

AUFBAU EINES DEMONSTRATORS IM PROJEKT KIEZ4-0 (KÜNSTLICHE INTELLIGENZ EUROPÄISCH ZERTIFIZIEREN UNTER INDUSTRIE 4.0)

Nils Ahrenhold*, Michael Lüttel†

* Deutsches Zentrum für Luft- und Raumfahrt e.V., Institut für Flugführung, Lilienthalplatz 7, Braunschweig, Deutschland

† Deutsche Flugsicherung GmbH, Requirements and Future Systems, Am DFS-Campus 10, Langen, Deutschland

Zusammenfassung

Die Zertifizierung von auf künstlicher Intelligenz (KI) basierenden Flugsicherungskomponenten soll am Beispiel eines Arrival Managers (AMAN), welcher selbständig aus historischen Daten lernt, gezeigt werden. Dieser von der DFS (Deutsche Flugsicherung GmbH) entwickelte AMAN wird hierzu in die Simulationsumgebung des Validierungszentrums Luftverkehr am DLR Institut für Flugführung eingebunden und durch speziell auf die Zertifizierung zugeschnittenen Szenarien analysiert und bewertet. Um den vollen Funktionsumfang des KI-AMAN zu demonstrieren, ist es notwendig, sowohl die Arbeitsposition des Pick-Up-Lotsens als auch die des Feeder-Lotsens nachzubilden. Die beiden Positionen werden nebeneinander mit Radarbild und einem zusätzlichen Monitor zur Darstellung des KI-AMAN aufgebaut. Es werden vier Positionen mit Radar-Ausgabe und Pseudopiloten-Interface eingerichtet, so dass jedem Lotsen zwei Pseudopiloten zugeteilt werden können. Für den Demonstrator wurde der Luftraum Düsseldorf (EDDL) in Landerichtung Südwest ausgewählt. Der Lotsenarbeitsplatz wird als streifenloser Standards-Arbeitsplatz eingerichtet, was bedeutet, dass der Lotse ausschließlich mit dem Radar-Bildschirm und dem separaten AMAN-Monitor interagiert. Der dabei als Unterstützungsinstrument bereitgestellte AMAN basiert auf künstlicher Intelligenz. Zusätzlich ist der Lotse über simulierte Funkfrequenzen per Sprechfunk mit den dem Sektor zugewiesenen Pseudo-Piloten verbunden, welche seine Anweisungen zurücklesen und ausführen. Im Projekt KIEZ4-0 wurden verschiedene Szenarien entwickelt, die darauf ausgelegt sind, den KI-AMAN sowohl im Nominalbetrieb als auch beim Vorliegen außergewöhnlichen Situationen zu testen und daher eine besondere Situation in der Anflugplanung repräsentieren. Hierbei handelt es sich um Situationen, die im Regelbetrieb sehr selten auftreten und daher auch kaum in den Trainingsdaten erfasst werden. Zusätzlich zu den Sonder-Situationen wird eine Variation der Verkehrsmenge in vier Stufen implementiert. Jeder dieser vier Verkehrsmengen wird einmal ohne Sonder-Situation und einmal mit einer Auswahl der oben genannten Optionen simuliert, so dass insgesamt acht unterschiedliche Szenarien modelliert werden. Das Auftreten der Sonder-Situationen ist dabei so angelegt, dass möglichst viele potentielle Änderungen der geplanten Luftfahrzeug-Sequenz initiiert werden. Der Demonstrator setzt sich aus einzelnen Komponenten zusammen, die jede für sich verifizierbar ist. Durch eine Kombination dieser Komponenten lässt sich ein Abbild der Realität aufbauen, welches geeignet ist die Fragestellung hinsichtlich der Zertifizierbarkeit des KI-AMAN zu unterstützen.

Keywords

KI; Zertifizierung; Arrival Manager; Verifikation; Demonstrator

1. ZERTIFIZIERUNG VON KÜNSTLICHER INTELLIGENZ IN DER LUFTFAHRT

Innerhalb der letzten Jahre hält die Entwicklung von Komponenten, die auf künstlicher Intelligenz (KI) basieren, Einzug in nahezu allen Bereichen der Forschung und Industrie. Die Beispiele reichen von KI gestützter Bilderkennungsoftware bis hin zu ersten autonomen operierenden Vehikeln [1]. Dieser Trend setzt sich auch in der Luftfahrt und vor allem im Air Traffic Management (ATM) Umfeld fort. ATM Aufgaben zu denen beispielhaft die Flugplanung oder auch das Verkehrsflussmanagement zählen, sind hoch-

gradig komplexe und repetitive Aufgaben. Aktuell gibt es bereits eine Vielzahl an Unterstützungsinstrumenten für Fluglotsen die zumeist auf konventionellen Algorithmen basieren. KI kann zu Verbesserung und Weiterentwicklung dieser Unterstützungsinstrumente eingesetzt werden, um Aufgaben und Anwendungen, die nicht durch diese konventionelle Algorithmen beschrieben werden können, abzubilden. Durch den Einsatz werden die bestehenden Systeme verbessert oder sogar neue Systeme für autonome Entscheidungsfindung entwickelt. Zwei gegenwärtige Beispiele sind die Prognose von Flugbewegungen

oder Frühwarnsysteme für Kollisionen [2].

