoljeća. Turing (1950) postavlja teorijske temelje za modernu računalnu znanost, a svoj rad iz 1950. godine, „Computing Machinery and Intelligence“ uvodi koncept Turingovog testa kao mjere sposobnosti stroja da demonstrira inteligentno ponašanje nerazlučivo od ljudskog. Prvi računalni programi osposobljeni za samostalno obavljanje osnovnih intelektualnih zadataka razvijani su od pionira poput Johna McCarthyja, Marvinina Minskya i Claudea Shannona. Termin „umjetna inteligencija“ prvi put upotrebljava McCarthy na konferenciji u Dartmouthu 1956. godine. Tada ga definira kao „znanost i inženjerstvo stvaranja inteligentnih strojeva“ (McCarthy i sur., 1956).

Tijekom 1960-ih i 1970-ih razvijaju se prvi programi umjetne inteligencije koji su samostalno mogli obavljati određene radnje. Odnosno, prvi programi umjetne inteligencije mogli su igrati igre na ploči poput šaha, što je razvijeno od strane Allena Newella i Herberta Simona, koji su koristili metode pretraživanja i heuristike za donošenje odluka (Newell i Simon, 1963). Osim igranja igara na ploči, prvi funkcionalni programi UI rješavali su i jednostavne logičke probleme. Unatoč početnim uspjesima i zanimacijom za umjetnu inteligenciju, dolazi do razdoblja poznatog kao „*AI Winter*“. Nedostatak računalne snage i ograničenje algoritama uzrokovali su smanjen interes za provođenje daljnjeg istraživanja, ali isto tako i smanjenje financiranja istraživanja tijekom 1970-ih i 1980-ih godina (Findler i Lo, 1991). Značajniji pomak događa se početkom 21. stoljeća kada razvoj strojnog, posebice dubokog učenja radi ogroman pomak u istraživanju i unaprjeđivanju umjetne inteligencije. Kao što je ranije rečeno, algoritmi dubokog učenja koji su temeljeni na umjetnim neuronskim mrežama s više slojeva, omogućili su analizu velikih količina podataka i prepoznavanje složenih obrazaca (Bharadiya, 2023). Ove tehnologije primjenjuju se u različitim područjima poput prepoznavanja govora, računalnom vidu i autonomnim vozilima (Xie i sur., 2021).

U kontekstu umjetne inteligencije i njene primjene u upravljanju zračnim prometom, prvi pokušaji sežu u 1960-te godine kada istraživači počinju koristiti osnovne algoritme za pomoć u kontroli leta. Iako oskudni i bez velikih i značajnih funkcionalnosti, prvi pokušaji su postavili temelje za budući razvoj. Prema Findler i Lo (1991), distribuirana umjetna inteligencija omogućila je bolju koordinaciju među agentima, što je bilo ključno za rješavanje složenih problema u upravljanju zračnim prometom. Do sofisticiranijih primjena dolazi tijekom 1980-ih i 1990-ih kada napredak računalne tehnologije omogućuje optimizacije rute letenja, predikciju vremenskih uvjeta i automatsko otkrivanje potencijalnih sukoba između zrakoplova. Primjena umjetne inteligencije, kako opisuju Findler i Lo (1991), bila je ključna u razvoju sustava koji su mogli upravljati velikim brojem letova i kompleksnim zračnim prostorom. Osim toga, Durso i Manning (2008) ističu da je primjena tehnologije UI tijekom ovog razdoblja omogućila bolje razumijevanje ljudskih faktora i ergonomije u kontrolnom okruženju.

Kroz povijest umjetna inteligencija konzistentno je napredovala i transformirala se iz ideja u inovacije koje se danas primjenjuju u upravljanju zračnim prometom. Uvođenjem umjetne

inteligencije u svijet zračnog prometa dovodi do transformacije čitave industrije i mijenja način i učinkovitost rada s naglaskom na sigurnost.

2.2. Alati i tehnike umjetne inteligencije

Strojno učenje, kao ključna komponenta umjetne inteligencije i sustav bez kojeg ona ne bi ispunjavala zadatke na relevantan način, može se podijeliti na nekoliko podtipova. Podjela na podtipove i svaki pojedinačni, specifičan je na svoj način i koristi drugačije metode i primjenu.

Tako nadzirano učenje (*engl.* supervised learning) podrazumijeva vrstu strojnog učenja koja koristi označene podatke, gdje su ulazni podaci upareni s odgovarajućim izlazima. Cilj je učenje modela koji može predvidjeti izlazne vrijednosti za nove ulazne podatke na temelju prethodnog učenja; a metode koje se koriste su regresija i klasifikacija. Jedan od primjera je korištenje povijesnih podataka o letovima za predviđanje kašnjenja zrakoplova (Liu i sur., 2019).

Nenadzirano učenje (*engl.* unsupervised learning) se koristi za analizu i grupiranje neoznačenih podataka. Razlikuje se od nadziranog učenja na način da radi s podacima koji nemaju unaprijed definirane oznake. Cilj ove vrste učenja je otkrivanje skrivenih obrazaca ili struktura unutar podataka. Prema Degas i sur. (2022), ovaj podtip strojnog učenja ima ključnu ulogu u primjeni umjetne inteligencije u zračnom prometu omogućavajući analizu velikih količina podataka bez potrebe za prethodnim označavanjem. Za uspješno prepoznavanje obrazaca u podacima o letu, sigurnosnim incidentima i prometnim tokovima koriste se tehnike kao što su klasteriranje i asocijacijsko učenje.

Pojačano učenje (*engl.* reinforcement learning) se temelji na sustavu nagrada i kazni. Kako bi se maksimizirala kumulativna nagrada tijekom vremena, algoritmi učenja donose odluke u sekvencama. Ovaj podtip učenja je iznimno koristan kada se odluke moraju donositi u stvarnom vremenu. Primjer ove vrste učenja je optimizacija ruta letenja u stvarnom vremenu kako bi se smanjilo vrijeme putovanja i potrošnja goriva (Patriarca i sur., 2022).

Pregledom raznih podtipova strojnog učenja uviđa se široki spektar primjene i alata za analizu podataka i donošenje odluka u raznim situacijama kod upravljanja zračnim prometom.

Navedene metode imaju prednosti, ali i nedostatke i upravo zbog toga postoji još više podvrsta strojnog učenja da bi se uvijek odabrala ona metoda koja najbolje odgovara potrebama.

Kao iznimno bitan podskup strojnog učenja, spominje se duboko učenje (*engl.* deep learning, DL). Findler i Lo (1991) ističu kako je duboko učenje omogućilo značajne napretke u područjima kao što su prepoznavanje govora, obrada prirodnog jezika i računalni vid. S fokusom na korištenje umjetnih neuronskih mreža s više slojeva (dubokih mreža), osnovna uporaba i primjena dubokog učenja ogleda se u analizi složenih podataka. Xie i sur. (2021) tvrde da se takve duboke neuronske mreže koriste u sustavima za prepoznavanje lica, automatsko prevođenje jezika i dijagnosticiranje bolesti iz medicinskih slika. Kod upravljanja zračnim prometom duboko učenje primjenjuje se prvenstveno za analizu velikih količina podataka, čime se poboljšava preciznost predikcija i donošenje odluka. Ortner i sur. (2022) navode kako duboko učenje može pomoći u predikciji sukoba u zračnom prometu, što omogućuje pravovremene i učinkovite intervencije za izbjegavanje nesreća. Nadovezujući se na prethodno, duboko učenje uz pomoć specijaliziranih algoritama uspješno omogućava analizu podataka radara i senzora kako bi se otkrile potencijalne prijetnje i anomalije u zračnom prostoru. Pinska-Chauvin i sur. (2023) istražuju kako se duboko učenje koristi za automatsko prepoznavanje govora u kontrolnom okruženju, čime se poboljšava komunikacija između pilota i kontrolora leta. Još jedna prednost koja se ističe kod ove podvrste strojnog učenja je značajka da duboko učenje prikuplja informacije iz sirovih podataka i automatiziranim procesom uči relevantne značajke, čime se smanjuje potreba za ručnim inženjeringom. S druge strane, duboko učenje također zahtijeva velike količine podataka i računalne resurse za obuku modela, što može predstavljati izazov u praksi (Patriarca i sur., 2022).

Nadalje definirajući osnovne pojmove umjetne inteligencije i sisteme koji omogućuju da ona ispravno djeluje, neizostavno je osvrnuti se na računalni vid (*engl.* computer vision) koje predstavlja još jedno područje unutar umjetne inteligencije koje se bavi razvojem algoritama koji omogućuju računalima da interpretiraju i razumiju vizualne informacije iz svijeta. Ovo ključno područje u upravljanju zračnim prometom ima široki opseg djelovanja poput prepoznavanja raznih objekata u zraku pa sve do analize snimaka s kamera za poboljšanje sigurnosti i efikasnosti operacija. Prema Zhang i Zhou (2019), računalni vid ima ključnu

ulogu u modernizaciji upravljanja zračnim prometom. Korištenje tehnologija računalnog vida omogućava precizno praćenje i analizu kretanja zrakoplova, što značajno doprinosi sigurnosti i efikasnosti zračnog prometa. Implementacija naprednih algoritama računalnog vida može pomoći u automatskom otkrivanju i predviđanju potencijalnih opasnosti, što je ključno za smanjenje rizika od nesreća. Ortner i sur. (2022) navode da ključna primjena računalnog vida u zračnom prometu omogućava automatsko prepoznavanje objekata, situacija, a algoritmi mogu analizirati snimke iz bespilotnih letjelica, aviona, nadzornih kamera sa aerodroma, čime se mogu identificirati i pratiti objekti, drugi zrakoplovi, vozila na tlu i potencijalne prepreke. Takav način djelovanja koristi se za poboljšanje sigurnosti i pravovremene intervencije. Kada se priča o načinu na koji računalni vid pospješuje sigurnost, primjer može biti nadzor pokreta zrakoplova i vozila na pistama i stazama za vožnju, kako bi se smanjili rizici od sudara i povećala efikasnost operacija.

Patriarca i sur. (2022) ističu da računalni vid može pomoći u optimizaciji rasporeda letova te boljoj zemaljskoj koordinaciji čime se podiže ukupna učinkovitost aerodroma. Sljedeća važna primjena računalnog vida je praćenje sigurnosnih prijetnji. Pinska-Chauvin i sur. (2023) istražuju kako računalni vid može poboljšati sigurnosne protokole kroz automatsko prepoznavanje sumnjivih objekata i ponašanja, što omogućuje brže i preciznije reakcije sigurnosnog osoblja. Daljnja primjena računalnog vida omogućava analizu slike i identifikaciju i korekciju potencijalnih grešaka u operacijama, smanjujući potrebu za ručnim nadzorom i intervencijama. Liu i sur. (2019) naglašavaju da računalni vid može značajno smanjiti operativne troškove i povećati pouzdanost upravljanja zračnim prometom. Također, računalni vid povezan s dubokim učenjem otvara mogućnosti za stvaranje novih kognitivnih usluga koje poboljšavaju rad zračnog prometa. Aplikacije kao te obuhvaćaju optimiziranje ruta letova, prognoziranje vremenskih uvjeta i automatsko detektiranje mogućih sukoba među zrakoplovima. Ove tehnologije ne samo što povećavaju učinkovitost upravljanja zračnim prometom, već i unaprjeđuju sigurnosne standarde (Neto i sur., 2023).

Prirodno jezično procesiranje (engl. natural language processing, NLP) odnosi se na granu umjetne inteligencije koja omogućava računalima da prepoznaju, interpretiraju i generiraju ljudski jezik. Ovaj alat omogućava prepoznavanje ljudskog govora pomoću specijalnih algoritama čime se omogućava dvosmjerna komunikacija, na prirodan način. Korištenje NLP-a i drugih naprednih analitičkih tehnika omogućuje izgradnju okvira temeljenog na podacima

koji olakšava pronalaženje jezičnih obrazaca i korištenje unaprijed istreniranih jezičnih modela za klasifikaciju i ekstrakciju korisnih ograničenja i restrikcija zračnog prostora. Koristeći ovu tehnologiju, mogu se razviti alati koji će korisnicima zračnog prostora omogućiti bolje razumijevanje ograničenja. To rezultira poboljšanim planiranjem ruta i sigurnijim izvršavanjem letova. Tehnika poput prirodnog jezičnog procesiranja ima široku primjenu u upravljanju zračnim prometom. Kao neke od glavnih tehnika ove metode ističu se „Analiza Sintakse i Semantike“. Analiza sintakse uključuje razumijevanje strukture rečenica, dok analiza semantike uključuje razumijevanje značenja riječi i rečenica. Tehnike sintaktičke analize koriste se za prepoznavanje rečenica i identificiranje njihovih gramatičkih komponenti, a semantička analiza fokusira se na prepoznavanje entiteta, odnosa i koncepta unutar teksta (Pinska-Chauvin i sur., 2023).

Prepoznavanje entiteta (*engl.* named entity recognition, NER) proces je u kojem se klasificiraju ključni podaci unutar tekstualnih poruka, poput imena osoba, organizacija, mjesta, datumi i drugi specifični podaci. Kako piše Pradhan i sur. (2013), ova tehnika omogućava prepoznavanje entiteta u velikim tekstualnim korpusima, što olakšava pretraživanje informacija i automatsko sažimanje teksta. U kontekstu zračnog prometa izdvaja se više mogućnosti gdje je ovaj alat primjenjiv.

Tako Manning i sur. (2008) ističu da je automatsko prepoznavanje ključnih informacija kritično za smanjenje mogućnosti nesporazuma i povećanja brzine reakcije u hitnim situacijama. Prepoznavanje entiteta koristi se za analizu komunikacija između pilota i kontrolora leta. Uslijed promjena podataka o rasporedu letova, uvjeta na aerodromu, sustavi NER-a automatski prilagođavaju i ažuriraju podatke te na taj način smanjuju troškove i povećavaju operativnu učinkovitost (Collobert i sur., 2011). Kako bi se bolje razumjeli razni uzroci incidenata ili potencijalnih prijetnji, prepoznavanje entiteta igra vrlo bitnu ulogu u identifikaciji ključnih faktora poput vremenskih uvjeta, tehničkih kvarova i proceduralnih grešaka. Hobbs (1993) naglašava važnost prepoznavanja obrazaca u podacima o kvarovima opreme za predviđanje i prevenciju budućih problema.

Prema LeCun i sur. (2015) integracija NER-a sa ostalim tehnologijama UI omogućava još veću sinergiju i operativnu učinkovitost različitih procesa. Integracija s analizom vizualnih podataka iz nadzornih kamera na aerodromima, analiza slike, sve to doprinosi boljem

pregledu trenutnog stanja i razumijevanju situacija poput zagušenja na pisti ili mogućih sigurnosnih prijetnji. Sustavi poput prepoznavanja entiteta smanjuju potrebu za ručnom administracijom, čime se smanjuje opterećenje osoblja. Također, mogućnost pogreške je svedena na minimum, a reakcije su pravovremene i točne. Odluke se donose na temelju relevantnih i preciznih informacija (Pradhan i sur., 2013).

Strojno prevođenje (*engl.* machine translation, MT) tehnika je koja omogućava automatsko prevođenje teksta s jednog jezika na drugi koristeći računalne algoritme. U zračnom prometu strojno prevođenje se koristi radi olakšavanja komunikacije među globalnim sudionicima čime se povećava efikasnost operacija i smanjuje mogućnost nesporazuma. U međunarodnom zračnom prometu, piloti i kontroleri leta često govore različite jezike. Strojno prevođenje u tom slučaju može pomoći u prevladavanju jezičnih barijera, omogućujući brži i točniji prijenos informacija (Pinska-Chauvin i sur., 2023). Osim komunikacije u stvarnom vremenu, ovaj alat visoku primjenu ima i u prevođenju tehničke dokumentacije, sigurnosnih izvještaja i operativnih priručnika na različite jezike. Majić, Pavlin i Škurla Babić (2010) ističu kako je standardizacija procedura i priručnika na različitim jezicima važna za sigurnost i učinkovitost operacija. Također je poznata i uporaba strojnog prevođenja u obrazovne svrhe što omogućava standardizaciju obuke i jednaki pristup istim podacima, bez obzira na jezik. Prema Jurafsky i Martin (2009), strojni prijevodi se ponekad susreću sa poteškoćama u prepoznavanju specifičnog konteksta ili tehničke terminologije. Ovakve situacije mogu rezultirati pogrešnim ili dvosmislenim prijevodima, a u kritičnim situacijama i najmanja pogreška može nositi ozbiljne posljedice. Često se nameće potreba za dodatnom ljudskom kontrolom i provjerom radi osiguranja što veće točnosti i pouzdanosti. Kako tvrdi Majić (2018), iznimno je bitno osigurati preciznu komunikaciju u zračnom prometu, neometano sporazumijevanje između pilota i kontrolora leta da bi se operativni problemi ili sigurnosni incidenti sveli na minimum.

Generiranje prirodnog jezika (*engl.* natural language generation, NLG) podrazumijeva podskup umjetne inteligencije koji se bavi automatskom proizvodnjom koherentnog i razumljivog teksta na temelju ulaznih podataka. Reiter i Dale (2000), NLG definiraju kao „*proces pretvaranja informacija iz računalnih podataka u čitljiv jezik prirodnog jezika.*“ Odnosno, ova tehnologija omogućuje računalima da interpretiraju podatke i generiraju tekstualne izlaze koji su korisni za ljudski kadar čime im olakšavaju automatizaciju

izvještavanja, sažimanja informacija i generiranja odgovora u različitim kontekstima. Reiter i Dale (2000) također navode da se generiranje prirodnog jezika sastoji od nekoliko različitih faza. Prva faza odnosi se na planiranje sadržaja što uključuje odluke o tome koje informacije uključiti u tekstu, druga faza je mikroplaniranje i odnosi se na organizaciju informacija iz prve faze u logičku strukturu. Posljednja faza je generiranje rečenica i realizacija stvarnog teksta na temelju prethodno prikupljenih informacija. Iako korisna tehnologije, gledano s druge strane Majić (2018) ističe kako takvi generirani tekstovi ponekad mogu biti previše umjetni i mehanički, odnosno nedovoljno adekvatni. Takvi slučajevi po njegovoj pretpostavci smanjuju učinkovitost komunikacije i korisničko iskustvo. Osim toga Majić, Pavlin i Škurla Babić (2010) još ističu da u situaciji kada su uključene kompleksne teme ili situacije, izazov postaje još teži i ponekad automatizirani sustavi generiranja prirodnog jezika nisu dovoljno precizni. Automatizacija izvještavanja može značajno smanjiti vrijeme potrebno za izradu izvještaja, omogućujući osoblju da kompletan fokus prebaci na analizu i donošenje odluka. Automatska generacija sigurnosnih izvještaja pomaže u brzom distribuciji informacija relevantnim timovima, što poboljšava ukupnu sigurnost (Patriarca i sur. 2022).

NLG se koristi u velikoj mjeri i za generiranje informacija u stvarnom vremenu za obavještavanje putnika. Na taj način putnici dobivaju obavijesti o promjenama u rasporedu letova, kašnjenjima ili sigurnosnim uputama. Putica (2018) također naglašava kako umjetna inteligencija ulazi u razne aspekte ljudskog života i sve više se primjenjuje u različitim industrijama pa tako i zračnom prometu. Kako spominje, umjetna inteligencija i sustavi poput generiranja prirodnog jezika uvelike poboljšavaju učinkovitost operacija, automatizaciju, smanjuju nepotrebno trošenje vremena i povećavaju točnost.