Die Entwicklung KI basierter Systeme im Bereich der Luftfahrt, wirft Fragen hinsichtlich ihrer Zertifizierbarkeit innerhalb eines ohnehin schon sicherheitskritischen Systems auf. Daher wird im Folgenden der Begriff KI definiert und die damit einhergehenden Herausforderungen identifiziert. Anschließend werden aktuelle Vorgaben und Regularien der European Union Aviation Safety Agency (EASA) zur Zertifizierung von KI in der Luftfahrt erörtert.

Laut BITKOM ist KI eine Informatik-Anwendung, mit dem Ziel ein intelligentes Verhalten aufzuweisen [3]. Dazu werden vier Kernfähigkeiten definiert: Wahrnehmen, Verstehen, Handeln und Lernen. Das grundlegende Neue ist der Lernprozess einer KI Software, sodass bessere Ergebnisse im Vergleich zu konventionellen Verfahren, die auf fest programmierten Regeln basieren, erzielt werden [3]. Das Teilgebiet des Maschinellen Lernens (ML) wird als eine der Schlüsseltechnologien für KI-Software definiert. Dabei bezweckt ML das Erzeugen von *Wissen* aus *Erfahrung*, indem komplexe Modelle aus Lernalgorithmen entwickelt werden [1]. Diese entwickelten komplexen Modelle können dann im Nachgang auf unbekannte Datensätze derselben Art angewandt werden. So können Prognosen und Entscheidungen generiert werden, ohne vorher ein Regelwerk zu definieren [1]. Diese Entwicklung stellt einerseits eine Erweiterung der heutigen regelbasierten Algorithmen dar, liefert aber andererseits die maßgebliche Herausforderung für die Zertifizierung von KI basierten Systemen in der Luftfahrt. Durch die Erweiterung der konventionellen regelbasierten Algorithmen entstehen nicht deterministische Systeme, deren Modelle und Entscheidungen nicht immer interpretierbar sind [4]. Darüberhinaus muss eine ML Software/System nicht immer zwangsläufig stabil gegenüber Änderungen aus der Umwelt (Eingangsgrößen) sein, auch wenn es einige grundlegende deterministische Eigenschaften aufweist. Aus diesen Gründen dürfen KI basierte Systeme nicht lediglich nach konventionelle Regularien zertifiziert werden. Zugleich entsteht der Bedarf nach neuen Regularien zur Zertifizierung von KI Systemen in der Luftfahrt.

1.1. Stand der Technik und Regularien

Im ATM Umfeld sind aktuell eine Reihe von Anwendungen, die auf ML Methodik basieren, Gegenstand der Forschung [1]. Die Reifegrade und Eigenschaften unterschiedlicher industrieller Anwendungen sind in [1] beschrieben. Generell sind die Reifegrade der ATM Anwendungen im Vergleich zu anderen industriellen Anwendungen relativ gering. Trotzdem stehen einige nicht sicherheitskritische Anwendungen kurz vor der Einführung. Dazu werden nachfolgend einige Beispiele aus dem EUROCONTROL Fly-AI Report

Level 1 AI: human assistance / augmentation

Level 1A: human augmentation

Level 1B: human cognitive assistance in decision and action selection

Level 2 AI: human / machine collaboration

Level 2: human / machine collaboration

Level 3 AI: more autonomous machine

Level 3A: AI-based system performs decisions and actions overridable by the human

Level 3B: AI-based system performs non-overridable decisions and actions

BILD 1. Ausschnitt aus den unterschiedlichen Klassifikationsebenen von KI Systemen gemäß EASA [4]

aufgelistet [2]:

- 1) Prediction of Take Off Time
- 2) Automated Flight Plan Correction
- 3) Airspace Complexity Prediction and Management (Thales)
- 4) Maintenance Costs and Fuel Optimization (Honeywell)