2.3. Primjena umjetne inteligencije u analizi podataka u zračnom prometu

U transportnoj industriji, zračni promet svrstava se u skupinu najkompleksnijih i najkritičnijih područja. Sigurnost i učinkovitost glavni su preduvjeti za uspješno odvijanje zračnog transporta i zahtijevaju najvišu razinu posvećenosti i organiziranosti. Korištenjem ranije spomenutih naprednih poput strojnog učenja, dubokog učenja i drugih tehnika umjetne inteligencije, zračni promet postiže novu razinu operativne učinkovitosti.

Prvi primjer koji će se koristiti za analizu ovog segmenta umjetne inteligencije i njene primjene u upravljanju zračnim prometom biti će optimizacija rasporeda letova. Tako su Liu i

suradnici (2019) proveli analizu i predikciju incidenata programa kašnjenja na zemlji (*engl.* Ground Delay Program, GDP). Svrha njihovog istraživanja bila je razvoj i testiranje modela strojnog učenja, odnosno utvrđivanje kako se strojno učenje može koristiti za optimizaciju rasporeda letova kroz analizu i predikciju incidenata programa kašnjenja na zemlji. GDP program se koristi za upravljanje prometnim opterećenjem na aerodromima posebice prilikom vremenskih nepogoda i drugih situacija kada je vjerojatnost nastanka kašnjenja povećana.


Kao ključne ciljeve Liu i suradnici (2019) su definirali sljedeće:

- Predikcija incidenata odnosno lociranje ključnih pretpostavki koje utječu na pojavu GDP-a te njihova kvantifikacija
- Optimizacija operacija koja podrazumijeva poboljšanje operativnih odluka, smanjenje kašnjenja, povećanje efikasnosti upravljanja zračnim prometom
- Analiza performansi modela. Evaluacija raznih modela kako bi se utvrdilo kojim se može najpreciznije odrediti pristup za predikciju incidenata GDP-a
- Implementacija odnosno kako se razvijeni modeli mogu integrirati u realnu sliku upravljanja zračnim prometom.

Istraživanje utjecaja vremenskih uvjeta i potražnje na dolazne letove Liu i sur. (2019) su proveli uporabom algoritama podržanih vektorskih strojeva (SVM). Ovaj model koristi agregaciju više odluka kako bi poboljšao točnost predikcija u složenim sustavima poput upravljanja zračnim prometom. Autori su također koristili modele logističke regresije i „Slučajnih šuma“ (Random Forest) za predikciju GDP-a, pri čemu model „Slučajnih šuma“ pokazuje bolje performanse. Ovaj model sastoji se od skupa stabala odluka, svako stablo daje svoju predikciju, a konačni rezultat dobije se agregacijom rezultata svih stabala (glasovanje/prosjek). Ovaj pristup smanjuje varijaciju modela i poboljšava njegovu sposobnost generalizacije novih podataka. Liu i suradnici (2019) prikupljaju podatke o vremenskim uvjetima, dolaznim letovima i ostalim faktorima koji ukazuju na vjerojatnost pojave GDP-a. Prednost ovog modela je mogućnost donošenja predikcija visoke preciznosti zbog svoje sposobnosti da se nose s nelinearnostima i interakcijama među varijablama. Breiman (2001), jedan od tvoraca modela Slučajnih šuma u svom istraživanju detaljno opisuje kako se može povećati točnost predikcija kombiniranjem rezultata mnogih stabala odluke treniranih na različitim podskupovima podataka. Ova metoda smanjuje varijaciju i pretreniranost, čime se postiže robusniji i precizniji model. Prema Dudeku (2022), "Random

Forest" se ističe kao jedan od najprepoznatljivijih modela strojnog učenja kada je riječ o zadacima klasifikacije i regresije.

Slika 1. Random Forest (Model Slučajnih šuma)



Izvor: Preuzeto sa <https://medium.com/@denizgunay/random-forest-af5bde5d7e1e> (pristupljeno 5. lipnja 2024.)

Temeljem rezultata provedenog istraživanja Liu i sur. (2019) zaključuju kako primjena strojnog učenja može značajno unaprijediti analizu i upravljanje zračnim prometom, posebice u slučaju programa kašnjenja na zemlji.

Drugi primjer koji će se analizira vezano za primjenu umjetne inteligencije u analizi podataka u zračnom prometu odnosi se na analizu sigurnosnih incidenata. Automatska analiza podataka iz izvještaja o sigurnosnim incidentima, senzora u avionima i komunikaciji između pilota i kontrolora leta pomaže u bržem otkrivanju potencijalnih problema i omogućuje pravovremene intervencije za sprječavanje nesreća (Patriarca i sur., 2022). Ove tehnike koriste obradu prirodnog jezika i prepoznavanje govora kako bi identificirali probleme, a prema Pinska-Chauvin i suradnicima (2023), automatsko prepoznavanje govora može poboljšati sigurnost na način da umjetna inteligencija prepozna ključne fraze i abnormalnosti u komunikaciji. Studija Degasa i suradnika (2022) analizirala je primjenu umjetne inteligencije u upravljanju

zračnim prometom s posebnim naglaskom na eXplainable AI (XAI). Integracija takvog sustava poboljšava povjerenje operatera u sustave i omogućava bolje donošenje odluka. Pri tome se koriste XGBoost algoritam i radi kombinacija s SHapley Additive exPlanations (SHAP) i Local Interpretable Model-Agnostic Explanations (LIME) za generiranje post-hoc objašnjenja odluka modela. SHAP se koristi kao metoda za lokalno objašnjenje modela strojnog učenja u zračnom prometu. Kroz primjenu teorije igara, ova metoda proučava važnost aditivnih značajki za svaku posebnu predikciju kako bi operatorima zračnog prometa omogućila razumijevanje utjecaja individualnih karakteristika modela (Strumberger i suradnici, 2023). Ključni cilj ovog modela je napraviti bolju integraciju između ljudskog faktora i umjetne inteligencije i olakšati donošenje odluka na način da XAI modeli generiraju takva rješenja koja ljudski operateri razumiju i uspješno implementiraju. Primjena kombinacije XGBoost algoritma s SHAP metodologijom koristi se kako bi se unaprijedila predikcija vremena polijetanja zrakoplova. Upotreba ove kombinacije algoritama omogućava temeljitu analizu i razumijevanje bitnih faktora koji utječu na kašnjenja u zračnom prometu. To je ključno za poboljšanje optimizacije operacija u zračnom prometu (Dalmau Codina i sur., 2021).

XAI modeli povećavaju transparentnost odluka donesenih pomoću sustava umjetne inteligencije omogućujući ljudskim operaterima da bolje razumiju razloge iza predloženih akcija. Prema Degas i suradnicima (2022) takva rješenja povećavaju povjerenje ljudskih operatera u umjetnu inteligenciju što omogućava daljnje prihvaćanje i učinkovitu integraciju ovih tehnologija u svakodnevne operacije.

Sljedeća primjena umjetne inteligencije u analizi podataka u zračnom prometu odnosi se na sustav analize kvarova. Ovaj sustav predstavlja značajan korak u unaprjeđenju sigurnosti i učinkovitosti u održavanju zrakoplova. Prema istraživanju Aviation Maintenance Magazine (2024), sustavi umjetne inteligencije i strojnog učenja uspješno detektiraju razne anomalije u zrakoplovima. Također vrlo bitna stavka ovog istraživanja je i prediktivno održavanje zrakoplova i mogućnost prepoznavanja i otklona kvarova prije nego se on i pojavi. Algoritmi su sposobni odrediti opseg popravka, odnosno je li to inspekcija, testiranje, popravak ili remont. Isto tako određuju koji je materijal potreban za popravak dijelova i recertifikaciju komponenti prema zahtjevima zračnog prometa.

Prikupljanje podataka: informacije vezane za brzinu zrakoplova, visinu leta, parametre motora, potrošnja goriva i mnoge druge. Podatke poput ovih sustavi umjetne inteligencije bilježe putem brojnih integriranih senzora. Tako Boeing 787 tijekom jednog leta memorira više od 0,5 terabajta podataka (Aviation Maintenance Magazine, 2024). Svi prikupljeni podaci se svrstavaju u jedinstveni sustav za analizu gdje se prati ukupno stanje zrakoplova i usklađuju informacije dobivene od svih senzora. Čišćenje i normalizacija podataka podrazumijeva da se nepotpune, netočne informacije odbacuju, dok se ostali podaci obrađuju kako bi se osigurala uniformiranost i mogućnost usporedbe. Pri tom se od analitičkih tehnika koriste: strojno učenje (Random Forest), duboko učenje, potporni vektorski strojevi (SVM) – predikcija kvarova, prepoznavanje obrazaca. Vizualizacija podataka se vrši pomoću grafova, dijagrama, interaktivnih ploča, omogućava lakši pregled i razumijevanje podataka.

Ucar i sur. (2024) navode kako analiza putem senzorskih podataka omogućuje ranu identifikaciju potencijalnih sigurnosnih prijetnji. Intervencije u ranoj fazi nastanka problema i preventivne mjere poboljšavaju ukupnu sigurnost operacija. Bansal (2024) naglašava kako analiza velikih skupova podataka poboljšava i optimizaciju upravljanja zalihama i logističkim operacijama, osigurava dostupnost potrebnih dijelova u pravo vrijeme čime smanjuje troškove i zastoje. U daljnjem proučavanju analize velikih skupova podataka i prediktivne analitike izdvajaju se neki primjeri iz prakse:

1. Delta Air Lines.

Kako tvrdi Aviation Today (2024), neplanirani zastoji zrakoplova smanjeni su za 15-20% radi redovne kontrole i nadzora zrakoplova putem senzora umjetne inteligencije

2. United Airlines.

Aviation Maintenance Magazine (2024) s druge strane tvrdi da praćenjem performansi motora i drugih kritičnih sustava troškovi održavanja smanjuju se za 10%.

3. Lufthansa Technik.

Razvoj platforme za prediktivno održavanje AVIATAR. Ova platforma koristi strojno učenje i analizu velikih skupova podataka za predviđanje kvarova i optimizaciju održavanja zrakoplova. Smanjenje neplaniranih održavanja za 30% (Lufthansa Technik Press Release, 2021).

4. EasyJet.

Sustavi održavanja temeljeni na tehnologijama umjetne inteligencije i IoT (Internet Of Things). Kako tvrdi IoT Now (2019), EasyJet smanjuje postotak kvarova za 50% i poboljšava operativnu učinkovitost. Suradnjom s Airbusom pokreću platformu Skywise. Platforma djeluje na način da prikuplja podatke iz FOMAX (Flight Operations and Maintenance Exchanger) sustava koji je instaliran na zrakoplovima i zatim prikupljene podatke analizira. Informacije se prikupljaju iz više od 24,000 parametara. Osim podataka iz realnog vremena, također se koriste i povijesni podaci iz razloga da se spriječe i bolje predvide mogući budući kvarovi. Do sada je razvijeno i kalibrirano 13 modela, dok je u izradi još 87. Takav način pristupa održavanju omogućilo je EasyJetu izbjegavanje 35 otkazivanja i 12 manjih kašnjenja samo u razdoblju od jednog mjeseca. Ovakav pristup doveo je i do uštede goriva i boljeg iskustva putnika. Prema tvrdnjama Aviation Week (2022), reducirana je i komponenta AOG (Aircraft On Ground) što ukazuje na smanjenje zastoja zrakoplova zbog raznih tehničkih kvarova.

2.4. Automatizacija i autonomija umjetne inteligencije u zračnom prometu

Tehnološki napredak u računalnim sustavima, sensorima, preciznom pozicioniranju i navigacijskim informacijama te drugim područjima omogućava razvoj i rad sve autonomnijih sustava i vozila za različite primjene na zemlji, u svemiru, na moru i u zraku (National Research Council, 2014). Gledajući kompletan sustav i inovativnost u razvoju umjetne inteligencije, izražene su brojne prednosti koje ona pruža poput povećanja produktivnosti, sigurnosti, smanjenja troškova operativne učinkovitosti, veća pouzdanost. Uz sve prednosti i dalje su vidljivi i određeni nedostaci koje ovaj sustav kao takav ima. Autonomija je osigurana, ali u slučajevima neadekvatne implementacije dolazi do značajnog smanjenja sigurnosti i pouzdanosti. Takve situacije mogu biti kritične kada se priča u kontekstu civilnog zrakoplovstva zbog visokih standarda sigurnosti i pouzdanosti, ali također i rizika za javnu sigurnost kada performanse novih tehnologija ili sustava za civilno zrakoplovstvo ne ispunjavaju očekivanja. Kako tvrde Beckman i suradnici (2020), uvođenje automatizacije i autonomije u zrakoplovne sustave povećava sigurnost i mobilnost te ekonomske koristi za milijun ljudi, ali brojni tehnički pristupi ne slijede holistički pristup. U tom smislu nailazi se na mnoge izazove povezane s terminologijom, certifikacijom, regulacijama. Također tvrde kako rješenja nekih od ovih izazova neće biti dovoljna za prijelaz zrakoplovstva na visoku razinu automatizacije i autonomije u budućnosti. National Research Council (2014) navodi

tehnološke prepreke koje bi mogle utjecati na potpunu autonomiju i automatizaciju umjetne inteligencije poput kiberfizičke sigurnosti, odnosno sustavi UI u zraku koriste sve povezanije mreže i sve složenije softvere pa su kao takvi sve više ugroženi i izloženi potencijalnim kiberfizičkim napadima što ugrožava sigurnost i pouzdanost. Također smatraju kako će biti teško inženjerski uklopiti moderne sustave umjetne inteligencije da budu kompatibilni sa starim modelima zrakoplova. Takva integracija čovjeka i stroja zahtijevala bi i potrebu da rade zajedno i na nove načine koji još nisu u potpunosti identificirani. Kako funkcije upravljanja zračnim prometom postaju sve automatiziranije, većinu funkcija će i dalje obavljati timovi ljudskih i strojnih agenata koji zajedno rade na osiguravanju sigurnih, urednih i brzih operacija. To vrijedi duž cijele skale automatizacije gdje neke funkcije ili aktivnosti mogu zahtijevati takvu suradnju, odnosno neke nadzornu ulogu ljudskog agenta, dok druge funkcije i aktivnosti mogu biti jednako dobro izvedene bilo od strane ljudskih ili strojnih agenata (NASA Aviation Systems, 2020).

Napredak tehnologije i integracija umjetne inteligencije u upravljanje zračnim prometom također će se odraziti i na ostale aspekte povezane sa ovom temom. Budućnost zračnog prometa ogleda se i u moderniziranju i uvođenju aspekata umjetne inteligencije i u pametne zračne luke. Yaqoobi (2020) definira pametne zračne luke kao središnji dio međusobno povezanog gradskog područja s pridruženim pametnim tehnologijama, inteligentnom infrastrukturuom i inteligentnom mobilnošću. Nadalje, pametna zračna luka je okruženje bogatim podacima, ispunjena raznim sensorima i drugim uređajima koji omogućuju putniku interakciju sa gotovo svakim objektom. Zračne luke predstavljaju temeljni dio lanca vrijednosti zračnog prijevoza. One se moraju kontinuirano prilagođavati tehnološkim zahtjevima različitih dionika koji sudjeluju u sektoru. Stoga je ključno modernizirati zračne luke kako bi se poboljšao prolaz putnika uz pružanje kvalitetnijeg iskustva i povećanje zadovoljstva (Bao i sur., 2016).

Glavni cilj pametnih zračnih luka je pružiti putnicima brzo i sigurno putovanje, poboljšati cjelokupno iskustvo puta, smanjiti kašnjenja i otkazivanja, prekomjerna rezerviranja i gubitak prtljage jer sve su to događaji koji negativno utječu na percepciju kvalitete usluge kod putnika (Gregghi i sur., 2013). Brojni autori dotakli su se pametnih zračnih luka i raznih načina na koje one utječu na putnike. Tako Abdelaziz i sur. (2010) procjenjuju koristi tehnologija za korisnike u zračnim lukama uspoređujući pristup s tradicionalnim operacijama i opremom. S

druge strane Bogicevic i suradnici (2017) razvijaju alat koji bilježi percepciju putnika o novim tehnologijama u zračnim lukama i rade modele koji testiraju odnose između tih tehnologija i ljudi na način da ispituju povjerenje, zadovoljstvo i ostale aspekte. Ostala istraživanja bave se pitanjima poput kvaliteta usluga zračne luke, točnost letova, adekvatne i pravovremene informacije, učinkoviti sigurnosni postupci, odgovarajuće i jasne signalizacije (Chen i Chang, 2015; De Barros i suradnici, 2017; Fodness i Murray, 2007).

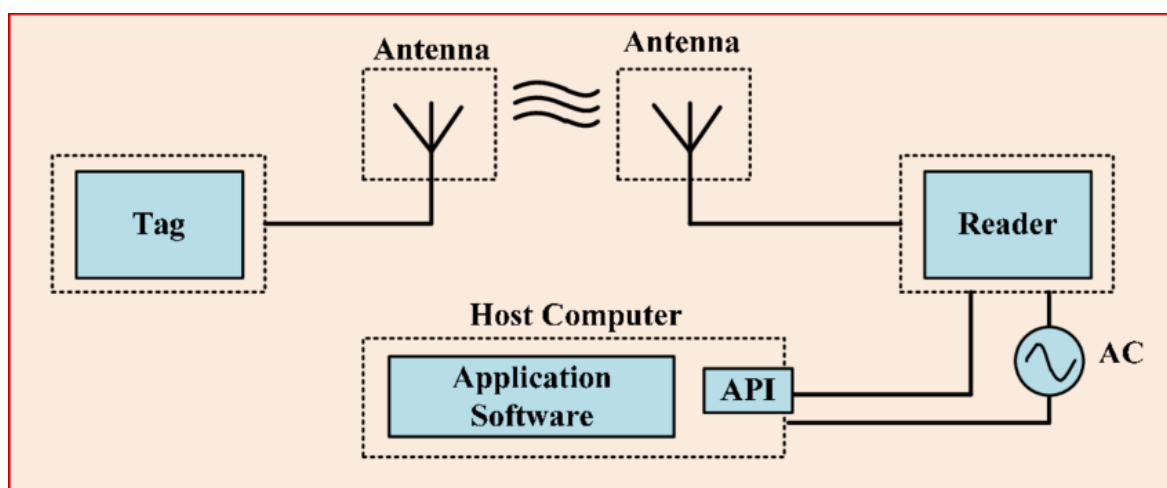
Yaqoobi (2020) navodi kako su pametne zračne luke prošle kroz četiri vala integracije pametne tehnologije i umjetne inteligencije. Ova četiri vala usko su povezana s usvajanjem viših razina automatizacije. Zračne luke se prema Yaqoobi (2020) razlikuju prema njihovom stupnju digitalne zrelosti, a temeljeno na ovim valovima digitalizacije. Također, ova četiri vala dovela su do evolucije četiri tipa zračnih luka (Nau i Benoit, 2017):

1. **Zračna luka 1.0.** Osnovne usluge za putnike, većina procesa se obavljaju ručno, implementacija IT-a ograničena i bazirana na specifičnim rješenjima poput CUTE (Common Use Terminal Equipment).
2. **Zračna luka 2.0.** Samoposlužne usluge, masovna primjena CUTE-a, bežične komunikacijske tehnologije.
3. **Zračna luka 3.0.** Operacije automatizirane, mobilnost i na strani terminala i na strani zračne luke, tehnologija samoposluživanja koristi se tijekom cijelog putovanja.
4. **Zračna luka 4.0.** Ovaj tip zračne luke naziva se još i pametna zračna luka. U potpunosti iskorištava snage transformacijskih tehnologija poput Interneta stvari (IoT), analize velikih podataka (big data), blok-lanaca (blockchain) i računalstva u oblaku (cloud computing) kako bi poboljšale iskustvo putnika i operativnu učinkovitost.

Tehnologija utječe na učinkovitost zračnih luka, doprinosi uštedi vremena, poboljšanju sigurnosti i usluge za putnike (Brida i suradnici, 2016). Jedan od sljedećih načina i primjera integracije pametne tehnologije u zračne luke su automatizirani sustavi za provjeru prtljage. Ovi sustavi koriste napredne tehnologije poput Internet stvari, umjetne inteligencije i raznih senzora kako bi optimizirali proces provjere. Prtljaga je opremljena radiofrekventnom identifikacijom (*engl.* Radio Frequency Identification, RFID), oznakama koje omogućuju praćenje u stvarnom vremenu i koje smanjuju šansu gubitka prtljage (Deloitte Insights, 2020).

U prošlosti je u uporabi bio bar kod koji se koristio za očitavanje prtljage. Problem bar koda ogledao se u sporom očitavanju, odnosno potrebno je doći u neposrednu blizinu prtljage kako bi se kod očitao, što predstavlja problem u novom bržem, efikasnijem i operativno kvalitetnijem sustavu automatizacije prtljage. Napredni sustavi skeniranja i analize provjeravaju svaki komad prtljage radi provjere potencijalnih prijetnji poput eksploziva ili zabranjenih predmeta. Na taj način povećava se ukupna sigurnost i smanjuje potreba za ručnom inspekcijom (AlMashari i suradnici, 2018). Potgieter (2020) piše kako se nakon provjere prtljaga automatski razvrstava prema destinaciji, prioritetu i drugim relevantnim kriterijima. Za to se koriste pokretne trake i roboti koji smanjuju ukupno vrijeme potrebno za obradu, a operativni troškovi se smanjuju. RFID tehnologija ulazi u uporabu i funkcionira na način da se prtljaga očitava pomoću radio valova. Na taj način uklanjaju se osnovna ograničenja bar kodova poput udaljenosti čitača, dotrajalosti naljepnice, prave pozicije očitavanja koda. RFID oznake i crtični kodovi sadrže važne informacije o prtljagi s kojom su povezani. Za razliku od bar koda, RFID čitači ne zahtijevaju izravnu vidljivost ispisanog crtičnog koda što znači da se oznake mogu čitati na puno većim udaljenostima do 100m ili više (Finkenzeller, 2004). Čitačima je obično potrebno pola sekunde da uspješno dovrše čitanje. Osnovni RFID sustav sastoji se od tri dijela: identifikator (uređaja zaštićenog od neovlaštenog otvaranja koji je trajno pričvršćen ili ugrađen), uređaja za aktiviranje i/ili očitavanje i softvera za elektroničko snimanje i prijenos podataka.

Slika 2. RFID komponente



Izvor: https://www.researchgate.net/figure/RFID-System-Components_fig1_308167938 (pristupljeno 5. lipnja 2024.)

Osim RFID-a, u automatiziranim sustavim za provjeru prtljage također se koristi i umjetna inteligencija, računalni vid i duboko učenje. Automatizirani sustavi koriste UI za analizu rendgenskih (X-ray) slika prtljage u stvarnom vremenu što omogućuje brzo i precizno prepoznavanje opasnih materijala (Liang i sur., 2019). Tradicionalni sustavi često zahtijevaju veći broj ručnih provjera zbog lažnih pozitiva na nedopuštena sredstva, stoga umjetna inteligencija smanjuje pojavu takvih pogrešaka na minimum. Vukadinović i suradnici (2022) napominju kako računalni algoritmi i umjetna inteligencija nema slabosti koje se mogu pojaviti kod ljudskih kadrova. Umjetna inteligencija ne nailazi na umor, dosadu, loš dan i ostale kritične varijable. Sudeći po tomu, UI predstavlja značajan korak u nastojanju da se sigurnost u zračnim lukama poveća i u potpunosti automatizira. Kako dalje navode, potencijalne primjene umjetne inteligencije u zračnom prometu mogu se podijeliti na tri osnovne kategorije: optimizacija operacija zračne luke, upravljanje zračnim prometom i sigurnosne primjene.

Operacije na pisti mogu uključivati automatiziranu video analizu koja poboljšava sliku i detektira objekte kroz područje ograničene vidljivosti i zaklonjenost. Na ovaj način uklanja se potreba za fizičkim kontrolnim tornjevima (NVIDIA, 2018). U nastavku se analiziraju dva primjera:

1. Primjer 1. - implementirano u zračnoj luci London Heathrow (Wolfe, 2020). Kako tvrdi inovacijska tvrtka Searidge Technologies, njihova platforma UI „Aimee“ sposobna je pojednostaviti proces konfiguriranja i obuke umjetnih neuronskih mreža s velikim i složenim skupovima podataka koji tada omogućavaju primjenu UI za zadatke poput praćenja slika i geolokacije zrakoplova. Time se osigurava da pista bude spremna sa slijetanje sljedećeg zrakoplova. Upravo na taj način je ova tehnologija implementirana u londonskoj međunarodnoj zračnoj luci Heathrow. Odnosno, kada se kontrolni toranj izgubi zbog oblaka ili magle, umjetna inteligencija naprednim vidom preuzima operacijsku kontrolu. To je ujedno i prvi u svijetu digitalni kontrolni toranj i u cilju mu je da se povrati 20 posto izgubljenog kapaciteta za slijetanje u zračnoj luci do kojeg je došlo zbog uvjeta slabe vidljivosti. Devet 4K kamera se nalazi na sjevernoj strani tornja i devet 4K kamera na južnoj strani čime se osigurava potpuna pokrivenost piste. Zapisi kamera se šalju uživo u sustav koji zatim interpretira fotografije, prati letjelicu te u konačnici obavještava kontrolora kada

uspješno napusti pistu. Osim Heathrowa i ostale zračne luke su spremne za integraciju ove tehnologije umjetne inteligencije.

2. Primjer 2. – sustav Aimee u međunarodnoj zračnoj luci Dubai. Sustav prati i detektira osoblje i događaje povezane s tipičnim procesom okretanja zrakoplova u stvarnom vremenu, uključujući praćenje kretanja mlaznog mosta, kamiona i servisnih vozila među ostalim radnim procesima. Ti se podaci zatim uspoređuju s povijesnim podacima povezanim s istim događajima kako bi se predvidjelo hoće li zrakoplov ispuniti planirano vrijeme polijetanja.

Slika 3. Prvi digitalni kontrolni toranj, Heathrow-London



Izvor: <https://www.aviationtoday.com/2020/06/29/how-searidge-uses-artificial-intelligence-to-revolutionize-airports-air-traffic-management/> (pristupljeno 7. lipnja 2024.)

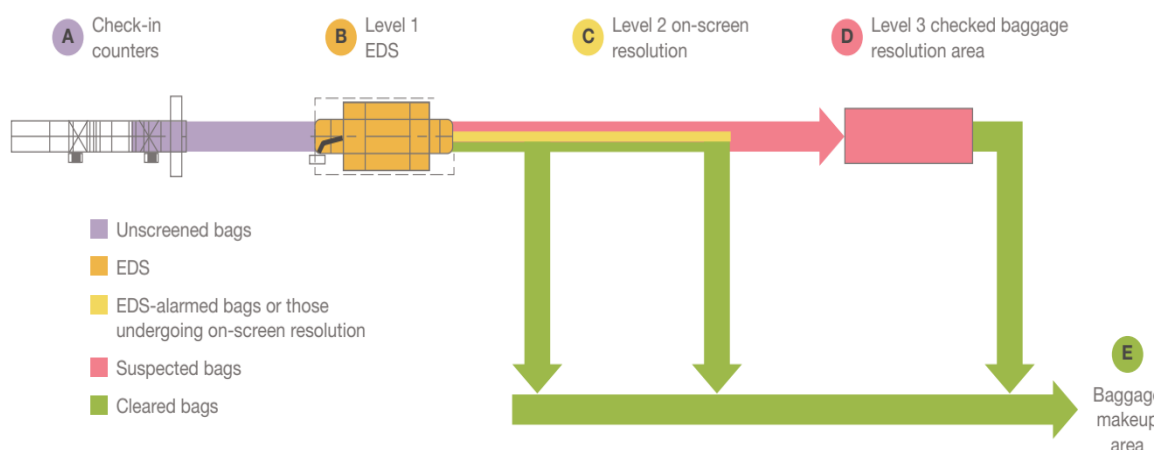
Optimizacija transfera putnika između izlaza – automatska raspodjela izlaza putnicima, sustavi umjetne inteligencije savjetuju putnike kako se optimalno kretati između izlaza koristeći podatke u stvarnom vremenu

Poboljšanje predviđanja putanje leta je ključna komponenta sustava za upravljanje zračnim prometom, ali je otežano zbog neizvjesnosti ruta uzrokovane budućim odobrenjima kontrolora zračnog prometa. Povećanjem tradicionalne logike predviđanja putanja pomoću strojnog učenja omogućava se značajno poboljšanje točnosti (Maastricht Upper Area Control Centre, 2018).

Sigurnosne primjene obuhvaćaju automatske sustave biometrijske identifikacije, uključujući prepoznavanje lica, šarenice i mrežnice, glasa, hoda, otisaka prstiju, linija trenja na koži, vena na ruci te geometrije ruke. Osim toga, automatsko otkrivanje sumnjivog ponašanja oslanja se na analizu verbalnih i neverbalnih znakova. U zračnim lukama, ovo se odnosi na prepoznavanje nesigurnosti u smjeru i brzini kretanja, povećane brzine, nepotrebnih zaustavljanja i pokreta. Na kontrolnim točkama, sustavi prepoznaju vizualne znakove poput pojačanog treptanja, vokalnih znakova, poput oklijevanja, grešaka u govoru, kraćih odgovora i višeg tona glasa. Također, automatsko otkrivanje opasnih predmeta uključuje pregledavanje putnika i njihove prtljage.

Zakon o zrakoplovnoj i transportnoj sigurnosti (Aviation and Transportation Security Act, Pub. L. 107-71, 2001) zahtijeva da Uprava za sigurnost u transportu pregledava sto posto prijavljene prtljage na aerodromima. Veliki dio procesa pregleda prtljage uključuje analizu digitalnih slika, moguće je da bi metode računalnog vida mogle biti korištene za poboljšanje sigurnosti zračnog prometa i učinkovitosti procesa pregleda. Pregled Uprave za sigurnost u transportu sastoji se od tri razine. Prva razina u potpunosti je automatizirana i tijekom ovog koraka, sustavi za otkrivanje eksploziva koriste rendgenske zrake i tehnologiju računalne tomografije za identifikaciju potencijalno prijetećeg materijala. Nakon prolaska prtljage kroz razinu jedan, dobiju se dva izlazna podatka: binarni indikator prijetnje (bilo da nema prijetećeg materijala ili da postoji potencijalno prijeteći materijal) i trodimenzionalna (3D) CT slika prtljage. Radi osiguravanja što veće sigurnosti da će prtljaga koja sadrži prijeteći materijal biti identificirana, mnoge bezopasne prtljage se označavaju kao potencijalno prijeteće. Nakon pregleda razine jedan, prtljaga se šalje na pregled razine dva koji se sastoji od pregleda 3D CT slike od strane stručno osposobljenog sigurnosnog operatera. Stručni operater traži znakove da je prtljaga bezopasna (tj. nije prijetnja i može biti ukrcana u zrakoplov) ili da je prtljaga prijetnja. Ako se prtljaga ne može odobriti na drugoj razini, prelazi na razinu tri. Posljednja i najkritičnija razina pregleda uključuje pregled 3D CT slike, testiranje na tragove eksploziva u i na prtljazi te ako je potrebno, fizičku inspekciju prtljage.

Slika 4. Generički sustav za pregled prijavljene prtljage u liniji



Izvor: TSA, 2020, str. 2-3. (pristupljeno 8. lipnja 2024.)

Kao što je ranije spomenuto, X-ray omogućuje brzo i precizno skeniranje prtljage. X-ray slike pomoću umjetne inteligencije moguće je poboljšati putem računalnih algoritama (Abidi i suradnici, 2006). Najkorištenija metoda za poboljšanje slika je smanjenje šuma slike, nakon čega slijedi pseudo-koloriranje. Smanjenje šuma postiže se korištenjem histograma (Chen i suradnici, 2005) detekcijom rubova i Gausovim zamučivanjem (Dmitruk i suradnici, 2017), te korištenjem Gaborovih filtera (Movafeghi i suradnici, 2020). Chen i suradnici (2005) prvotne pokušaje za smanjenje šuma slike pokušavali su na način da su kombinirali slike s niskom i visokom energijom X-zraka i primijetili oduzimanje pozadine za smanjenje šuma. Za adaptivno poboljšanje slike koristi se višeslojni perceptron, pri čemu model predviđa najbolju tehniku poboljšanja na temelju ulaznih i izlaznih slika (Singh i Singh, 2005). Govoreći dalje o metodama razumijevanja slika uočavaju se dvije primjene: prepoznavanje objekata i zadatak detekcije objekata. Kod prepoznavanja objekata, testne slike su već isječene i baziraju se samo na objekt od interesa (Bastan i suradnici, 2011), dok se kod metode detekcije objekata oni moraju identificirati na slici prtljage i klasificirati kao jedan od unaprijed definiranih tipova objekata (Franzel i suradnici, 2012).


Slika 5. Primjer pozitivnih (lijevo) i negativnih (desno) podataka za prepoznavanje objekata



Izvor: Turcsany i suradnici (2013)

Na slici 5 mogu se vidjeti rendgenske snimke različitih vrsta vatrenog oružja i srodnih objekata. Ovi objekti su prikazani u različitim pozicijama i kutovima kako bi bili što vjerniji prizoru pregleda prtljage u zračnoj luci. Slike koriste boje kao što su plava, zelena i narančasta da bi se razlikovali materijali kroz koje rendgenski uređaj prolazi, tako da je moguće vidjeti razliku između metala i drugih materijala. Obično se koristi slika ove vrste za obuku i testiranje sustava koji automatski detektiraju opasne predmete.

Slika 6. Primjer detekcije objekta, a) detektiran pištolj, b) torba bez prijetnji



Izvor: Bastan i suradnici (2011), Bastan (2015)

Na slici 6 se mogu vidjeti rendgenski snimci dva kofera. Na slici (a) vidi se kofer u čijoj je unutrašnjosti vidljiv predmet koji podsjeća na pištolj, smješten unutar pravokutnog okvira. Na slici (b) prikazan je kofer s većim elektroničkim uređajem, možda računalom ili nekom vrstom elektroničke ploče, bez ikakvih dodatnih oznaka na površini. Različiti materijali imaju različite boje na rendgenskim snimkama, koje su karakteristične za ovu vrstu pregleda.

3. UMJETNA INTELIGENCIJA U UPRAVLJANJU ZRAČNIM PROMETOM

Uloga i primjena umjetne inteligencije u upravljanju zračnim prometom nedvojbeno je sve veća i važnija. Do sada se spominjala primjena umjetne inteligencije u raznim područjima u okviru zračnog prijevoza od prediktivne analitike, strojnog učenja, pametnih zračnih luka, raznih automatiziranih sustava. Iduća poglavlja će se bazirati na primjenu umjetne inteligencije u područjima kao što su prediktivna analitika i upravljanje rizicima, analiza podataka o letovima kroz umjetnu inteligenciju, sigurnost u zračnom prometu kroz umjetnu inteligenciju te primjenu umjetne inteligencije u razvoju novih tehnologija u zračnom prometu.


3.1. Prediktivna analitika i upravljanje rizicima

Evaluacija složenih sustava poput sustava za upravljanje zračnim prometom izazovan je zadatak i vrlo je važno koristiti ispravne matematičke modele unutar analize. Zrakoplovstvo se promatra kao vremenski kontinuiran sustav mjeran u vremenskim serijama s diskretnim vrijednostima poput pokazatelja performansi i određenih metrika. Osnova za prediktivnu analitiku je prikupljanje podataka. Prema Liu i suradnicima (2019), analiza velikih skupova podataka omogućuje precizno identificiranje obrazaca u zračnom prometu, što je ključno za prediktivnu analitiku. Algoritmi strojnog učenja razvijaju prediktivne modele koji mogu predvidjeti buduće događaje s velikom točnošću. Reitmann i Schultz (2022) ističu kako primjena algoritama strojnog učenja omogućuje precizne predikcije koje pomažu u optimizaciji operacija i povećavanju sigurnosti. Netočne predikcije mogu značajno utjecati na razne faktore poput povećan broj sukoba u zraku, povećano opterećenje kontrolora i smanjujući kapacitet njihovog sektora, neučinkovito trošenje goriva zbog stalnih odstupanja, negativan utjecaj na okoliš zbog većeg sagorijevanja goriva što dovodi do više emisija. Prediktivna analitika pomaže u održavanju dijelova aviona.

Zrakoplovni motori

Vrlo su složeni i skupi za održavanje te kao takvi čine 35-40% ukupnih troškova održavanja zrakoplova (Ackert, 2011). Turboventilatorski motori (vidi Slika 7) mogu sadržavati velike skupove senzora koji bilježe brojne podatke prilikom rada motora koji se tiču temperature i tlaka na ulazu ventilatora te fizičku brzinu ventilatora (Wu i sur., 2019).

Slika 7. Turboventilatorski motor



Izvor: <https://www.mdpi.com/1424-8220/20/22/6626> (pristupljeno 13. lipnja 2024.)

Ležajevi zrakoplova

Ležajevi su komponente koje smanjuju trenje između pokretnih dijelova koji se kreću u odnosu na željenu os. Ležajevi se u zrakoplovima obično nalaze u motorima, stajnom trapu, hidrauličkim pumpama za gorivo, vratima i kontrolama kokpita. Ova komponenta je iznimno važna i neophodna je njezina potpuna pouzdanost. Kvar ležaja može potencijalno ugroziti veliki broj života. Mjerenje kvalitete ležajeva pomoću senzora može biti teško stoga se koriste mjerenja temperature, vibracija i akustike za procjenu njihovog stanja (Franz-Josef E., 2007). NA slici 8 prikazani su ležajevi stajnog tipa.

Slika 8. Ležajevi stajnog trapa




Izvor: <https://www.envirofluid.com/articles/aviation-landing-gear-and-wheel-bearing-maintenance/> (pristupljeno 12. lipnja 2024.)