Die EASA hat 2020 hinsichtlich des Umgangs mit KI Systemen in der Luftfahrt zwei Dokumente veröffentlicht. Dabei handelt es sich um eine erste Vorgehensweise und Definitionsgrundlage *Artificial Intelligence Roadmap 1.0* [4], sowie andererseits um ein Konzeptpapier für den Gebrauch von KI in der Luftfahrt *EASA Concept Paper: First usable guidance for Level 1 machine learning application* [5]. Gemäß EASA ist KI *any technology that appears to emulate the performance of a human* [4]. Dabei wird das Augenmerk genauer auf datengetriebenen Lernmethoden, wie ML und Deep Learning (DL), gelegt. Demnach beschreibt ML den Gebrauch von Daten, um die Leistungsfähigkeit und das Ergebnis eines Systems zu verbessern [4]. DL umfasst laut EASA den Einsatz von Neuronalen Netzen (NN), um aus großen Datenmengen zu lernen. Nach der grundlegenden Definition des Begriffs KI, ML und DL schlägt die EASA eine Klassifikation der KI Systeme in unterschiedliche Level vor. Ausschlaggebender Parameter für die Klassifikation ist die Mensch-Maschine-Interaktion. Bild 1 zeigt einen Ausschnitt der EASA Klassifikationsebenen. Das vorliegende Paper beschreibt gemäß diesen Klassifikationen eine Level 1 Anwendung. Thematisiert also die Unterstützung des Menschen in seinem Auswahl- und Entscheidungsprozess. Daher wird hier auf die tiefergreifende Klassifikation der EASA nicht eingegangen. Generell postuliert die EASA die größte Herausforderung in der sogenannten *trustworthiness* von KI Systemen, zu deutsch Vertrauenswürdigkeit [4]. Diese soll laut EASA mittels noch zu definierenden ethischen Grundsätzen geprüft werden.

Es kann festgehalten werden, dass im gegenwärtigen rechtlichen Rahmen sowohl auf internationaler wie auf nationaler Ebene keine Vorgaben für eine Zertifizierung KI basierter Systeme vorhanden sind. Die bestehenden Regularien der Flugsicherung beziehen sich zumeist auf technische Aspekte und sind statischer Natur. Das bedeutet, dass das Testergebnis eindeutig ist und keinerlei Abweichungen zulässt, demzufolge den beschriebenen deterministischen Charakter aufweist. Der Umgang von KI ist in den bestehenden Regularien nicht behandelt und daher für die Zertifizierung von KI basierten Systemen unzureichend. Die von der EASA veröffentlichten Dokumente liefern erste Leitlinien zum Umgang mit KI, sind damit aber nur bedingt nutzbar für eine mögliche Zertifizierung. Daher wird ein umfassendes Konzept benötigt.

1.2. KIEZ4-0

Das Projekt KIEZ4-0 (Künstliche Intelligenz Europäisch Zertifizieren unter Industrie 4.0) soll eine Grundlage für mögliche Zertifizierungskonzepte von KI Systemen in der Luftfahrt schaffen. In diesem Zuge haben sich die beiden Projektpartner Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR) und die Deutsche Flugsicherung GmbH (DFS) dazu entschieden, Möglichkeiten für eine Zertifizierung am Beispiel eines Arrival Managers (AMAN), welcher selbstständig aus historischen Daten lernt, zu demonstrieren. Der AMAN wurde für den Demonstrator ausgewählt, um die Zertifizierungsmethodik für KI im Sinne der Zulassung für die operative Anwendung im Bereich der Flugsicherung validieren zu können. Da die DFS bereits mehrere Arrival Manager im betrieblichen Einsatz hat und diese entsprechend der geltenden Regularien abgenommen und freigegeben worden sind, besteht die Möglichkeit den KI-AMAN gegen eine Referenz zu betrachten, ohne dass diese zusätzlich entwickelt werden müsste. Der Demonstrator wird dann auf Basis der Methodik des EASA Konzeptpapiers [5] aufgebaut. Nachfolgend wird erläutert welche infrastrukturellen Komponenten und Funktionalitäten für einen solchen Demonstrator benötigt werden.

2. INFRASTRUKTURELLE KOMPONENTEN

Der zu entwickelnde mögliche Demonstrator soll eine Grundlage für eine erste Zertifizierung des KI basierenden AMAN darstellen. Hierzu wird der von der DFS entwickelte AMAN in die Simulationsumgebung des Validierungszentrums Luftverkehr am DLR, Institut für Flugführung eingebunden und durch speziell auf die Zertifizierung zugeschnittene Szenarien analysiert und bewertet. Das nachfolgende Bild 2 zeigt die grundlegenden Komponenten des Demonstrators. Neben der KI-AMAN Software werden Lotsenarbeitspositionen (engl. Controller Working