Hidraulika i pneumatika

Hidraulika je mehanička funkcija koja djeluje pomoću sile pritiska tekućine. Mehanički pokret se proizvodi na način da se tekućina pumpa, obično kroz cilindre koji pomiču klipove. Ovakvi sustavi se često nalaze i u građevinarstvu, automobilskoj industriji, ali također i u zrakoplovima, gdje se iskorištava veća količina snage koja se može generirati u usporedbi s pneumatikom. U zrakoplovima hidraulika svoju primjenu pronalazi u mnogim područjima poput stajnog trapa, vodova za gorivo i pumpe pokretane motorom (vidi sliku 9).

Slika 9. Hidraulički sustav zrakoplova



Izvor: <https://blog.brennaninc.com/the-significance-of-pressure-and-temperature-in-aerospace-hydraulics> (pristupljeno 12. lipnja 2024.)

Trup

Zrakoplovni trup podložan je brojnim mogućim oštećenjima. Trup mogu oštetiti naleti ptica, udari munje, ali i degradiranje kako prolazi vrijeme. U posljednjih nekoliko godina, čestični (Yousuf i sur., 2017) i Kalmanovi filteri (Wang i sur., 2017) korišteni su za procjenu i predviđanje veličine oštećenja i pukotina na okviru i krilima zrakoplova. Na taj način postignuta su brojna smanjenja troškova. Osim toga, za praćenje stanja trupa koriste se i senzori koji vrše promatranje i analizu (vidi Slika 10).

Slika 10. Senzori na trupu zrakoplova



Izvor: <https://mondortiz.com/the-different-external-sensors-found-on-planes/>
(pristupljeno 12. lipnja 2024.)

3.2. Analiza podataka o letovima kroz umjetnu inteligenciju

Sve više dolazi do važnosti uloga umjetne inteligencije u analizi podataka o letovima na način da zračnim prijevoznicima pomogne u optimiziranju operacija, povećanju učinkovitosti te u konačnici povećanju sigurnosti zračne plovidbe. Korištenjem algoritama strojnog učenja mogu se predvidjeti razni događaji poput kašnjenja letova, rasporeda, identifikacija i prevencija sukoba i drugih bitnih elemenata. Napredna tehnologija osigurava preciznu i robusnu analizu i pruža točne i lakše razumljivije informacije u stvarnom vremenu. Na taj način zrakoplovne kompanije mogu iskoristiti specifično znanje za domenu te pružiti dodatnu analizu.

Zračna industrija se temeljito promijenila kao rezultat deregulirajućih zakona, posebno Zakona o deregulaciji zračnih prijevoznika iz 1978. godine u SAD-u koji je ukidao savezne vlade nad mnogim aspektima industrije i doveo do uspostavljanja slobodnog tržišta (Scharpenseel, 2001). Isto tako, Europska unija prošla je kroz procese deregulacije počevši od 1990-ih, s vrhuncem u trećem paketu deregulacija 1993, kojima se omogućava zrakoplovnim kompanijama besprekidan ulaz na sve linije leta bez ikakvih ograničenja vezanim za cijene.

Cijene karata

Određivanje taktike cijena avionskih karta prošle su proces evolucije od jednostavnijih pa do onih složenijih modela koji uključuju dinamičko određivanje cijena i svijest o konkurenciji.

Napredne politike izračunavanja cijena razvile su se koristeći mehanizam strojnog učenja (ML) kao što je regresijska analiza i potkrepljeno učenje (RL) (Tian i suradnici, 2021). Određivanje cijena zrakoplovnih karata strategija je koja određuje broj i vrstu cjenovnih proizvoda ponuđenih na različitim tržištima. Cijene su za svaki proizvod precizno određene, koriste se često i razni skupovi ograničenja, što rezultira ograničenjima u broju sjedala koja se mogu prodati po određenim cijenama.

Dinamično određivanje cijena

Zrakoplovne kompanije imaju potencijal povećati ukupne prihode na način da primjenjuju različite razine ograničenja kako bi ponudile proizvode više cjenovne klase. Tipični proizvodi dinamičkog određivanja cijena imaju tri karakteristike (Tian i sur., 2021):

1. Proizvodi imaju fiksni redoslijed i količinu
2. Prodaja završava s određenim rokom
3. Marginalni trošak prodaje jednog dodatnog proizvoda je nizak.

Kada su se pojavile internetske putničke agencije i niskotarifni prijevoznici, zrakoplovne kompanije bile su prisiljene uzeti u obzir konkurenciju pri određivanju cijena karata što se odnosi na mnoge faktore koji su povezane s kartom, kontrolom inventara, modelima ponašanja kupaca i drugim konkurentskim atributima i parametrima (Ratliff i Vinod, 2005). Na slici 12 može se vidjeti na koji način umjetna inteligencija pomaže u potrazi za najjeftinijom opcijom i na taj način olakšava korisniku često kompliciranu i skupu potragu za što isplativijom opcijom. Snižavanje cijene karata nije jednostavna odluka jer određivanje cijena bez ograničenja (bilo previsoke ili preniske) može rezultirati gubitkom kupaca ili negativnim prihodom. Ponekad je bolja opcija pustiti da let ode s praznim sjedalima. Zrakoplovne kompanije koriste brojne strategije kojima je glavni cilj donošenje odluka. Identifikacija kupaca i tržišna segmentacija ključna je za bolje donošenje odluka i upravljanje prihodima te se koriste razne tehnike klasteriranja u strojnom učenju, algoritmi particioniranja (klasteriranje temeljeno na centroidima). Pritscher i Feyen (2001) navode kako se kupci koji putuju zrakoplovom mogu se segmentirati prema tipovima ovisno koliko često kupuju karte, ali i prema svrsi putovanja koje može biti rekreativno ili s druge strane poslovno. Uz uporabu klasičnog klasteriranja kao što je „K-means“, definirano je šest segmenata kupaca na temelju obilježja njihova ponašanja tijekom putovanja. To su segmenti koji uključuju „srednji broj putovanja“, „nekoliko vikend letova“, „bez povratnih letova“ i tako dalje. Za

konceptualizaciju strategija popusta koje koriste zrakoplovne kompanije, koristili su se nelinearni regresijski modeli i analiza klasteriranja. Kako bi predstavili karakteristike sjedala, autori su prvo odabrali nekoliko normaliziranih varijabli kao što su broj dana prije leta, trajanje putovanja i kapacitet aviona. Nakon toga su odlučili primijeniti analizu klastera na te varijable kako bi pronašli strategije za određivanje cijena, što je rezultiralo identifikacijom četiri rješenja. Za svaku grupu tarifa, od najjeftinijih do najskupljih, postoji mogućnost primijene zasebne strategije u ovim četiri klasterima. Kao završni korak, „logit“ model je razvijen radi opisa ključnih karakteristika koje utječu na konačnu sniženu cijenu (Obeng i Sakano, 2012). Općenito, K-means se smatra kao jednostavna i efikasna metoda klasteriranja koja je pogodno primjenjiva na obimne skupove podataka zrakoplovnih tvrtki. No, preduvjet za korištenje je poznavanje broja klastera (K) i algoritam je vrlo osjetljiv na iznimke. Hijerarhijsko klasteriranje je informativnije od algoritama particioniranja, jer omogućuje lakše otkrivanje broja segmenata putem stablastih dijagrama. Ova značajka ima važnost u raznim primjenama u zrakoplovstvu gdje je broj klastera nepoznat.

Dai i suradnici (2012) su koristili hijerarhijsko klasteriranje kako bi segmentirali tržište povezano s opstankom zrakoplovnih operatera. Studija razvrstava operatere u sedam grupa, koje obuhvaćaju „Lokalno neefikasne“, „Kratke rute“, „Male efikasne“, „Domaće efikasne“, „Bez domaćih letova“, „Duge domaće rute“ i „Međunarodne“. Također, istražena je veza faktora opterećenja kao ključnog parametra za razlikovanje tih segmenata i opstanak svakog operatorskog klastera. Ipak, zbog visoke vremenske složenosti, hijerarhijsko klasteriranje nije pogodno za obrađivanje velikih podataka. U 2015. godini Piggott je koristio nekoliko algoritama klasteriranja kako bi identificirao tržišne segmente i moguće poslovne putnike. Među njima su K-means, X-means (kao alternativa za K-means), Expectation-Maximization (EM) te hijerarhijsko klasteriranje. Gore navedene tehnike klasteriranja su se pokazale učinkovitima za segmentaciju putnika i analizu tržišta prema rezultatima. U toj studiji, EM algoritam je pokazao najbolje rezultate u klasteriranju. Od ranih 2000-ih, počeli su se koristiti pristupi strojnog učenja, kao što je regresijska analiza i učenje potkrepljenja (RL), kako bi se pružila analitička podrška za razvijanje naprednih politika. Ukoliko veza između odgovornih i objašnjavajućih varijabli nije linearna i ne može se opisati putem jednostavne linearne regresije (LR), tada LR može biti neadekvatna u tim slučajevima. Prema den Boeru (2015), kako bi se dobila preciznija analiza i opisali podaci zrakoplovne industrije koji pokazuju nelinearnost, primijenjeni su generalizirani linearni modeli (GLM).

Primjena modela dvostupanjskih najmanjih kvadrata (2SLS)

Kako bi se prevladala ograničenja modela običnih najmanjih kvadrata (OLS) pri procjeni elastičnosti cijena, primijenjen je dvostupanjski model najmanjih kvadrata (2SLS). Model 2SLS pri izračunu elastičnosti cijena uzima u obzir karakteristike letova, rezervacije i prodaje te promotivne aktivnosti konkurencije. Istraživanje je ograničeno na specifičan uzorak s više od četvrtine nedostajućih podataka o cijenama i potražnji (Mumbower, Garrow i Higgins, 2014), međutim pokazano je da 2SLS može predviđati broj rezervacija za letove unaprijed kada se uzmu u obzir objašnjavajući čimbenici poput datuma polaska i tržišta. Istraživanje je ograničeno na specifičnu veličinu uzorka s više od četvrtine podataka o cijenama i potražnji koji nedostaju (Mumbower, Garrow i Higgins, 2014).

Primjena tehnika učenja potkrepljenja (RL)

Dodavanje dodatne dimenzije intuiciji u igri određivanja cijena rješava probleme koji su bili nerješivi konvencionalnim strategijama putem upotrebe tehnika učenja potkrepljenja. U 2012. godini Collins i Thomas su proveli paralelnu studiju koristeći dinamičnu igru određivanja cijena u zrakoplovnoj industriji kao primjer, istražujući razne RL algoritme poput Q-learninga, SARSA-e (State-Action-Reward-State-Action) i Monte Carlo učenje. U njihovim eksperimentima, Q-learning i SARSA su pokazali bolje rezultate od Monte Carlo pristupa. Prema Collinsu i Thomasu (2012) dodavanje dodatnih dimenzija modelu tijekom učenja moglo bi biti korisno za proces donošenja odluka, no važno je napomenuti da se te dimenzije mogu primjenjivati samo radi boljeg razumijevanja. Collins i Thomas (2013) su istraživali primjenu RL, posebno SARSA-a, u analizi kompleksnih ponašanja kupaca. Dok su koristili SARSA, raspravljalo se o tri nova aspekta vezana uz modeliranje kupaca: tražnja potrošača, odabir kupaca i obim tržišta. SARSA demonstrira sposobnost rješavanja složenih igara u zrakoplovnoj industriji i pruža obećavajuće rezultate učenja, što ga čini superiorinijim modelom od predviđanja potražnje (Collins i Thomas, 2013). Kada se razmišlja o vertikalnim odnosima u zrakoplovnoj industriji (kao što su proizvođači i prodavači), bitno je uzeti u obzir i druge situacije. I zrakoplovne kompanije (koje su proizvođači) i internetske putničke agencije (kao prodavači) imaju određenu kontrolu nad tržištem. Unatoč tome što internetske putničke agencije (OTAs) određuju vlastite cijene zrakoplovnih karata, zrakoplovne kompanije su proizvođači usluga i stoga imaju kontrolu nad cijenama. Iako je u domeni OTAs da postavljaju vlastite cijene, potrošači koji traže ponude putem različitih kanala mogu dobiti varijacije konačne cijene zbog prostora za pregovaranje. Konkurencija među proizvodima i

prodavačima može utjecati na konačnu cijenu putem raspodjele tržišta. Da bi se dublje razumjela distribucija cijena zrakoplovnih karata na konkurentskim tržištima, Bilotkach i Pejcinovska (2012) su nasumično odabrali 50 vodećih američkih domaćih tržišnih parova. Analizom jednostavne regresije s primijenjenom prirodnom logaritamskom transformacijom na zavisne varijable, došli su do zaključka da je konkurencija među agentima odlučujući faktor za određivanje cijene. Isto tako, nastaje natjecanje među proizvođačima (različitim zrakoplovnim tvrtkama). Bilotkach i suradnici (2015) su otkrili da, za razliku od široko prihvaćenog mišljenja, postoji pozitivna povezanost između faktora opterećenja i cijena karata. Prema teoriji, cijena karte bi trebala postupno rasti kako se datum putovanja približava, što odražava porast faktora opterećenja. Međutim, rezultati eksperimenata s varijablama pokazali su drugačiju mogućnost koja može dovesti do povećanja prihoda. Povećanje cijene karata prema datumu putovanja ne garantira profit jer bi moglo zaustaviti rast faktora opterećenja. Ovi teorijski modeli uzimaju u obzir nekoliko važnih neovisnih varijabli poput potencijalnih vršnih razdoblja potražnje, ekonometrijskih ograničenja te korelacije s zalihama (Bilotkach, Gaggero i Piga, 2015).

Primjena naprednih tehnika strojnog učenja, poput generaliziranih linearnih modela i učenja potkrepljenja, pomaže zrakoplovnim tvrtkama bolje razumjeti kompleksne veze među različitim čimbenicima koji utječu na postavljanje cijena. To rezultira preciznijim i učinkovitijim strategijama postavljanja cijena koje mogu optimizirati prihode i unaprijediti zadovoljstvo korisnika.


Slika 11. Područja primijene umjetne inteligencije u upravljanju zračnim prometom prometom



Izvor: preuzeto sa: <https://www.altexsoft.com/blog/ai-airlines/> (pristupljeno 16. lipnja 2024.)

Umjetna inteligencija pronašla je mjesto u brojnim područjima primjene u upravljanju zračnim prometom. Na slici 11 prikazane su neke od kategorija gdje umjetna inteligencija uvelike pridonosi kvalitetnijem funkcioniranju i obavljanju dužnosti, što će pobliže biti objašnjeno u nastavku.

Slika 12. Pronalazak najpovoljnijih karata korištenjem alata umjetne inteligencije



Izvor: preuzeto sa: <https://www.eddytravels.com/flights> (pristupljeno 16. lipnja 2024.)

Korištenje UI za predikciju vremenskih uvjeta

Vremenski uvjeti poput oluja, turbulencija, vjetrova, oborina i temperature mogu znatno poremetiti letove. Oni dovode do zakašnjenja, povećavaju potrošnju goriva i utječu na sigurnost letova. Tehnologije umjetne inteligencije pomažu u predviđanju i rješavanju tih izazova. Umjetna inteligencija ima sposobnost analizirati različite atmosferske varijable kako bi generirala vremenske prognoze specifično prilagođene zrakoplovstvu. Algoritmi bazirani na UI pregledavaju povijesne klimatske podatke, trenutno atmosfersko stanje i informacije povezane sa zrakoplovnim potrebama, identificirajući obrasce vezane uz razne vremenske pojave (Tomorrow.io). Tehnologije poput strojnog učenja i dubokog učenja omogućuju kontinuirano prilagođavanje novim podacima, čime se unaprjeđuju predikcije. Kroz ove tehnologije moguće je modelirati meteorološke procese u mikroskali, omogućujući razumijevanje lokalnih događaja poput mikroburstova ili uvjeta na pistama tijekom lošeg

vremena. Na primjer, Alaska Airlines upotrebljava UI-vođeni program Flyways za optimizaciju letnih putanja, uzimajući u obzir aktualne vremenske uvjete, težinu letjelice i druge faktore. Tijekom šestomjesečnog pokusnog razdoblja, ovaj program je smanjio vrijeme leta za otprilike pet minuta po letu, što je rezultiralo uštedom od 480 tisuća galona goriva (Avionics Today). UI upotrebljava raznolike tehnike strojnog učenja, uključujući nadzirano te nenadzirano učenje, radi analize vremenskih setova podataka. Primjerice, Reitmann i suradnici (2019) osmislili su model strojnog učenja koji koristi meteorološke izvještaje i podatke o učinkovitosti zračnih luka za klasifikaciju i predviđanje kašnjenja uzrokovanih vremenskim uvjetima. Njihova metoda uključuje upotrebu rekurentnih i konvolucijskih neuronskih mreža za prepoznavanje obrazaca u podacima te predikciju operativnih poremećaja (Reitmann i sur., 2019).

Meteorološki uvjeti značajno utječu na poslovanje zračne luke i učinkovitost cijele zrakoplovne mreže. Odgođeni radovi mogu biti izravna posljedica otežavajućih vremenskih uvjeta koji uzrokuju restrikcije u kapacitetima zračne luke. Za točne operacije potrebno je dobiti predikciju zračnih procesa duž svih njihovih puteva. Neizvjesnosti na letu u zraku nemaju veliki utjecaj na ukupnu točnost. Zemaljske radnje postaju važne u trenutnom poslovnom okruženju. To omogućava različitim dionicima da se usredotoče na operacije tla i definiraju sveobuhvatnu 4D putanju aviona za čitav dan operacija (zemlja). Jedan od glavnih zadataka zemaljskih aktivnosti je korištenje sigurnog i pouzdanog vremena polaska. Godine 2016. kašnjenja zbog reakcija nastavila su biti glavni uzrok kašnjenja, praćena kašnjenjima u obratu, koja su činila 46% kašnjenja pri polasku (EUROCONTROL, 2017).

Devijacije u letovima su ključne za upravljanje zračnim prometom i uzrokovane su različitim vremenskim i prometnim uvjetima, kao i intervencijom kontrolora leta. Uobičajene standardne devijacije za letove u zraku iznose 30 sekundi do 20 minuta prije slijetanja, ali mogu se povećati na 15 minuta kada je avion još na tlu (Bronsvort i sur., 2009). Prosječna varijabilnost vremena tijekom faze leta (5,3 minute) veća je nego tijekom faza taxi-out (3,8 minute) i taxi-in (2,0 minute), no još uvijek značajno manja od varijabilnosti u fazama polaska (16,6 minuta) i dolaska (18,6 minuta) (EUROCONTROL, 2017). Promjene koje se događaju tijekom faze od vrata do vrata su relativno male te se time prenosi varijabilnost polaska na varijabilnost dolaska (Tielrooij i sur., 2015). Stoga je preciznost dolaska ovisna o preciznosti polaska te svi sudionici (zračne kompanije, zračne luke, mrežni menadžeri,

pružatelji usluga zračne navigacije) igraju važnu ulogu u ukupnoj izvedbi sustava točnosti (Mueller i Chatterji, 2002).

3.3. Sigurnost u zračnom prometu kroz umjetnu inteligenciju

Umjetna inteligencija predstavlja ključnu tehnologiju radi poboljšavanja stupnja sigurnosti u zračnom prometu. UI ima ključnu ulogu i u poboljšanju kibernetičke sigurnosti u zračnom prometu, uz fizičku sigurnost. Prskalo (2023) ističe koliko je važno da se UI koristi za prepoznavanje i smanjenje kibernetičkih prijetnji koje mogu dovesti u opasnost sigurnost zračnog prometa. Sustavi UI, koristeći napredne algoritme, mogu analizirati mrežne aktivnosti i otkriti potencijalne prijetnje prije nego postanu veliki sigurnosni izazovi (Prskalo, 2023). To se odnosi na pokušaje neovlaštenih pristupa osjetljivim podacima, napade na mrežne sustave i razne druge oblike cyber napada koji mogu destabilizirati operacije zračnog prometa.

Prema tvrdnjama European Union Aviation Safety Agency (2024), jedna od ključnih prednosti umjetne inteligencije je sposobnost obrađivanja velikih količina podataka i učenja iz njih. To se moćno oruđe može primijeniti za otkrivanje obrazaca, izradu prediktivnih modela i procjenjivanje rizika. Pomoću umjetne inteligencije, posada aviona može obaviti svoj redovan posao s više efikasnosti. Isto tako, mogu predvidjeti probleme, kao što je turbulencija ili zamrzavanje te im pomoći u donošenju konačnih odluka. Kako se digitalizacijom povećava količina podataka koje obrađuju poduzeća za proizvodnju i održavanje, tako raste i potreba za obradom velikih volumena podataka tehnologijom umjetne inteligencije. Konkretno, prediktivno održavanje temeljeno na umjetnoj inteligenciji pomoći će poduzeću u više aspekata: pomoći će u optimizaciji rasporeda održavanja, moći će predvidjeti preostali vijek trajanja pojedinih dijelova i time spriječiti kvar. Optimizacijom putanje leta umjetna inteligencija pomaže u smanjenju emisija ugljikovog dioksida tijekom letačkih operacija. Procjena učinka zrakoplovstva na okoliš poput buke oko zračnih luka ili emisije motora tijekom leta, podatkovno je i računalno intenzivna aktivnosti. Umjetna inteligencija doprinosi obradi takvih podataka. Uz umjetnu inteligenciju moguće je odrediti optimalne pravce leta analizom podataka o obrascima vremenskih uvjeta, konfiguracijama sektora, zagušenima zračnog prometa i drugim čimbenicima. Takva optimizacija rezultira skraćivanjem trajanja letova, smanjenjem potrošnje goriva i operativnih troškova (European Union Aviation Safety Agency, 2024).

Postoji više tipova sigurnosti koji se razlikuju obzirom na zaštićena dobra i vrijednosti. Tu se ubrajaju sigurnost prometa na putevima, u zraku, na rijekama i morima, koja se ostvaruje zakonima i drugim propisima kojim su definirana prometna pravila koja određuju ponašanje sudionika, organe koji reguliraju i vrše kontrolu sigurnosti u tim oblastima (Masleša, 2001).

Sustav zračnog prometa dijeli se na (Pavlin, 2006):

- Infrastrukturu (aerodromi i zračni putevi sa sredstvima koja ih definiraju)
- Zrakoplovi, odnosno letjelice koje koriste infrastrukturu
- Kontrolu letenja i vođenja zrakoplova.

Kibernetički rizici se klasificiraju u:

1. **NAMJERNE PRIJETNJE.** Ciljane od strane organiziranih skupina ili pojedinaca s glavnom namjerom izazivanja štete ili krađe važnih informacija. Kao mete ili sredstva za napade, terorističke organizacije mogu koristiti zračni promet. Ti udari uključuju otmicu zrakoplova, postavljanje bombi na njih ili korištenje samih aviona kao oruđa (Jenkins, 2001). Načinjena šteta zrakoplovima, aerodromima i navigacijskim sustavima može ozbiljno ugroziti sigurnost. Sabotaža može biti izvedena od strane nezadovoljnih radnika, konkurenata ili drugih interesnih skupina koji žele nanijeti štetu ili prekinuti operacije (Price i Forrest, 2016). Moderni zrakoplovi i sistemi za navigaciju oslanjaju se na složene informacijske sisteme. Kibernetički napadi mogu ciljati ove sustave kako bi ih preuzeli, prouzrokovali kvarove ili ukrali povjerljive podatke (Stavridis, 2014). Zloupotreba zračnog prometa od strane kriminalnih grupa u svrhu krijumčarenja droge, oružja i ostalih ilegalnih proizvoda. Također unutar aerodroma mogu vršiti naoružane pljačke i druge nasilne radnje (Abeyratne, 2018). Radnici unutar sistema civilnog zrakoplovstva mogu predstavljati prijetnju ako su potkupljeni ili imaju svoje motive za izvršenje kriminalnih radnji. Ovaj oblik uključuje krađu informacija, sabotaže ili pomoć u izvođenju napada (Cole, 2010).
2. **NENAMJERNE PRIJETNJE.** Nastaju greškom ili nepažnjom zaposlenika, tehničkih kvarovima ili neispravnom opremom. Ozbiljni sigurnosni incidenti mogu se dogoditi zbog pogrešaka osoblja koje radi u zračnom prometu, poput pilota, kontrolora leta, tehničara i drugih. Primjerice, neispravna interpretacija instrumenata, greške u komunikaciji ili proceduralne pogreške mogu dovesti do nesreća ili zamalo nesreće

(Federal Aviation Administration, 2019). Opasne situacije mogu izazvati kvarovi u avionima, motorima, navigacijskim sistemima ili drugim ključnim komponentama zrakoplova. Ako se sistemi ne održavaju i pregledavaju redovito, to može dovesti do povećanja opasnosti (International Civil Aviation Organization, 2020). Ekstremni vremenski uvjeti kao što su oluje, turbulencije i led te vulkanski pepeo ili udarci ptica mogu ozbiljno prijetiti sigurnosti leta. Predviđanja vremena i fleksibilnost planova leta mogu smanjiti rizike (National Transportation Safety Board, 2021). Rizik od incidenata može se povećati ako sigurnosne procedure i sustavi nisu dovoljno razvijeni ili adekvatno implementirani. Kontinuirano unapređivanje procedura i sistema na osnovu povratnih informacija i analize incidenata je ključno za održavanje visokog stupnja sigurnosti (European Union Aviation Safety Agency, 2022).

3. CILJANI NAPADI. Planirani napadi na glavne infrastrukturne sustave. Definicija ciljanog kibernetičkog napada je složeni napad usmjeren na određenu osobu, organizaciju ili sustav. Često ga provode kriminalne skupine, državni hakeri ili hakvisti s namjerom postizanja specifičnih ciljeva. Takvi napadi mogu koristiti razne taktike koje se provode u više faza, a njihova evolucija može trajati dugo vremena, što predstavlja izazov pri njihovom otkrivanju i sprječavanju (NordVPN, 2024).
4. NE-CILJANI NAPADI. Širenje zlonamjernog softwarea koji nema definiran cilj (virus, crv). Ne-ciljani kibernetički napadi, također poznati kao oportunistički napadi, nemaju specifičnu osobu, organizaciju ili sustav na kojem su usmjereni. Umjesto toga, napadači primjenjuju automatizirane alate za skeniranje interneta kao način da otkriju već poznate slabosti u sustavima ili mrežama. Glavna svrha ovih napada je da se poveća broj kompromitiranih sustava, bez obzira na identitet njihovih žrtava. Uobičajeno su manje sofisticirani napadi koji se koriste metode poput širenja phishing kampanji, zaraženih web stranica ili brute force napada na lozinke (SEI, 2021; LBMC, 2018).

Garcia (2022) ističe da kibernetička sigurnost u zračnom prometu postaje sve kompleksnija zbog mnogostrukih komponenti i njihovih međusobnih veza. Do sada su istraživanja na ovom području bila fragmentirana i usmjerena samo na izolirane module, umjesto da iskoriste napredne alate kao što su strojno učenje i umjetna inteligencija. Nadalje, Garcia (2022) predlaže novi model prijetnji koji omogućuje precizniju identifikaciju kibernetičkih prijetnji te razvoj testnog okruženja za eksperimentiranje s metodama strojnog učenja i umjetne

inteligencije. Ovi modeli pomažu u dubljem razumijevanju prijetnji i stvaranju efikasnih strategija obrane.

Kibernetička sigurnost u zračnom prometu složena je zbog brojnih komponenti i njihovih međusobnih interakcija. Do sada su istraživanja bila fragmentirana i usredotočena na izolirane module umjesto korištenja naprednih alata poput strojnog učenja i umjetne inteligencije (Garcia, 2022).

Garcia (2022) je prepoznala važna područja istraživanja sigurnosti, koja uključuju analizu avionske elektronike, tehnologije komunikacije poput Software Defined Radios (SDRs) i zabrinutost za mrežnu sigurnost uslijed međusobne povezanosti unutar zrakoplovnog ekosustava.

Prema istraživanju Tachtatzis, Andonovic i Bellekens (2022), primjećuje se porast broja inherentnih ranjivosti u softverskim alatima koji pokreću sustave kako se razina integracije povećava. Integracija informacijsko-komunikacijskih tehnologija (ICT) u mehaničke uređaje avijacije znatno je podigla svijest o kibernetičkoj sigurnosti. Nadalje, tijekom posljednjih dvadeset godina autori su proučavali ključne vrste prijetnji i napada u zrakoplovnoj industriji. Prema Tachtatzisu, Andonovicu i Bellekensu (2022) otkriveno je da su najveće prijetnje povezane s naprednim trajnim prijetnjama (APT) koje često surađuju s državnim akterima. Ova vrsta napada ima za cilj krađu intelektualnog vlasništva i informacija radi unaprjeđivanja domaćih zrakoplovnih kapaciteta i nadzora te infiltracije sposobnosti drugih država. Osim toga, autori ističu da IT infrastruktura u zrakoplovstvu redovito postaje žrtva zlonamjernih napada, pri čemu je najuočljiviji oblik takvog napada neovlašteno hakiranje s ciljem provaljivanja. Prema Tachtatzisu, Andonovicu i Bellekensu (2022), proučavanje napadnih površina i analiza trenutnih dinamičkih prijetnji omogućuje predviđanje budućih kibernetičkih napada te razvoj unaprijeđenih obrambenih strategija. Organizacijski aspekti sigurnosti sustava zračnog prometa u užem smislu predstavlja prostornu i vremensku sinkronizaciju niza subjekata i aktivnosti u jedinstven kontinuirani proces (Steiner, 1998). Metodologija procjene rizika u sustavima upravljanja zračnim prostorom temelji se na različitim parametrima i ključni je dio procesa upravljanja rizicima organizacije koja pruža usluge zračnog prijevoza. Primarni cilj je identificirati, procijeniti i smanjiti rizike do prihvatljive razine. Osim toga, čini temelj za planiranje operacija i donošenje odluka u zračnom prijevozu te promiče proaktivan

pristup na mjesto reaktivnog. Sustavno prikupljanje i analiza odgovarajućih informacija olakšava otkrivanje opasnosti i postavljanje kontrole već prije početka. Ahić i Nađ (2017) tvrde da procjena rizika uključuje određivanje gdje se, kada, zašto i kako procijenjeni događaji mogu spriječiti, smanjiti, odlagati ili pomoći u postizanju ciljeva.

3.4. Primjena umjetne inteligencije u razvoju novih tehnologija u zračnom prometu

UI ima presudan utjecaj na razvoj novih tehnologija u zračnom prometu. S obzirom na kompleksnost i potrebe za sigurnošću u zračnom prometu, korištenje naprednih tehnologija UI ima potencijal da značajno unaprijedi djelovanje, osigura veću sigurnost i poveća produktivnost. Primjena algoritma UI za optimizaciju ruta i vremena letova sve više raste. Koristeći model strojnog učenja, moguće je predvidjeti optimalne putove na temelju obimnih skupova podataka uzeti vremenske uvjete, stanje prometa i ostale bitne faktore u obzir. Ovi modeli omogućuju značajno smanjenje potrošnje goriva i emisiju štetnih plinova, što podržava održivost ekonomije i zaštite okoliša u avioindustriji. Analizom podataka sa senzora uz pomoć algoritama, UI se koristi u prediktivnom održavanju kako bi unaprijed predvidio kvarove. Često se koriste reaktivni pristupi održavanju koji su tradicionalni i često dovode do neočekivanih kvarova. Kroz analizu podataka sa senzora, UI se koristi u prediktivnom održavanju kako bi se mogući kvarovi unaprijed predvidjeli. Prema istraživanju Sun i ostalih autora (2019), ovaj pristup donosi povećanu pouzdanost i sigurnost zrakoplova, uz istodobno smanjenje troškova održavanja. Na taj način, pouzdanost i sigurnost zrakoplova rastu dok se istovremeno smanjuju troškovi održavanja. U zračnom prometu, najnaprednije korištenje umjetne inteligencije je vidljivo u razvoju autonomnih sustava za upravljanje letjelicama, koji uključuju i dronove. Suvremene tehnike umjetne inteligencije omogućuju autonomnim letjelicama da u realnom vremenu navigiraju i izbjegnu prepreke. Primjena ovoga je široka u mnogim aplikacijama, poput dostave, nadzora i istraživanja. U zračnom prometu, UI igra važnu ulogu u unapređenju korisničkog iskustva. Algoritmi za prepoznavanje lica pomažu u brzom prijavi putnika, dok personalizirane preporuke UI podržavaju putnike pri planiranju svojih putovanja. Uz to, UI ima sposobnost optimizacije rasporeda i kapaciteta aerodroma kako bi smanjio pretrpanost i poboljšao sveukupnu operativnu efikasnost. Tehnologije UI igraju ključnu ulogu u osiguravanju sigurnosti zračnog prometa, pružajući inovacije u tom području. NLP algoritmi su sposobni u realnom vremenu analizirati komunikaciju radi otkrivanja potencijalnih prijetnji. Također, sustavi UI za otkrivanje uzoraka u zračnim lukama mogu brzo reagirati na sigurnosne incidente tako da prepoznaju neuobičajene aktivnosti.

Umjetna inteligencija u bespilotnim letjelicama

Napredak prema autonomiji vozila postignut je primjenom dubokog učenja u računalnim vizualnim aplikacijama. Prema istraživanju Leea, Mckeevera i Courtneyja (2021), primjećuje se eksponencijalni rast u aktivnostima istraživanja autonomne navigacije dronova tijekom proteklih pet godina te se sve bliže dolazi postizanju konačnog cilja. Razlikuje se pet razina autonomije kada se priča o bespilotnim letjelicama (SAE International, 2018):

a. 1. razina autonomije

Asistirane značajke: GPS navođenje, detekcija zračnog prostora i evaluacija zone slijetanja. Prema Chenu i suradnicima (2022), navedene značajke pružaju podršku ljudskom operateru i već su prisutne u komercijalno dostupnim dronovima

b. 2. razina autonomije

Specifične navigacijske operacije: Operater letjelicom nadzire, ali ne i kontrolira dron. Ima mogućnosti poput "prati me" i "prati odredište", pri čemu dron prelazi u autonomni mod rada ukoliko je to izvodivo. Značajke koje su navedene dostupne su u premium komercijalnim proizvodima (Kumar i sur. , 2021).

c. 3. razina autonomije

Autonomna navigacija u identificiranim okruženjima: Dron može samostalno navigirati u određenim okruženjima, a pilot će biti angažiran samo ukoliko bude potrebno. Ova razina omogućava veću samostalnost uz minimalnu ljudsku intervenciju. Bespilotna letjelica, MQ-9 Reaper, prikazana na slici 13 može se smatrati letjelicom treće razine autonomije. Ista može autonomno upravljati u određenim uvjetima, poput leta na unaprijed definiranim rutama ili održavanja visine, te može automatski vratiti letjelicu u bazu u slučaju prekida komunikacije. Međutim, za složenije operacije ili neočekivane situacije potrebna je ljudska intervencija. Iako je MQ-9 visoko automatizirana, još uvijek nije potpuno autonomna, ali može samostalno letjeti unutar okvira koji su unaprijed definirani od strane operatera.

d. 4. razina autonomije

Autonomna navigacija: pretežito nema potrebe za ljudskom intervencijom, letjelica sposobna donositi vlastite odluke u većini slučajeva

e. 5. razina autonomije

Potpuna autonomija: podrazumijeva razinu autonomije 4, ali u svom slučajevima. Teoretski se smatra idealnom i izvan je okvira trenutnih mogućnosti (Sun i suradnici, 2019.).

Slika 13. Unmanned aerial vehicle (UAV - bespilotna letjelica), MQ-9 Reaper



Izvor: preuzeto sa: <https://www.newamerica.org/future-security/reports/world-drones/who-has-what-countries-with-armed-drones/> (pristupljeno 20. lipnja 2024.)

Primjena UI u simulaciji i obuci pilota

Sve veću primjenu umjetna inteligencija pronalazi i u područjima obuke pilota gdje donose odluke kroz interakciju sa simuliranim okruženjem. Ova metoda omogućava agentima da razviju sposobnosti koje su ključne za zračne borbene scenarije i druge složene letne operacije (Gheorghiu, 2013; Sutton i Barto, 2018). Kada se UI koristi u simulacijama, stvaraju se realističniji i složeniji scenariji koji unapređuju sposobnosti pilota u donošenju odluka u praktičnim situacijama. Učenje pojačanjem (reinforcement learning) koristi se za razvijanje autonomnih agenata koji mogu djelovati zajedno s ljudskim pilotima i pružiti im vjerodostojne treninge. Kao primjer, TACAIR-SOAR sustavi simuliraju ljudsko ponašanje tijekom vojnih zračnih misija te omogućuju izvođenje složenih scenarija u stvarnom vremenu. Ovaj koncept je opisan u istraživanju provedenom za vrijeme simulacija leta, virtualni instruktori pružaju verbalne upute i povratne informacije u stvarnom vremenu. Ovi sistemi koriste grafički sustav za analizu performansi pilota i pružanje specifičnih povratnih informacija u cilju unapređenja njihovih vještina. Na primjer, TakeFlight Interactive platforma koristi virtualne instruktore kako bi pružila personaliziranu letnu obuku i omogućila pilotima brzo usavršavanje potrebnih manevra (TakeFlight Interactive, 2024). Podaci istraživanja ukazuju da kroz analizu podataka i optimizaciju trening scenarija, UI ima potencijal za povećanje učinkovitosti i poboljšanje kvalitete obuke pilota. Na primjer, korištenjem metoda kao što su Gaussian Kernel Density Estimation (KDE) za procjenu performansi pilota i prepoznavanje anomalija, može se značajno unaprijediti i poboljšati točnost i pouzdanost simulacija (Zhang i suradnici, 2023). Prema pisanju Källströma i Heintza

(2019), tehnike dubokog učenja s ciljem poboljšanja autonomije budućih sustava obuke mogu se koristiti za automatizaciju stvaranja naprednih adaptivnih modela ponašanja u simulacijama. Rezultati eksperimenata pokazuju da ovaj pristup omogućava sintetičkim pilotima da razviju vještine suradnje i prioritizacije u sukobnim situacijama zračne borbe, što smanjuje potrebu za ljudskim intervencijama i troškove obuke. Källströma i Heintza (2023) istražuju i načine na koje modeli kontroliraju zrakoplov u složenim situacijama i okruženjima s višestrukim ciljevima. Rezultati istraživanja upućuju na to da su kontrolni modeli zrakoplova u složenim okruženjima najefikasniji kada se mogu prilagoditi promjenljivim uvjetima. Kada se nalazi u dinamičnim situacijama, zrakoplov mora donositi odluke s obzirom na različite ciljeve koji su međusobno konkurentni, kao što su sigurnost leta, efikasnost i uspješnost izvršavanja misije. Letjelici se omogućuje prilagodba različitim izazovima u stvarnom vremenu zahvaljujući adaptivnim modelima, što uključuje nepredvidive vremenske uvjete i neočekivane prepreke. Autori su naglasili kako je glavni problem u dizajnu ovih modela pronalaženje prave ravnoteže između različitih ciljeva, kao što su izbjegavanje prepreka, održavanje optimalne rute i uspješno obavljanje primarnih zadataka. Modeli koji postižu uspješno balansiranje ovih ciljeva koriste napredne algoritme za donošenje odluka temeljene na više kriterija, dopuštajući letjelici da se prilagodi prioritetima cilja ovisno o situaciji.