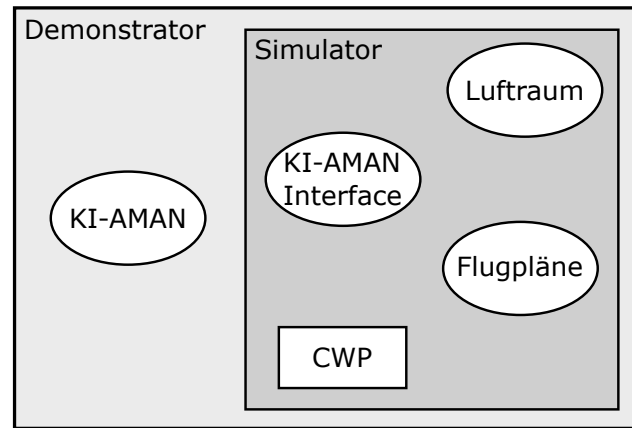


BILD 2. Aufbau und Bestandteile des KI-AMAN Demonstrators; CWP = controller working position

Position - CWP), der zu simulierende Luftraum, Flugpläne, als auch eine Schnittstelle für die Kommunikation und Darstellung des KI-AMAN benötigt. Im Folgenden werden die genannten Komponenten erläutert.

2.1. Air Traffic Management and Operations Simulator

Der Air Traffic Management and Operations Simulator (ATMOS) [6] ist die Radarsimulationsumgebung innerhalb des Validierungszentrums Luftverkehr des DLR, welches schon bei vielen ATM Validierungsstudien sowohl im nationalen als auch internationalen Rahmen eingesetzt wurde. Bei der dahinterliegenden Software NARSIM (NLR Air Traffic Control Research Simulator) handelt es sich um eine generische Echtzeitsimulationssoftware [7]. Der ATMOS ist eine hoch konfigurierbare Simulationsplattform, die in Echtzeit eine Testumgebung für die Forschung liefert. Die Bewegung der Luftfahrzeuge beruht auf einem Energie-Masse-Modell, welches auf der von der europäischen Luftfahrt-Organisation Eurocontrol veröffentlichten Datenbank für Luftfahrzeuge (BADA) aufsetzt [8]. Dies ist das zurzeit verbreitetste und umfangreichste Modell von Luftfahrzeugleistungsparametern zur Benutzung in Simulationen. Es enthält alle gängigen Luftfahrzeugmuster und Flugleistungsprofile. Dadurch wird ermöglicht, realistische Bewegungsprofile von Luftfahrzeugen in der Simulation zu modellieren und darzustellen. Neben den softwareseitigen Bestandteilen, besitzt der ATMOS die folgenden drei physischen Komponenten:

- Lotsenarbeitsplatz - CWP (Radardisplay sowie Funkverbindung zu den Pseudopiloten)
- Pseudopilotenarbeitsplatz (Kommunikation mit den Lotsen und Bedienterminal zur Steuerung der Luftfahrzeuge)
- Supervisorposition (Simulations-/ Stationssteuerung)

Luftraum

Für den Demonstrator wurde der Flughafen Düsseldorf (EDDL) in Landerichtung Südwest (230°) ausgewählt und modelliert. Das Bild 3 zeigt einen bearbeiteten Auszug aus der Aeronautical Information Publication (AIP) der DFS für den Luftraum EDDL, die als Grundlage für die Modellierung verwendet wurde [9]. Das bedeutet, dass sämtliche in dem betrachteten Luftraum vorkommenden Wegpunkte, Flugrouten und Anforderungen (z.B. vorgegebene Flughöhen) exakt wie zu dem veröffentlichtem Zeitraum im Simulator implementiert sind.

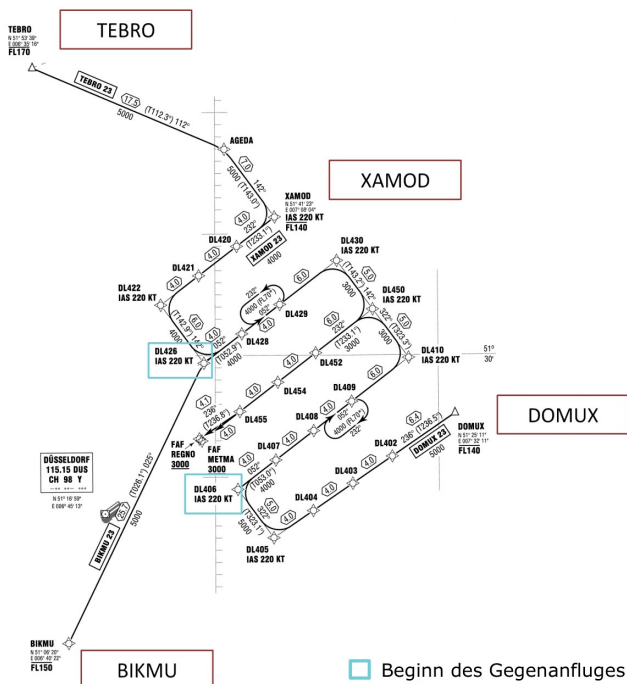


BILD 3. Modellierter Anflugkarte Flughafen Düsseldorf (EDDL), Landerichtung 23 (Quelle [9])