4. EMPIRIJSKO ISTRAŽIVANJE PRIMJENE UMJETNE INTELIGENCIJE U UPRAVLJANJU ZRAČNIM PROMETOM

4.1. Pregled postojećih istraživanja

Tematika umjetne inteligencije postaje sve više proučavana i raste interes za provođenje brojnih istraživanja, kako domaćih tako i stranih autora. Degas i suradnici (2022) provode istraživanje pod naslovom „A Survey on Artificial Intelligence (AI) and eXplainable AI in Air Traffic Management: Current Trends and Development with Future Research Trajectory". Ovo istraživanje proučavalo je trenutno stanje umjetne inteligencije u upravljanju zračnim prometom te je predstavljena dimenzija UI i eXplainable (XAI). Također se analiziralo i identificiralo zašto je XAI potreban, ali navela su se i njegova ograničenja. Razvijen je i konceptualni okvir naziva DPP (Descriptive, Predictive, Prescriptive) model kojim se ilustrira primjena UI u scenariju za 2030. godinu.

Liu i suradnici (2019) proveli su istraživanje temeljeno na praksi koje se koristi modelima strojnog učenja za analizu akcija upravljanja zračnim prometom, posebice u kontekstu programa za smanjenje kašnjenja na pisti. Njihovi rezultati ukazuju da umjetna inteligencija može značajno smanjiti kašnjenja letova i optimizirati operacije, što dovodi do poboljšanja efikasnosti i smanjenja troškova.

U svom istraživanju, Gardi i Sabatini (2021) su se bavili primjenom tehnike strojnog učenja kako bi predvidjeli rizik operacija zračnog prometa. Kako bi poboljšali povjerenje korisnika u ove sustave, iskoristili su algoritme XGBoost i metode objašnjive umjetne inteligencije (XAI). Prema njihovom istraživanju, UI može unaprijediti sigurnost zračnog prometa putem preciznijih predikcija i dubljeg razumijevanja operativnih rizika.

Kada se fokus stavlja na domaće autore i istraživanja na temu primjene umjetne inteligencije u upravljanju zračnim prometom, opseg se značajno smanjuje. Prskalo (2023) u svom radu „Suvremeni kibernetički rizici u upravljanju zračnim prometom“ istražuje način na koji umjetna inteligencija pomaže u prepoznavanju i sprječavanju kibernetičkih napada. Naglašava kako UI može unaprijed analizirati informacije i mrežne aktivnosti te vodeći se time identificirati potencijalne prijetnje prije nego što postanu ozbiljni sigurnosni problemi.


4.2. Metodologija istraživanja

Ovo istraživanje usmjereno je na ispitivanje u kojoj mjeri umjetna inteligencija pomaže i olakšava obavljanje svakodnevnih zadataka stručnjacima u Hrvatskoj kontroli zračne plovidbe. Oni kao ciljna skupina predstavljaju relevantan okvir za ovo istraživanje jer posjeduju specifična znanja i iskustva u upravljanju zračnim prometom. Kao instrument istraživanja korišten je anketni upitnik, a cilj je ispitati različite aspekte primjene umjetne inteligencije u upravljanju zračnim prometom.

4.3. Rezultati istraživanja

U primarnom istraživanju sudjelovala su 4 ispitanika, a čija je dobna struktura prikazana na Grafikonu 1. Svi ispitanici zaposleni su u Hrvatskoj kontroli zračne plovidbe s time da veći broj ispitanika radi u istoj više od šest godina, dok je jedan zaposlenik zaposlen tek nešto kraće od jedne godine. Pozicije koje ispitanici obnašaju su kontrolor leta, inženjer sustava, menadžer operacija te voditelj odjela u MET službi. Svi ispitanici su naveli kako su umjereno upoznati sa primjenom umjetne inteligencije u upravljanju zračnim prometom.

Grafikon 1. Dobna struktura ispitanika



Izvor: primarno istraživanje

Temeljem rezultata provedenog primarnog istraživanja uočava se kako su najzastupljeniji alati koje koriste u svakodnevnom radu predikcija vremenskih uvjeta, Gemini, Chat GPT za specijalne zahtjeve. Većina ispitanika vjeruje kako primjena sustava umjetne inteligencije doprinosi smanjenju kašnjenja letova i da značajno poboljšava sigurnost u upravljanju zračnim prometom. Dio ispitanika se i u potpunosti slaže s ovom tvrdnjom.

Rezultati istraživanja pokazali su da su najveće prednosti korištenja umjetne inteligencije u upravljanju zračnim prometom ubrzanje rada, povećanje redovitosti uz povećanje sigurnosti, dok je najveća prepreka dug i kompliciran proces upoznavanja za naprednije korištenje. Primjena tehnologija umjetne inteligencije će se u budućnosti postupno povećavati. Sukladno tome ne čudi kako su ispitanici naveli da jo uvijek nisu imali obuku za korištenje umjetne inteligencije.

Najviše povjerenja ispitanici su iskazali prema tvrdnji kako umjetna inteligencija omogućava brže donošenje odluka u kriznim situacijama. Većina sudionika se slaže ili potpuno slaže s ovom izjavom, što ukazuje na prepoznatu vrijednost UI-e u uvjetima kada je vrijeme ključno, a brza reakcija može značiti razliku između sigurnog i nesigurnog ishoda. Kapacitet UI za obradu velikih količina podataka u realnom vremenu omogućava donošenje informiranih odluka u situacijama koje zahtijevaju hitnu intervenciju, čime se značajno povećava njegova vrijednost u kriznom upravljanju. S druge strane, tvrdnje koje se odnose na ulogu UI-e u optimizaciji ruta zrakoplova i smanjenju broja incidenata i nesreća izazvale su veću dozu skepticizma među sudionicima. Mišljenja su podijeljena i odražavaju izazove s kojima se UI susreće u ovim područjima, kao što su složenost algoritama i njihova primjena u stvarnim uvjetima te potencijalni nedostatak povjerenja u sposobnost UI-e da potpuno eliminiira ljudsku pogrešku i nesigurnosti.

Pitanje predikcije vremenskih uvjeta, iako ključno za sigurnost zračnog prometa, također nije izazvalo visoku razinu povjerenja među ispitanicima. Iako UI ima potencijal za značajno poboljšanje točnosti vremenskih predikcija, stavovi sudionika podijeljeni su između neutralnih i onih koji se ne slažu. Ovaj skepticizam može biti rezultat trenutnih ograničenja u sposobnosti UI-e da precizno predvidi složene vremenske obrasce. Zanimljivo je primijetiti da tvrdnja o sposobnosti sustava UI da olakšavaju praćenje i analizu performansi zrakoplova ipak dobiva određenu podršku, iako ne toliko izraženu kao u slučaju kriznog upravljanja. Ovo ukazuje na prepoznavanje potencijala UI-e u prikupljanju i analizi podataka o performansama, što može poboljšati održavanje i operativnu efikasnost zrakoplova.

Iako se umjetnoj inteligenciji priznaju određene prednosti u upravljanju zračnim prometom, postoji i značajna doza opreza. Potreba za daljnjim istraživanjem i testiranjem sustava UI, kako bi se povećalo povjerenje u njihovu učinkovitost i pouzdanost u ovom kritičnom

sektoru, i dalje je jako izražena. Primjena umjetne inteligencije u radnom okruženju sve više izaziva interes, posebno u kontekstu njenog utjecaja na radnu atmosferu i zadovoljstvo poslom. Različiti stavovi sudionika, reflektiraju kompleksnost i višeznačnost ove teme. Percepcija utjecaja tehnologije UI na radnu atmosferu i zadovoljstvo poslom podijeljena je. Na tvrdnju kako tehnologije UI smanjuju stres na radnom mjestu, glavnina ispitanika (75%) je ostala neutralna, dok se jedan ispitanik slaže. U pogledu povećanja produktivnosti korištenjem tehnologija UI, jedan ispitanik je zauzeo neutralan stav, dok su tri ispitanika izrazila slaganje s tvrdnjom. Što se tiče poboljšanja komunikacije među zaposlenicima putem tehnologija UI, jedan ispitanik se ne slaže, dok su tri ispitanika ostala neutralna. Kod tvrdnje kako tehnologije UI omogućavaju bolju ravnotežu između posla i privatnog života, tri ispitanika ostala su neutralna dok se jedan slaže s tvrdnjom.

Tvrdnje koje se odnose na zadovoljstvo poslom u vezi s korištenjem tehnologija UI pokazuju sličnu podijeljenost mišljenja. Dok se dva ispitanika slaže s tvrdnjom kako UI može poboljšati zadovoljstvo poslom, dva su izrazili suprotno mišljenje. Ova podijeljenost može ukazivati na razlike u iskustvima i percepcijama zaposlenika u vezi s UI-om, gdje neki vide prednosti u smanjenju monotonih zadataka i povećanju produktivnosti, dok drugi osjećaju da tehnologija smanjuje ljudsku interakciju i kreativnost, što može smanjiti zadovoljstvo poslom.

Zanimljivo je primijetiti da je u nekoliko slučajeva zabilježen značajan broj neutralnih odgovora. Ovaj neutralan stav može sugerirati kako dio ispitanika nema dovoljno iskustva ili informacija o utjecaju AI-a na njihovo radno okruženje, ili su još uvijek neodlučni u vezi s tim kako bi tehnologija mogla dugoročno utjecati na njihov radni prostor i osobno zadovoljstvo. Ovaj skepticizam i podijeljeni stavovi naglašavaju potrebu za dodatnim istraživanjem i prilagodbom sustava UI kako bi se osigurala njihova integracija na način koji će pozitivno utjecati na radno okruženje i zadovoljstvo poslom. Važna je edukacija zaposlenika o mogućnostima i ograničenjima tehnologije UI kako bi se smanjila nesigurnost i povećala prihvaćenost novih tehnologija u radnim procesima. Umjetna inteligencija ima ogroman potencijal u poboljšanju upravljanja zračnim prometom, osobito u kontekstu Hrvatske kontrole zračne plovidbe. Jedna od glavnih prednosti je ubrzanje postupaka rada i pomoć pri donošenju odluka. UI može omogućiti brže i točnije odluke, osobito u kompleksnim situacijama u kojima zračni kontrolori moraju brzo reagirati. To smanjuje rizik od ljudskih pogrešaka i poboljšava ukupnu sigurnost u zračnom prometu. Druga često spominjana

prednost je optimizacija obzirom da ista može pomoći u optimizaciji ruta letenja, vremenskih rasporeda i potrošnje resursa, čime se postiže učinkovitije upravljanje zračnim prometom. Optimizacija ne samo da može smanjiti troškove, već može doprinijeti i ekološkoj održivosti zračnog prometa. Međutim, neki ispitanici su naveli da se umjetna inteligencija trenutno ne koristi, ili da nije prisutna u operativnom kontekstu u HKZP-u. Ovo ukazuje na to da postoje ili prepreke u implementaciji UI-e ili nedovoljna informiranost o njezinoj trenutnoj upotrebi u sustavu. Daljnja edukacija i razvoj potrebni su kako bi se te tehnologije uspješno integrirale u HKZP te iskoristile sve njihove mogućnosti.

Iako postoji interes i potreba za primjenom UI-e, nije osigurano dovoljno vremena za detaljnu i učinkovitu integraciju ove tehnologije u postojeće radne procese. Drugi izazov odnosi se na to da tehnologija UI može biti "prezahtjevna". Zahtjevi tehnologije u smislu infrastrukture, resursa ili znanja preveliki se u usporedbi s mogućnostima trenutnih radnih uvjeta. Složenost sustava UI može stvarati dodatni pritisak na radnike ili infrastrukturu. S druge strane, neki ispitanici su izjavili da nisu primijetili nikakve prepreke, dok su drugi naveli da tema nije relevantna za njihov svakodnevni rad. Ovi odgovori ukazuju na to da primjena tehnologija UI nije univerzalno prisutna ili jednako važna u svim sektorima rada unutar organizacije.

Primjena umjetne inteligencije u upravljanju zračnim prometom očekuje se u brojnim sektorima i raznim oblastima u skoroj budućnosti. U okviru inicijativa kao što je Eurocontrol (ECTRL), sustavi UI se razvijaju s ciljem predviđanja i ublažavanja uskih grla u prometu. To uključuje optimizaciju ruta letenja u realnom vremenu, smanjenje kašnjenja i poboljšanje ukupne učinkovitosti. Ova rješenja omogućuju bolje planiranje resursa i raspodjelu prometa, čime se postiže bolja protočnost bez ugrožavanja sigurnosnih standarda. Također, UI nudi mogućnosti automatizacije i podrške za kontrolore zračnog prometa. Alati za sugestiju naredbi, koji se razvijaju i primjenjuju u različitim segmentima zračnog prometa, mogu značajno smanjiti opterećenje kontrolora, predlažući optimalne naredbe za pilote. Ovi sustavi mogu povećati brzinu donošenja odluka i smanjiti rizik od nesporazuma ili kašnjenja, čime se dodatno povećava sigurnost i učinkovitost. U budućnosti, UI će vjerojatno igrati sve značajniju ulogu ne samo u operativnim aspektima zračnog prometa, već i u njegovom planiranju i analizi. Alati za simulaciju i analizu, potpomognuti umjetnom inteligencijom, mogu omogućiti preciznije predviđanje potreba u zračnom prometu, bolju raspodjelu resursa i optimizaciju dugoročnih strategija upravljanja. Prije same implementacije tehnologija UI,

ključno je uključiti kontrolore zračnog prometa i druge relevantne dionike u proces razvoja i prilagodbe sustava. Ovo će osigurati da se alati UI dizajniraju na način koji odgovara stvarnim potrebama i izazovima s kojima se suočavaju kontrolori. Aktivno uključivanje korisnika omogućit će identificiranje potencijalnih problema i prilika za optimizaciju sustava u ranoj fazi. Nakon implementacije, važno je nastaviti dijalog s korisnicima kako bi se prikupile povratne informacije o funkcioniranju sustava. Na temelju tih povratnih informacija, UI sustavi mogu se dodatno prilagoditi i usavršavati, čime se povećava njihova učinkovitost i prihvaćenost među korisnicima.

Kontrolore zračnog prometa treba educirati ne samo o načinu korištenja novih alata UI, već i o osnovama kako ti sustavi funkcioniraju. Razumijevanje algoritama i logike iza odluka UI pomoći će u izgradnji povjerenja u tehnologiju i smanjiti otpor prema promjenama. Edukacija bi trebala uključivati treninge koji pomažu korisnicima u prilagodbi na promjene koje donosi UI, naglašavajući prednosti i nove mogućnosti koje sustavi nude. Organizacija redovitih radionica, simulacija i demonstracija rada sustava UI može pomoći u tome da se kontrolori osjećaju sigurnije i kompetentnije u korištenju novih alata. Primjena umjetne inteligencije u upravljanju zračnim prometom nosi sa sobom značajan potencijal, ali i određene izazove. Ključne preporuke za poboljšanje implementacije uključuju aktivno savjetovanje s korisnicima, temeljitu edukaciju kontrolora te demonstraciju pouzdanosti sustava kroz pilot projekte i testiranja. Ove mjere pomoći će u izgradnji povjerenja u nove tehnologije i osiguranju njihove uspješne primjene u svakodnevnom radu zračnog prometa.

4.4. Ograničenja i preporuke za buduća istraživanja

Tijekom pisanja diplomskog rada i istraživanja provedenog na temu uloge umjetne inteligencije u upravljanju zračnim prometom, uočen je manjak empirijskih istraživanja s naglaskom na praktičnu primjenu u Hrvatskoj, osobito u kontekstu najnovijih tehnoloških dostignuća i sigurnosnih izazova.

Isto tako, iznimno je teško doći do podataka i mišljenja iz „prve ruke“ jer je ovo područje vrlo kompleksno te je proces prikupljanja informacija od stručnih osoba dugotrajan i kompliciran. Praktičnih primjera implementacije umjetne inteligencije u Hrvatskoj kontroli zračne plovidbe gotovo da i nema. Iako teorijski modeli i simulacije nude uvide, oni ne odražavaju sve izazove iz stvarnog svijeta.

Za buduća istraživanja preporučuje su obuhvatiti šire područje od Republike Hrvatske te uključiti veće međunarodne zračne luke i kontrolne tornjeve koji su u svoj svakodnevni rad već implementirali određene alate UI koji su trenutno u Hrvatskoj nedostupni, a vrijeme potrebno da se počnu upotrebljavati nepoznato. Na taj način provedbe istraživanja, informacije prikupljene mogu biti puno šire, točnije i jasnije objašnjene.

5. ZAKLJUČAK

Pojam umjetne inteligencije je sve više prisutan u svakodnevnom životu. U brojnim područjima umjetna inteligencija je zauzela popriličan udio već sada, a svakim danom taj udio se samo povećava. U upravljanju zračnim prometom umjetna inteligencija donosi značajne prednosti, uključujući povećanje učinkovitosti operacija, poboljšanje sigurnosnih standarda, unaprjeđenje prediktivnih mogućnosti za rješavanje složenih situacija u stvarnom vremenu.

Korištenjem tehnologija umjetne inteligencije moguće je ubrzati postupke rada, smanjiti rizik od ljudskih pogrešaka i optimizirati rute i resurse, što može značajno doprinijeti rastu održivosti i ekonomičnosti zračnog prometa. Industrija zračnog prometa postepeno se prilagođava tehnologijama umjetne inteligencije, ali su potrebni daljnji naponi u standardizaciji, regulaciji i osposobljavanju osoblja kako bi se maksimalno iskoristile sve prednosti umjetne inteligencije.

Implementacija umjetne inteligencije u Hrvatsku kontrolu zračne plovidbe trenutno nailazi na određene prepreke. Zračna industrija, kao izrazito regulirana industrija, usvaja nove tehnologije s velikom pažnjom i sporim tempom, čime se osigurava visoka razina sigurnosti i pouzdanosti. Ova stroga regulativa rezultirala je tehnološkim zaostajanjem zrakoplovnih sustava u usporedbi s drugim industrijama, kako u zrakoplovima tako i u zemaljskoj infrastrukturi. NA temelju rezultata provedenog primarnog istraživanja može se zaključiti kako će do potpune integracije proći još dosta vremena zbog iznimne kompleksnosti zračnih sustava. Iako postoje određeni nedostaci, dugoročne koristi od primjene umjetne inteligencije u zračnom prometu su neosporne, a budući razvoj i prilagodba ključni za postizanje optimalnih rezultata.