Darüberhinaus sind die Initial Approach Fixe (IAF) (TEBRO, XAMOD, DOMUX und BIKMU) im Bild 3 rot markiert. Über diese Punkte, melden die Luftfahrzeuge ihren Einflug in den Luftraum an. Danach folgen sie bis auf weitere Anweisungen den schwarz eingezeichneten Flugstraßen, exemplarisch der TEBRO23. Die hellblau markierten Wegpunkte (DL426 und DL406) kennzeichnen den Start des Gegenanfluges. Nach Übergabe des Luftfahrzeuges und Neuanmeldung beim Feeder Lotsen, fädelt dieser das Luftfahrzeug in den Endanflugsstrom (DL450 bis REGNO/METMA) ein. Ziel dabei ist, eine bestmögliche Ausnutzung des vorhandenen Luftraums unter Berücksichtigung aller notwendigen Abstände der Luftfahrzeuge zueinander sowie eines möglichst ökonomisch und ökologischen Flugwegs. Ist das LFZ auf dem Endanflugkurs etabliert, wird es an den zuständigen Tower übergeben und von ihm zur Landung freigegeben.

Lotsen- Pseudopilotenarbeitsplatz

Um den vollen Funktionsumfang des KI-AMAN zu demonstrieren ist es notwendig, sowohl die Arbeitsposition des Pick-Up als auch die des Feeder Lotsen nachzubilden, da der KI-AMAN an beiden Positionen eingesetzt wird. Der Pick-Up Lotse übernimmt dabei die Luftfahrzeuge im Bereich der Einflugpunkte in den Luftraum (IAF in Bild 3) und führt sie bis zu einem koordinierten Punkt, im Regelfall den Gegenanflug (DL426 und DL406 in Bild 3). Dort übergibt er sie an den Feeder Lotsen, welcher sie auf den Endanflug führt. Die beiden Positionen werden nebeneinander mit Radarbild und einem zusätzlichen Monitor zur Darstellung des KI-AMAN aufgebaut. Im Pseudopilotenarbeitsbereich werden vier Positionen mit Radar-Ausgabe und Pseudopiloten-Interface eingerichtet, sodass jedem Lotsen zwei Pseudopiloten zugeteilt werden können. Gesteuert wird die gesamte Simulation sowie die insgesamt sechs Pseudopilotenarbeitsplätze vom Supervisor. Dieser besitzt die Möglichkeit, die Arbeitspositionen zu starten, zu stoppen, Simulationsdaten zu sichern, die simulierte Funkverbindung zu initiieren und abhängig vom Ablaufplan das jeweils gültige Szenario zu starten.

Flugpläne - Szenarien

Für den Demonstrator werden Szenarien benötigt um die Funktionalität des KI-AMAN zu testen. Insgesamt wurden acht unterschiedliche Szenarien entwickelt und implementiert, die darauf ausgelegt sind, den KI-AMAN sowohl im Nominalbetrieb als auch beim Vorliegen außergewöhnlicher Situationen zu testen. Hierbei handelt es sich um Situationen, die im Regelbetrieb selten auftreten und daher auch kaum in den Trainingsdaten erfasst werden. Im Einzelnen handelt es sich um:

- 1) Notfälle / priorisierte Luftfahrzeuge
- 2) Bahnsperungen
- 3) Starker Wind
- 4) Nicht kooperativer Pilot (bedingt beispielsweise durch Unerfahrenheit, Kommunikationsproblemen oder technische Probleme am Luftfahrzeug)

Zusätzlich zu den genannten Sonder-Situationen wird eine Variation der Verkehrsmenge in vier Stufen von wenig Verkehr (30 Landungen pro Stunde) bis extremen Verkehr (46 Landungen pro Stunde) implementiert. Jeder dieser vier Verkehrsmengen wird einmal ohne Sonder-Situation und einmal mit einer Auswahl der oben genannten Optionen simuliert, sodass insgesamt acht unterschiedliche Szenarien modelliert werden. Die meisten Szenarien beruhen auf realen Flugplandaten des Flughafens Düsseldorf aus dem Jahr 2018, die den unterschiedlichen Verkehrsbelastungen entsprechen. Lediglich die Flugpläne mit der höchsten Belastung (46 Landungen pro Stunde) sind künstlich konstruiert, um das Verhalten des KI-AMANs auch unter der theoretisch maximalen Verkehrsmenge analysieren zu können. Das Bild 4 liefert einen Überblick über die Zusam-