POPIS LITERATURE

1. Abdelaziz, E.A., Saidur, R., & Mekhilef, S. (2010) A review on energy-saving strategies in industrial sector. *Renewable and Sustainable Energy Reviews*, 15(1), str. 150-168. <https://doi.org/10.1016/j.epsr.2010.01.001>.
2. Abeyratne, R. I. R. (2018). *Aviation Security Law*. Springer. Dostupno na: https://books.google.hr/books/about/Aviation_Security_Law.html?id=tw8g6C479vUC&redir_esc=y [Pristupljeno 3. srpnja 2024.]
3. Abidi, B.R., Zheng, Y., Gribok, A.V. & Abidi, M.A., 2006. Improving Weapon Detection in Single Energy X-Ray Images Through Pseudocoloring. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 36(6), str. 784-796. <https://doi.org/10.1109/TSMCC.2005.855523>
4. Ackert, S. (2011). Engine maintenance concepts for financiers: Elements of turbofan shop maintenance costs (Technical report). Aircraft Monitor. Dostupno na: http://www.aircraftmonitor.com/uploads/1/5/9/9/15993320/engine_mx_concepts_for_financiers__v2.pdf [Pristupljeno 13. lipnja 2024.]
5. Ahić, J., & Nađ, I. (2017). *Upravljanje rizikom u privatnoj sigurnosti*. Sarajevo: Fakultet za kriminalistiku, kriminologiju i sigurnosne studije Univerziteta u Sarajevu. Dostupno na: <https://www.croris.hr/crosbi/publikacija/knjiga/16875> [Pristupljeno 8. lipnja 2024.]
6. AlMashari, R., AlJurbua, G., AlHoshan, L., Al Saud, N. S., BinSaeed, O., & Nasser, N. (2018). IoT-based Smart Airport Solution. *Proceedings of the 2018 International Conference on Smart Communications and Networking (SmartNets)* (str. 1-6). Yasmine Hammamet: IEEE Dostupno na: <https://ieeexplore.ieee.org/document/8707393> [Pristupljeno 11. lipnja 2024.]
7. Arnoud V. den Boer (2015). Dynamic pricing and learning: Historical origins, current research, and new directions. *Surveys in Operations Research and Management Science*, 20(1), str. 1-18.
8. Aviation and Transportation Security Act, Pub. L. 107-71, 115 Stat. 597 (2001). Dostupno na: <https://www.congress.gov/bill/107th-congress/senate-bill/1447/text> [Pristupljeno 9. lipnja 2024.]
9. Aviation Maintenance Magazine. (2024). *AI/ML is A-OK for aviation maintenance tracking and predictive maintenance*. *Aviation Maintenance Magazine*. Dostupno na:

- <https://www.avm-mag.com/ai-ml-is-a-ok-for-aviation-maintenance-tracking-and-predictive-maintenance>
10. Aviation Week. (2022). *EasyJet Reaps Big Gains From Early Predictive Maintenance Efforts*. Dostupno na: <https://ngtest.aviationweek.com/mro/easyjet-reaps-big-gains-early-predictive-maintenance-efforts>
 11. Avionics Today. (2022). AI in the Sky: How Artificial Intelligence and Aviation Are Working Together. Dostupno na: <https://interactive.aviationtoday.com/avionicsmagazine/may-june-2022/ai-in-the-sky-how-artificial-intelligence-and-aviation-are-working-together/> [Pristupljeno 11. lipnja 2024.]
 12. Bao, X., Li, Y., & Zhang, J. (2016). Modernization of Airports to Improve Passenger Experience and Satisfaction. *Journal of Air Transport Management*, 54, str. 123-135.
 13. Baştan, M., Yousefi, M.R., & Breuel, T.M. (2011). Visual words on baggage X-ray images. U: Real, P., Diaz-Pernil, D., Molina-Abril, H. Berciano, A. & Kropatsch, W. (Ur.), *Computer Analysis of Images and Patterns. CAIP 2011* (Lecture Notes in Computer Science, vol. 6854, str. 383-390). Springer. https://doi.org/10.1007/978-3-642-23672-3_44
 14. Beckman, W., Kenney, K., & White, L. (2020). Advancing Autonomy in Aviation: A Holistic Approach. *IEEE Aerospace and Electronic Systems Magazine*, 35(3), str. 34-46. <https://doi.org/10.1109/DASC50938.2020.9256568>
 15. Bharadiya, J. (2023). Artificial Intelligence in Transportation Systems: A Critical Review. *American Journal of Computing and Engineering*, 6(1), str. 34-45. <https://doi.org/10.47672/ajce.1487>
 16. Bilotkach, V., Pejcinovska, M. (2012). Distribution of airline tickets: A tale of two market structures. In *Pricing Behavior and Non-price Characteristics in the Airline Industry*, Bingley: Emerald Group Publishing Limited, str. 107-138.
 17. Bilotkach, V., Gaggero, A., & Piga, C. A. (2015). Airline pricing under different market conditions: Evidence from European low-cost carriers. *Tourism Management*, 47(2015), str. 152-163.
 18. Bogicevic, V., Yang, W., Bilgihan, A. and Bujisic, M. (2013) Airport service quality drivers of passenger satisfaction. *Tourism Review*, 68(4), str. 3-18. <https://doi.org/10.1016/j.techfore.2017.03.038>

19. Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), str. 5-32.
<https://doi.org/10.1023/A:1010933404324>
20. Brida, J.G., Bukstein, D., & Zapata-Aguirre, S. (2016). The impact of information and communication technologies on airport performance. *International Journal of Aviation Management*, 3(2), str. 150-167. Dostupno na: <https://www.inderscienceonline.com/doi/pdf/10.1504/IJAM.2016.078660> [Pristupljeno 10. srpnja 2024.]
21. Bronsvort, J., McDonald, G., Porteous, R., & Gutt, E. (2009). Study of aircraft derived temporal prediction accuracy using FANS. U: Smith, M. J., Williams, K. J., Johnson, P. T. (Ur.) *Proceedings of the 13th Air Transport Research Society (ATRS) World Conference*, Abu Dhabi: Air Transport Research Society.
22. Chen, F.Y. i Chang, Y.H. (2015) Examining airline service quality: A service marketing mix perspective. *Journal of Air Transport Management*, 47, str. 23-35.
<https://doi.org/10.1016/j.jairtraman.2004.09.002>
23. Chen, Z., Zheng, Y., Abidi, B.R., Page, D.L. & Abidi, M.A. (2005). A Combinational Approach to the Fusion, De-noising and Enhancement of Dual-Energy X-Ray Luggage Images. *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05) - Workshops*, San Diego, CA, USA.
<https://doi.org/10.1109/CVPR.2005.386>
24. Cole, E. (2010). *Insider Threat: Protecting the Enterprise from Sabotage, Spying, and Theft*. Syngress. Dostupno na: <https://shop.elsevier.com/books/insider-threat-protecting-the-enterprise-from-sabotage-spying-and-theft/cole/978-1-59749-048-1> [Pristupljeno 3. srpnja 2024.]
25. Collins, A., Thomas, L. (2012). Comparing reinforcement learning approaches for solving game theoretic models: A dynamic airline pricing game example. *Journal of the Operational Research Society*, 63(8), str. 1165-1173.
26. Collins, A., Thomas, L. (2013). Learning competitive dynamic airline pricing under different customer models. *Journal of Revenue and Pricing Management*, 12(5), str. 416-430.
27. Collobert, R., Weston, J., Bottou, L., Karlen, M., Kavukcuoglu, K., & Kuksa, P. (2011). Natural Language Processing (almost) from Scratch. *Journal of Machine Learning Research*, 12(76), str. 2493–2537. Dostupno na: <https://jmlr.csail.mit.edu/papers/v12/collobert11a.html>

28. Dalmau Codina, R., Belkoura, S., Naessens, H., Ballerini, F. & Wagnick, S. (2019). Improving the predictability of take-off times with Machine Learning: a case study for the Maastricht upper area control centre area of responsibility. *Collection of Open Conferences in Research Transport*. Dostupno na: https://www.scipedia.com/public/Dalmau_Codina_et_al_2019b [Pristupljeno 9. lipnja 2024.]
29. Dalmau Codina, R., Belkoura, S., Naessens, H., Ballerini, F., & Wangnick, S. (2021). An explainable machine learning approach to improve take-off time predictions. *Journal of Air Transport Management*, 95, str. 102090. <https://doi.org/10.1016/j.jairtraman.2021.102090>
30. De Barros, A.G., Somasundaraswaran, A.K., & Ferreira, L. (2007). Evaluating Transfer Passenger Experience at Airports Using a Structural Equation Modelling Approach. *Journal of Air Transport Management*, 13(3), str. 174-183. <https://doi.org/10.1016/j.jairtraman.2007.04.004>
31. Degas, A., Islam, M. R., Hurter, C., Barua, S., Rahman, H., Poudel, M., Ruscio, D., Uddin Ahmed, M., Begum, S., Rahman, M. A., Bonelli, S., Cartocci, G., Di Flumeri, G., Borghini, G., Babiloni, F., & Arico, P. (2022). A survey on artificial intelligence (AI) and explainable AI in air traffic management: Current trends and development with future research trajectory. *Applied Sciences*, 12(3), str. 1295. <https://doi.org/10.3390/app12031295>
32. Deloitte. (n.d.). *IoT in smart airports: How digital transformation is elevating airport operations*. Dostupno na: <https://www2.deloitte.com/us/en/insights/industry/public-sector/iot-in-smart-airports.html> [Pristupljeno 10. lipnja 2024.]
33. Dmitruk, K., Denkowski, M., Mazur, M., Książopolski, K., & Stolarz, K. (2017). Sharpening filter for false color imaging of dual-energy X-ray scans. *SIViP*, 11, str. 613–620. <https://doi.org/10.1007/s11760-016-1001-7>
34. Dudek, G. (2022). A Comprehensive study of random forest for short-term load forecasting. *Energies*, 15(16), str. 5278. <https://doi.org/10.3390/en15207547>
35. Dudek, G. (2022). *A Comprehensive Study of Random Forest for Short-Term Load Forecasting*. *Energies*, 15(20), str. 7547. <https://doi.org/10.3390/en15207547>
36. Durso, F. T., & Manning, C. A. (2008). *Air Traffic Control. Reviews of Human Factors and Ergonomics*, 4(1), str. 195–244. SAGE Publications. <https://doi.org/10.1518/155723408x342853>

37. EUROCONTROL. (2017). Performance Review Report – An assessment of air traffic management in Europe during the calendar year 2014, 2015, 2016. Performance Review Commission. Dostupno na: <https://www.eurocontrol.int/sites/default/files/content/documents/single-sky/pru/publications/other/PRR-2015.pdf> [Pristupljeno 11. lipnja 2024.]
38. European Commission, Joint Research Centre, Vukadinovic, D. & Anderson, D., 2022. X-ray baggage screening and artificial intelligence (AI) – A technical review of machine learning techniques for X-ray baggage screening. Publications Office of the European Union. Dostupno na: <https://data.europa.eu/doi/10.2760/46363> [Pristupljeno 5. lipnja 2024.]
39. European Union Aviation Safety Agency. (2022). *Safety Procedures and System Improvements*. Cologne: EASA.
40. European Union Aviation Safety Agency. (2024). Artificial Intelligence and Aviation. [online] Dostupno na: <https://www.easa.europa.eu/hr/light/topics/artificial-intelligence-and-aviation-0> [Pristupljeno 15. lipnja 2024].
41. Federal Aviation Administration. (2019). *Aviation Safety*. Washington, DC: FAA.
42. Findler, N. V., & Lo, R. (1991). Distributed artificial intelligence approach to air traffic control. *IEE Proceedings D Control Theory and Applications*, 138(6), str. 515-524. <https://doi.org/10.1049/ip-d.1991.0072>
43. Finkenzeller, K., 2004. *RFID Handbook: Fundamentals and Applications in Contactless Smart Cards and Identification*. John Wiley & Sons. Dostupno na: <https://doi.org/10.1002/0470868023.ch9> [Pristupljeno 4. lipnja 2024.]
44. Fodness, D., & Murray, B. (2007). Passengers' expectations of airport service quality. *Journal of Services Marketing*, 21(7), str. 492-506. <https://doi.org/10.1108/08876040710824852>
45. Franzel, T., Schmidt, U., & Roth, S. (2012). Object detection in multi-view X-ray images. U: Pinz, A., Pock, T., Bischof, H., & Leberl, F. (ur.) *Pattern Recognition. DAGM/OAGM 2012* (Lecture Notes in Computer Science, vol. 7476, str. 148-157). Springer. https://doi.org/10.1007/978-3-642-32717-9_15
46. Franz-Josef E (2007). An overview of performance characteristics, experiences and trends of aerospace engine bearings technologies. *China Aerospace Technology and Industry Corporation Journal*, 20, str. 378-384.

47. Garcia, M. (2022). Enhancing Aviation Cybersecurity: Integrating Machine Learning and AI for Comprehensive Threat Analysis. *Journal of Aviation Security*, 28(4), str. 45-62.
48. Gheorghiu, S., 2013. Application of Reinforcement Learning in Pilot Training. *Journal of Artificial Intelligence Research*, 45(1), str. 123-145.
49. Gregghi, M., Silva, F.J., & Ghezzi, A. (2013). Impact of Technology on Passenger Experience in Airports. *Journal of Air Transport Management*, 35, str. 72-80. [10.1016/j.jairtraman.2014.10.005](https://doi.org/10.1016/j.jairtraman.2014.10.005)
50. Hobbs, A. (1993). *Managing maintenance error*. U: Reason, J. & Hobbs, A. (Ur.) *Managing Maintenance Error: A Practical Guide* (pp. 25-30). CRC Press. <https://doi.org/10.1201/9781315249926>
51. International Civil Aviation Organization. (2020). *Safety Management Manual (SMM)*. Montreal, Quebec: ICAO.
52. IoT Now. (2019). *EasyJet Reduces In-flight Failures by 50% with IoT Predictive Maintenance*. Preuzeto s IoT Now.
53. Jenkins, B. M. (2001). *Aviation Terrorism and Security Measures*. Santa Monica, CA: RAND Corporation. Dostupno na: <https://www.icct.nl/sites/default/files/2023-01/Chapter-26-Handbook-.pdf> [Pristupljeno 3. srpnja 2024.]
54. Jurafsky, D., & Martin, J. H. (2009). *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition* (2nd ed.). Upper Saddle River, NJ: Prentice Hall. Preuzeto sa <https://web.stanford.edu/~jurafsky/slp3/ed3book.pdf>
55. Källström, J., & Heintz, F. (2019). Multi-Agent Multi-Objective Deep Reinforcement Learning for Efficient and Effective Pilot Training. U: Larsson, R., Forsberg, B. (Ur.) *FT2019. Proceedings of the 10th Aerospace Technology Congress, Linköping Electronic Conference Proceedings 162:11* (str. 101-111). Dostupno na: https://ep.liu.se/en/conference-article.aspx?series=ecp&issue=162&Article_No=11 [Pristupljeno 9. srpnja 2024.]
56. Källström, J., & Heintz, F. (2019). Tunable Dynamics in Agent-Based Simulation using Multi-Objective Reinforcement Learning. U: *Adaptive and Learning Agents Workshop (ALA-19) at AAMAS, Montreal, Canada, May 13-14, 2019* (str. 1-7). Dostupno na: <https://www.diva-portal.org/smash/get/diva2:1362933/FULLTEXT01.pdf> [Pristupljeno: 8. srpnja 2024.].

57. Källström, J., & Heintz, F. (2023). Model-Based Actor-Critic for Multi-Objective Reinforcement Learning with Dynamic Utility Functions: Extended Abstract. U: Sycara, K. E., DeLoach, S. A., Smith, J. W. K. (Ur.) *Proceedings of the 22nd International Conference on Autonomous Agents and Multiagent Systems (AAMAS 2023), London, United Kingdom, May 29 – June 2, 2023*. Dostupno na: <https://www.ifaamas.org/Proceedings/aamas2023/pdfs/p2818.pdf> [Pristupljeno: 8. srpnja 2024.].
58. Kofi Obeng and Ryoichi Sakano. 2012. Airline fare and seat management strategies with demand dependency. *Journal of Air Transport Management*, 24 (2012), str. 42–48.
59. Kumar, V., Singh, R., & Sharma, A. (2021). Advanced Navigation Features in Commercial Drones. *Journal of Unmanned Vehicle Systems*, 9(3), str. 210-223.
60. LBMC. (2018). *Cybersecurity Risks and Best Practices*. LBMC Information Security. Dostupno na: <https://www.lbmc.com> [Pristupljeno 26. lipnja 2024.]
61. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), str. 436-444. <https://doi.org/10.1038/nature14539>
62. Lee, T., McKeever, S., & Courtney, J. (2021). Flying Free: A Research Overview of Deep Learning in Drone Navigation Autonomy. *Drones*, 5(52). Dostupno na <https://doi.org/10.3390/drones5020052> [Pristupljeno: 28. lipnja 2024].
63. Liang, K.J., Sigman, J.B., Spell, G.P., Strellis, D., Chang, W., Liu, F., Mehta, T., & Carin, L. (2019). Toward Automatic Threat Recognition for Airport X-ray Baggage Screening with Deep Convolutional Object Detection. *Papers with Code*. Dostupno na: <https://paperswithcode.com/paper/toward-automatic-threat-recognition-for> [Pristupljeno 4. lipnja 2024.]
64. Liu, Y., Liu, Y., Hansen, M., Pozdnukhov, A., & Zhang, D. (2019). Using machine learning to analyze air traffic management actions: Ground delay program case study. *Transportation Research Part E: Logistics and Transportation Review*, 131, str. 80-95. <https://doi.org/10.1016/j.tre.2019.09.012>
65. Lufthansa Technik. (2021). *AVIATAR: Lufthansa Technik's Predictive Maintenance Platform*. Dostupno na: <https://www.lufthansa-technik.com/en/aviatar>
66. Majić, J. (2018). Kultura sigurnosti u upravljanju zračnim prometom. U: Nađ, I. (Ur.), *Zbornik radova 11. međunarodna znanstveno-stručna konferencija: Dani kriznog upravljanja 2018* (str. 267-279). Velika Gorica: Veleučilište Velika Gorica. Preuzeto sa <https://dku.hr/wp-content/uploads/2019/01/DKU-Radovi-2018-1.pdf>

67. Majić, Z., Pavlin, S., & Škurla Babić, R. (2010). *Tehnologija prihvata i otpreme tereta u zračnom prometu*. Zagreb: Fakultet prometnih znanosti.
68. Masleša, R. (2001). *Teorije i sistemi sigurnosti*. Sarajevo: Magistrat. Dostupno na: <https://www.scribd.com/doc/201150437/Teorije-i-Sistemi-Sigurnosti-Ramo-Maslesa> [Pristupljeno 12. lipnja 2024.]
69. McCarthy, J., Minsky, M., Rochester, N., & Shannon, C. E. (2006). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Magazine*, 27(4), str. 12-14. <https://doi.org/10.1609/aimag.v27i4.1904>
70. Movafeghi, A., Rokrok, B., & Yahaghi, E. (2020). Dual-energy X-ray imaging in combination with automated threshold Gabor filtering for baggage screening application. *Russian Journal of Nondestructive Testing*, 56, str. 765–773. <https://doi.org/10.1134/S1061830920090065>
71. Mueller, E.; Chatterji, G. Analysis of Aircraft Arrival and Departure Delay. U: Cummings, A. G., DeLaurentis, A. M., O'Neill, K. R. H. (Ur.). *Proceedings of the AIAA ATIO Conference*, Williamsburg, 6 November 2002. <https://doi.org/10.2514/6.2002-5866>
72. Mumbower, S. Garrow, L.A., Newman, J.P. (2015). Investigating airline customers' premium coach seat purchases and implications for optimal pricing strategies. *Transportation Research Part A: Policy Practice*, 73(2015), str. 53-69.
73. NASA Aviation Systems. (2020). *Towards Autonomous Aviation Operations: What can we learn from other industries?* Dostupno na: <https://doi.org/10.2514/6.2016-3148>
74. National Research Council. (2014). *Autonomy Research for Civil Aviation: Toward a New Era of Flight*. Washington, DC: National Academies Press. Dostupno na: <https://doi.org/10.17226/18815>
75. National Transportation Safety Board. (2021). *Aviation Weather-Related Accident Prevention*. Washington, DC: NTSB.
76. Nau, J. & Benoit, F. (2017). *Smart Airport: A Review on Future of the Airport Operation*. *Journal of Business Research*, 76, str. 52-64.
77. Neto, J. B., Oliveira, L. M., & Almeida, M. F. (2023). *Artificial Intelligence Applications in Aviation Safety: Enhancing Efficiency and Security Standards*. *Journal of Aviation Technology*, 15(2), str. 101-112.
78. Newell, A., & Simon, H. A. (1963). GPS, a program that simulates human thought. In Feigenbaum, E. A., & Feldman, J. (Eds.), *Computers and Thought* (str. 279-293). McGraw-Hill. Dostupno na: <http://www.jimdavies.org/summaries/newell1963.html>

79. NordVPN. (2024). *Understanding Targeted Cyber Attacks*. Dostupno na <https://nordvpn.com/blog/what-is-a-cyber-attack/>
80. NVIDIA, 2018. *Metropolis - Video Analytics & Applications*. Dostupno na: <https://www.nvidia.com/en-us/metropolis/> [Pristupljeno 7. lipnja 2024.]
81. Ortner, P., Steinhöfler, R., Leitgeb, E., & Flühr, H. (2022). Augmented Air Traffic Control System-Artificial Intelligence as Digital Assistance System to Predict Air Traffic Conflicts. *Journal of Artificial Intelligence*, 3(3), str. 623–644. <https://doi.org/10.3390/ai3030036>
82. Patriarca, R., Di Gravio, G., Cioponea, R., & Licu, A. (2022). Democratizing business intelligence and machine learning for air traffic management safety. *Safety Science*, 146, str. 105530. <https://doi.org/10.1016/j.ssci.2021.105530>
83. Pavlin, S. (2006). *Air Traffic Systems: Components and Management*. Zagreb: Fakultet prometnih znanosti. Dostupno na: <https://www.croris.hr/crosbi/publikacija/rad-ostalo/744852> [Pristupljeno 12. lipnja 2024.]
84. Pinska-Chauvin, E., Helmke, H., Dokic, J., Hartikainen, P., Ohneiser, O., & Garcia Lasheras, R. (2023). Ensuring Safety for Artificial-Intelligence-Based Automatic Speech Recognition in Air Traffic Control Environment. *Aerospace*, 10(11), str. 941. <https://doi.org/10.3390/aerospace10110941>
85. Potgieter, A., 2020. Key drivers for same-day return airline choice of business travellers. A South African community airport perspective. *African Journal of Hospitality, Tourism and Leisure*, 9(3), str. 73-85. Dostupno na: <https://doi.org/10.46222/ajhtl.19770720-5> [Pristupljeno 10. lipnja 2024.]
86. Pradhan, S., Ramshaw, L., Marcus, M., Palmer, M., Weischedel, R., & Xue, N. (2013). CoNLL-2012 shared task: Modeling multilingual unrestricted coreference in OntoNotes. U: Palmer, A., Roukos, S., Martin, D. (Ur.) *Proceedings of the Sixteenth Conference on Computational Natural Language Learning: Shared Task* (str. 1-40). Dostupno na: <https://aclanthology.org/W12-4501>
87. Price, J., & Forrest, J. (2016). *Practical Aviation Security: Predicting and Preventing Future Threats*. Amsterdam: Butterworth-Heinemann. Dostupno na: https://books.google.hr/books/about/Practical_Aviation_Security.html?id=yIt4CgAAQB_AJ&redir_esc=y [Pristupljeno 3. srpnja 2024.]
88. Pritscher, L. Feyen, H. (2001). Data mining and strategic marketing in the airline industry. *Data Mining and Knowledge Discovery*, 39(2001), str. 39-48.

89. Prskalo, M. (2023). Suvremeni kibernetički rizici u upravljanju zračnim prometom, *Zaštita i sigurnost*, (2), str. 132-143. https://www.azur.ba/wp-content/uploads/2023/12/9_Prskalo.pdf
90. Putica, M. (2018). Umjetna inteligencija: dvojbe suvremenog razvoja. *Hum*, 13(20), 198-213. Preuzeto sa <https://hrcak.srce.hr/219733>
91. Ratliff, R., & Vinod, B. (2005). Future of revenue management: Airline pricing and revenue management: A future outlook. *Journal of Revenue and Pricing Management*, 4(3), str. 302-307.
92. Reiter, E., & Dale, R. (2000). *Building Natural Language Generation Systems*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511519857>
93. Reitmann, S., & Schultz, M. (2022). An adaptive framework for optimization and prediction of air traffic management (sub-)systems with machine learning. *Aerospace*, 9(2), str. 77. <https://doi.org/10.3390/aerospace9020077>
94. SAE International. (2018). *Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles*. Dostupno na: https://www.sae.org/standards/content/j3016_202104/ [Pristupljeno 2. srpnja 2024.].
95. Scharpenseel, M. F. (2001). Consequences of EU airline deregulation in the context of the global aviation market. *Journal of International Law and Business*, 22(1), str. 91–116.
96. SEI. (2021). *Understanding Cybersecurity Threats*. Software Engineering Institute. Dostupno na: <https://www.sei.cmu.edu> [Pristupljeno 26. lipnja 2024.]
97. Singh, S., & Singh, M. (2002). Explosives detection systems (EDS) for aviation security. *Microelectronics Reliability*, 42(12), 1787–1798. [https://doi.org/10.1016/S0165-1684\(02\)00391-2](https://doi.org/10.1016/S0165-1684(02)00391-2)
98. Stavridis, J. (2014). *Cybersecurity and Cyberwar: What Everyone Needs to Know*. Oxford University Press.
99. Steiner, H. (1998). Safety Management in Air Traffic Control Systems. *Journal of Air Transport Management*, 4(2), str. 57-64.
100. Strumberger, I., Alimpic, F., & Stojic, A. (2023). Potential of Coupling Metaheuristics-Optimized-XGBoost and SHAP in Revealing PAHs Environmental Fate. *Toxics*, 11(4), str. 394. <https://doi.org/10.3390/toxics11040394>
101. Sun, Y., Zhang, Y., & Li, X. (2019). Predictive Maintenance for Aircraft Systems Using Sensor Data and Machine Learning Algorithms. *IEEE Transactions on Industrial Informatics*, 15(4), 2241-2251.

102. Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction* (2. izd.). Cambridge, MA: The MIT Press. Dostupno na: <https://incompleteideas.net/book/the-book-2nd.html> [Pristupljeno 5. srpnja 2024.]
103. TakeFlight Interactive. (2024). *AI Virtual Flight Instruction*. Dostupno na: <https://takeflightinteractive.com> [Pristupljeno 28. lipnja 2024.]
104. Tian, H., Presa-Reyes, M., Tao, Y., Wang, T., Pouyanfar, S., Miguel, A., Luis, S., Shyu, M.-L., Chen, S.-C., & Iyengar, S. S. (2021). Data Analytics for Air Travel Data: A Survey and New Perspectives. *ACM Computing Surveys*, 54(8), Article 167. <https://doi.org/10.1145/3469028>
105. Tielrooij, M., Borst, M.C., van Paassen, M., & Mulder, M. (2015). Predicting Arrival Time Uncertainty from Actual Flight Information. U: Palmer, C. L., Lambert, G. B., Zink, M. L. C. M. (Ur.). *Proceedings of the 11th USA/Europe Air Traffic Management Research and Development Seminar (ATM 2015)*, Lisbon, Portugal, 23–26 June 2015. Dostupno na: [https://www.researchgate.net/profile/Clark-Borst/publication/283861651_Predicting_arrival_time_uncertainty_from_actual_flight_in formation/links/5651c82508ae4988a7aeb72f/Predicting-arrival-time-uncertainty-from-actual-flight-information.pdf](https://www.researchgate.net/profile/Clark-Borst/publication/283861651_Predicting_arrival_time_uncertainty_from_actual_flight_information/links/5651c82508ae4988a7aeb72f/Predicting-arrival-time-uncertainty-from-actual-flight-information.pdf).
106. Tomorrow.io. (2023). Using Weather AI to Improve Operations in Aviation. Dostupno na: <https://www.tomorrow.io/blog/using-weather-ai-to-improve-operations-in-aviation/> [Pristupljeno 15. lipnja 2024.]
107. Turing, A. M. (1950). *Computing Machinery and Intelligence*. *Mind*, 59(236), str. 433-460. <https://doi.org/10.1093/mind/LIX.236.433>
108. Ucar, A., Karakose, M., & Kırımça, N. (2024). Artificial Intelligence for Predictive Maintenance Applications: Key Components, Trustworthiness, and Future Trends. *Applied Sciences*, 14(2), 898. <https://doi.org/10.3390/app14020898>
109. Ukwandu, E., Ben-Farah, M. A., Hindy, H., Bures, M., Atkinson, R., Tachtatzis, C., Andonovic, I., & Bellekens, X. (2022). Cyber-security challenges in aviation industry: a review of current and future trends. *Information*, 13(3), Article 146. <https://doi.org/10.3390/info13030146>
110. Wang, Y., Gogu, C., Binaud, N., Bes, C., Haftka R. T., Kim, N H. A (2017). Cost driven predictive maintenance policy for structural airframe maintenance. *Chinese Journal of Aeronautics*, 30, str. 1242-1257

111. Wolfe, F. (2020). How Searidge Uses Artificial Intelligence to Revolutionize Airports. *Aviation Today*. Dostupno na: <https://www.aviationtoday.com/2020/06/29/how-searidge-uses-artificial-intelligence-to-revolutionize-airports-air-traffic-management/> [Pristupljeno 8. lipnja 2024.]
112. Wu, J, Hu, K, Cheng, Y, Wang, J, Deng, C, & Wang, Y. (2019). Ensemble recurrent neural network-based residual useful life prognostics of aircraft engines. *Structural Durability Health Monitoring*, 13, str. 317-329.
113. Xie, Y., Pongsakornsathien, N., Gardi, A., & Sabatini, R. (2021). Explanation of Machine-Learning Solutions in Air-Traffic Management. *Aerospace*, 8(8), str. 224. <https://doi.org/10.3390/aerospace8080224>
114. Yang Dai, Robert Raeside, and Austin Smyth. 2005. The use of load factors to segment airline operators. *Journal of Revenue and Pricing Management*, 4(2), str. 195-203.
115. Yaqoobi, M.H. (2020). *Smart Airport: Implementing Smart Technologies in Airports and Their Impact on Operational Efficiency and Passenger Satisfaction* [online]. Dostupno na: <https://www.academia.edu/> [Pristupljeno 26. lipnja 2024.]
116. Yousuf WB, Khan T, Ali T. (2017). Prognostic algorithms for flaw growth prediction in an aircraft wing. *IEEE Transaction on Reliability*, 66, str. 478-486.
117. Zhang, Y., & Zhou, D. (2020). Applications of Artificial Intelligence in Air Traffic Management. *Journal of Air Transport Management*, 90, str. 101935. <https://doi.org/10.1016/j.jairtraman.2020.101935>

POPIS SLIKA

Slika 1. Random Forest (Model Slučajnih šuma)	12
Slika 2. RFID komponente	18
Slika 3. Prvi digitalni kontrolni toranj, Heathrow-London	20
Slika 4. Generički sustav za pregled prijavljene prtljage u liniji	22
Slika 5. Primjer pozitivnih (lijevo) i negativnih (desno) podataka za prepoznavanje objekata	23
Slika 6. Primjer detekcije objekta, a) detektiran pištolj, b) torba bez prijetnji.....	23
Slika 7. Turboventilatorski motor	26
Slika 8. Ležajevi stajnog trapa	26
Slika 9. Hidraulički sustav zrakoplova	27
Slika 10. Senzori na trupu zrakoplova	28
Slika 11. Područja primijene umjetne inteligencije u upravljanju zračnim prometom	32
Slika 12. Pronalazak najpovoljnijih karata korištenjem alata umjetne inteligencije.....	33
Slika 13. Unmanned aerial vehicle (UAV - bespilotna letjelica), MQ-9 Reaper.....	41

POPIS GRAFIKONA

Grafikon 1. Dobna struktura ispitanika	44
--	----

POPIS PRILOGA

Prilog 1. Anketni upitnik

1. Molim Vas da odaberete Vaš spol.
 - a) Muški
 - b) Ženski
2. Koja je Vaša dobna skupina?
 - a) 18-24 godine
 - b) 25-34 godine
 - c) 35-44 godine
 - d) 45-54 godine
 - e) 55-64 godine
 - f) 65 i više godina
3. Koliko dugo radite u Hrvatskoj kontroli zračne plovidbe?
 - a) Manje od 1 godine
 - b) 1-3 godine
 - c) 4-6 godina
 - d) Više od 6 godina
4. Koja je Vaša trenutna pozicija u organizaciji?
 - a) Kontrolor leta
 - b) Inženjer sustava
 - c) Menadžer operacija
5. Koliko ste upoznati s primjenom umjetne inteligencije (UI) u Vašem radu?
 - a) Nimalo
 - b) Malo
 - c) Umjereno
 - d) Puno
 - e) Potpuno
6. Koje alate UI najčešće koristite u svakodnevnom radu?
 - a) Predikcija vremenskih uvjeta
 - b) Optimizacija ruta
 - c) Praćenje performansi zrakoplova
 - d) Analiza sigurnosnih podataka

7. Ocijenite stupanj slaganja s tvrdnjama na skali od 1 do 5 pri čemu 1 podrazumijeva u potpunosti se ne slažem, a 5 u potpunosti se slažem:
 - a) Primjena sustava umjetne inteligencije doprinosi smanjenju kašnjenja letova.
 - b) Primjena umjetne inteligencije značajno poboljšava sigurnost u upravljanju zračnim prometom.
 - c) UI značajno poboljšava sigurnost u upravljanju zračnim prometom.
8. Koje su, prema vašem mišljenju, najveće prednosti korištenja umjetne inteligencije u vašem radu?
9. Koje su najveće prepreke s kojima se suočavate pri implementaciji tehnologija UI?
10. Koliko smatrate da će se primjena tehnologija UI u upravljanju zračnim prometom povećati u narednih 5 godina?
 - a) Neće se povećati
 - b) Malo će se povećati
 - c) Umjereno će se povećati
 - d) Puno će se povećati
 - e) Izuzetno će se povećati
11. Da li ste imali obuku za korištenje tehnologija UI u Vašem radu?
 - a) Da
 - b) Ne
12. Ocijenite stupanj slaganja s pitanjem na skali *Ako ste imali obuku, koliko je ona bila korisna?* od 1 do 5 pri čemu 1 podrazumijeva uopće nije bila korisna, a 5 u potpunosti je bila korisna:
13. Ocijenite u kojoj mjeri se slažete sa sljedećim izjavama o učinkovitosti UI u različitim područjima upravljanja zračnim prometom (pri čemu 1 podrazumijeva u potpunosti se ne slažem, a 5 u potpunosti se slažem)
 - a) UI poboljšava točnost predikcije vremenskih uvjeta.
 - b) UI optimizira rute zrakoplova smanjujući potrošnju goriva.
 - c) Sustavi UI smanjuju broj incidenata i nesreća.
 - d) UI omogućava brže donošenje odluka u kriznim situacijama.
 - e) Sustavi UI olakšavaju praćenje i analizu performansi zrakoplova.
14. Ocijenite u kojoj mjeri se slažete sa sljedećim izjavama o utjecaju AI tehnologija na radnu atmosferu i zadovoljstvo poslom (pri čemu 1 podrazumijeva u potpunosti se ne slažem, a 5 u potpunosti se slažem)

- a) Tehnologije UI smanjuju stres na poslu.
 - b) Korištenje tehnologija UI povećava produktivnost.
 - c) Tehnologije UI poboljšavaju komunikaciju među zaposlenicima.
 - d) Korištenje tehnologija UI povećava zadovoljstvo poslom.
 - e) Tehnologije UI omogućavaju bolju ravnotežu između posla i privatnog života.
15. Koje su, prema Vašem mišljenju, glavne prednosti korištenja umjetne inteligencije u upravljanju zračnim prometom u Hrvatskoj kontroli zračne plovidbe?
16. Koje izazove i prepreke ste do sada primijetili pri implementaciji tehnologija UI u Vašem svakodnevnom radu?
17. Kako vidite budućnost primjene umjetne inteligencije u upravljanju zračnim prometom?
Koje dodatne funkcionalnosti ili poboljšanja očekujete?
18. Koje biste preporuke dali za poboljšanje implementacije umjetne inteligencije u upravljanju zračnim prometom?

ŽIVOTOPIS STUDENTA

Ja sam Bruno Rakonić i živim u Vrbju, malom mjestu pokraj Nove Gradiške. Rođen sam 12. srpnja 2000. godine u Novoj Gradiški. Osnovno obrazovanje započeo sam u područnoj školi u Vrbju, gdje sam pohađao nastavu do četvrtog razreda, a zatim sam nastavio školovanje u osnovnoj školi Ljudevita Gaja u Novoj Gradiški. Nakon završene osnovne škole, upisao sam opću Gimnaziju u Novoj Gradiški. Nakon gimnazije, upisao sam Ekonomski fakultet u Zagrebu, gdje nastavljam svoje obrazovanje.

Uz akademske obveze, od svoje šesnaeste godine profesionalno se bavim glazbom i sviram osam instrumenata. Godine 2024. izdao sam svoju prvu autorsku pjesmu. Nagrađen sam brojnim diplomama na raznim festivalima i usavršavanjima, uključujući pjevačke masterclassove, tečajeve glazbene produkcije i novih tehnologija u glazbi.

Osim glazbe, aktivno se bavim sportom; igram nogomet i redovito posjećujem teretanu.

Što se tiče poznavanja stranih jezika, tečno govorim engleski i koristim se njemačkim jezikom.