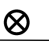


					
1	30 ac/h				
2	30 ac/h	✓	✓		
3	35 ac/h				
4	35 ac/h	✓			✓
5	40 ac/h				
6	40 ac/h	✓		✓	
7	46 ac/h				
8	46 ac/h			✓	✓

BILD 4. Komposition der acht Testszenarien; Spaltenerklärung (Verkehrsvolumen, Notfälle, Start- und Landebahnsperrung, Wind, unerfahrener Pilot; ac/h = aircraft per hour)

mensetzung der einzelnen Szenarien.

Das Auftreten der Sonder-Situationen ist dabei so angelegt, dass möglichst viele potenzielle Änderungen der geplanten Luftfahrzeugsequenz in unterschiedlichen Lufträumen initiiert werden. So treten die insgesamt vier Notfälle an vier unterschiedlichen IAFs auf. Eine detaillierte grafische Darstellung des zeitlichen Ablaufs der einzelnen Szenarien findet hier nicht statt, exemplarisch wird ein Szenarien genauer erläutert. Das nachfolgende Beispiel aus Bild 5 zeigt die Szenarien eins und zwei mit geringem Verkehr. Dabei enthält das erste Szenario keinen Sonderfall. Das zweite Szenario dagegen enthält zwei Notfälle im Abstand von einer Minute und einer Bahnsperrung. Im unteren Teil des Bildes ist eine Zeitleiste aufgetragen. Die roten Balken stellen die prognostizierte Dauer als Basis der neuen Sequenzplanung infolge der Sonder-Situation dar. Zu erkennen ist, dass die Notfälle mit dem Abstand von einer Minute initialisiert werden, um einen möglichst hohen Planungsaufwand für den KI-AMAN zu schaffen. Darüberhinaus werden die Notfälle für Luftfahrzeuge an unterschiedlichen Einflugpunkten initiiert. In Szenario zwei tritt der erste Notfall für ein Luftfahrzeug, welches über den IAF TEBRO (Nordwesten) in den Luftraum eingeflogen ist, auf. Der zweite Notfall wird für ein Luftfahrzeug des IAFs DOMUX (Nordosten) gemeldet.




BILD 5. Zeitlicher Ablauf der Szenarien 1 und 2; rot: Eintrittszeitpunkt inklusive prognostizierte Dauer des Sonderszenarios

2.2. Arrival Manager

In diesem Abschnitt wird der entwickelte KI-AMAN kurz erläutert und seine Funktionalität beschrieben.

Bisher musste bei der Entwicklung eines AMAN (Anflugplanung) das System immer an die speziellen operationellen Anforderungen (Bahnsystem, Anflugverfahren, Prozeduren, usw.) des jeweiligen Standorts und der Arbeitsweisen der Lotsen angepasst werden. Somit waren für jedes AMAN-System für den jeweiligen Standort Veränderungen im Algorithmus der Anflugplanungs-Software notwendig, sodass die speziellen Anforderungen und Arbeitsweisen in der Software abgebildet werden konnten. Die Nutzung von Verfahren aus dem Bereich des ML erlauben es nun, dass dieses Wissen nicht mehr programmiert werden muss, sondern durch Algorithmen aus zuvor aufgezeichneten Trainingsdaten extrahiert werden kann. In diesen lassen sich Kluster identifizieren und zur Berechnung der Sequenz nutzen.

Dazu verwendet der neue Ansatz Klassifikationsverfahren aus dem ML Bereich zur Berechnung der Anflugsequenz. Das Bild 6 verdeutlicht den prinzipiellen Planungsablauf des KI-AMAN. Der Ablauf besteht aus zwei wesentlichen Schritten. Als erstes werden die Positionsdaten im Format ASTERIX CAT62 vom KI-AMAN eingelesen. Dies ist ein von der Eurocontrol definiertes Datenformat zur Übermittlung von Informationen [10]. Im zweiten Schritt werden diese Daten zur Berechnung der Earliest and Latest Estimated Time of Arrival (EETA - LETA) verwendet. Die Estimates sind die geschätzten Flugzeiten von der jeweils aktuellen Flugzeugposition bis zu den Zielpunkten der Landebahnschwelle 23. Bei der Berechnung der Estimates werden die Standardanflugwege, siehe Bild 3, zugrunde gelegt. Es wird die jeweils früheste (Earliest) und späteste (Latest) Ankunftszeit für die Schwelle prognostiziert. Zur Berechnung der Estimates wird ein Regressionsmodell und Verfahren des ML (Gradient Boosting) durchgeführt. Im nächsten Schritt werden die Estimates an die Sequenzplanung übergeben, die mittels eines NN und den Flugplandaten im on-line data interchange (OLDI) Format die Anflugreihenfolge plant [11].

Grundsätzlich kann dabei die Berechnung der Anflugsequenz als Klassifikationsprobleme definiert werden, indem für jeweils zwei Luftfahrzeuge entschieden wird, ob Luftfahrzeug eins vor Luftfahrzeug zwei in der Sequenz geplant wird. Dieser sogenannte Paarvergleich wird sukzessiv für alle Luftfahrzeuge im Luftraum durchgeführt. Das Bild 7 illustriert die unterschiedlichen Eingangsdaten und Einflussfaktoren auf den Entscheidungsprozess des KI-AMAN. Als Eingangsdaten dienen die Radarpositionsdaten (Latitude-, Longitude-Koordinaten) sowie die Flughöhe, die Geschwindigkeit und die Entfernung zum Final Approach Fix (FAF) der Luftfahrzeuge. Weitere Einflussgrößen auf die Sequenzberechnung,

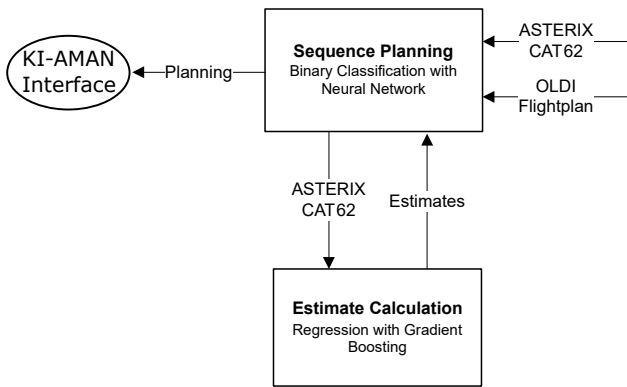


BILD 6. Ablauf der Estimate und Sequenzplanung des KI-AMAN mittels ML Klassifikationsverfahren [12]

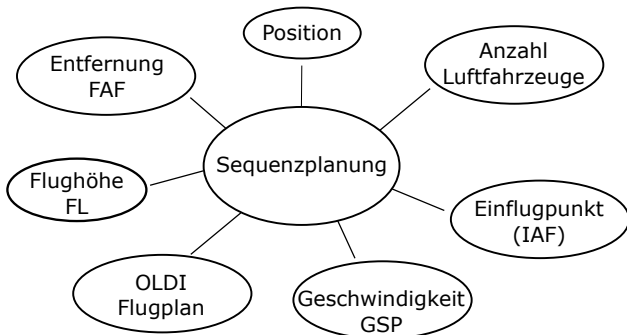


BILD 7. Eingangsdaten und Einflussfaktoren auf die Sequenzberechnung des KI-AMANS; FAF = final approach fix, FL = flight level, GSP = ground speed, IAF = initial approach fix

sind die Anzahl an Luftfahrzeugen im kontrollierten Luftraum und die unterschiedlichen IAF. Während der Trainingphase konnte identifiziert werden, dass mit steigender Anzahl an IAF, die Wahrscheinlichkeit einer korrekten Prognose abnimmt.

Trainingsdaten

Die KI-Trainingsdaten wurden sorgfältig und auf die notwendigen Informationen, die zum Lernen des KI-AMAN notwendig sind, ausgewählt. Damit möglichst realistische Szenarien für die Lernphase genutzt werden, wurden von der DFS gespeicherte Live-Daten aus dem Jahr 2018 herangezogen. Die Daten beinhalten ein hohes Verkehrsaufkommen über einen Zeitraum von 30 Tagen. Dadurch ist die Wahrscheinlichkeit ein breites Szenarienspektrum und unterschiedliche Arbeitsweisen von Feeder und Pick-Up Lotsen abgedeckt zu haben groß. Nach Abschluss der Trainingsphase, wurden das erlernte Modell mit neuen unbekanntem Datensatz (Testdaten) validiert. Die Testdaten bilden nicht nur die entsprechende Situation aus dem operationellen Umfeld sondern auch die tatsächlich durchgeführte Anflugreihenfolge der Luftfahrzeuge ab.

Im Anschluss wurden die Ergebnisse mit einer Referenzkomponente beurteilt und statistisch hinsichtlich ihrer Konsistenz geprüft. Dardurch konnte die tat-

sächlich geplant und geflogene Anflugreihenfolge der Lotsen mit der geplanten Anflugreihenfolge des KI-AMAN verglichen werden. Der KI-AMAN erziele eine korrekte Prädiktion der Anflugsequenz von 95%. Damit ist der KI-AMAN nach seiner Testphase verifiziert und kann in den Demonstrator integriert werden.

Durch das Zusammenspiel der oben erläuterten Bestandteile des Demonstrators ergibt sich die Möglichkeit das Verhalten des KI-AMAN zu bewerten und so letztendlich eine Grundlage für eine mögliche Zertifizierung zu bilden. Da der Fluglotse als Endanwender des KI-AMAN auch ein wichtiger Bestandteil des Zertifizierungssystemes ist, ist es essenziell, Fluglotsen auch bei der Bewertung des Demonstrators einzubinden, um signifikante Abweichungen von der Realität früh zu erkennen und gegenzusteuern. Sodass durch Konsultation eines oder mehrerer erfahrener Lotsen, in dem ausgewählten Luftraum, Verbesserungspotenziale einerseits für den Demonstrator und andererseits für das Verhalten des KI-AMAN identifiziert und in einem weiteren Schritt implementiert werden. Aus diesem Grund wurde eine Verifikationsstudie mit DFS Lotsen am DLR durchgeführt.

3. DEMONSTRATOR VERIFIKATIONSSTUDIE

Die Verifikationsstudie wurde mit insgesamt acht Lotsen am DLR Braunschweig im ATMOS durchgeführt. Dabei arbeiteten die Lotsen im Pick-Up Feeder Paar. Alternierend wurde die acht implementierten Szenarien simuliert, sodass jeder Lotse eins der beiden Paarszenarien (z.B. Szenario drei und vier) in beiden Arbeitspositionen simulieren konnte. In Nachgang erfolgt die Bewertung des KI-AMANS neben der Simulationsdatenanalyse auch anhand zweier ausgearbeiteter Lotsenfragebögen. Dabei handelt es sich einerseits um einen Post Run Questionnaire (PRQ) und andererseits um einen Post Exercise Questionnaire (PEQ). Der PRQ wird von beiden Lotsen (Pick-Up und Feeder) nach jedem Simulationslauf ausgefüllt. Der PEQ hingegen ist ein abschließender Fragebogen, den alle Probanden zum Ende ihrer gesamten Simulationsaufgabe ausfüllen.

Die Fragen des PRQ basieren auf einer fünf Punkte Likert Skala, die in Abhängigkeit des Fragentypus, ihre Antwortmöglichkeiten variiert. Die Likert Skala wird grundlegend dazu verwendet, die Einstellung der Probanden zu einem Thema zu erfassen. Dazu werden mehrere wertende Aussagen formuliert, die mittels der definierten Skala zugestimmt oder abgelehnt werden können. Die Antwortskalen bestehen üblicherweise aus fünf Antwortmöglichkeiten (z.B. Strongly Disagree, Disagree, Neither agree nor disagree, Agree, Strongly Agree).

Die Ergebnisse der jeweiligen Fragen wurden ausgewertet und über alle Probanden der Simulationsstu-

Q2: I was able to plan and organize my work according to my preferences




BILD 8. Exemplarische Auswertung der Fragebögen-ergebnisse; Ergebnisse sind über alle Probanden gemittelt

die gemittelt. Die finale Auswertung der Konsultation und aufgenommenen Simulationsdaten steht noch aus. Das Bild 8 veranschaulicht die beispielhafte Auswertung der Lotsenantworten mittels eines Netzdiagramms. Dabei wurden die Antworten der zwei verschiedenen Arbeitspositionen (Pick-Up, Feeder) gesondert dargestellt, um die Bewertung des KI-AMAN für beide Arbeitspositionen zu differenzieren. Zu erkennen ist, dass vornehmlich der Pick-Up Lotse in den Szenarien mit Sonder-Situationen (S2, S4, S6 & S8) vergleichsweise größere negative Effekte hinsichtlich seiner Planbarkeit empfindet. Ob dieser Effekt eine Konsequenz aus der Nutzung des KI-AMAN ist, muss durch Hinzunahme der Simulationsdatenanalyse und weiteren Fragen bewertet werden. Alle Fragen wurden in Englisch erstellt, da Teile der Fragen aus von der Eurocontrol entwickelten Fragebögen entnommen wurden.

4. ZUSAMMENFASSUNG

Abschließend kann festgehalten werden, dass für den Aufbau eines Demonstrators zur Zertifizierung von KI Systemen in der Luftfahrt eine Vielzahl an Komponenten benötigt werden. Die Integration des DFS KI-AMAN in den ATMOS des DLR Validierungszentrums für Luftfahrt, genauer ATMOS, konnte erfolgreich abgeschlossen werden. Durch die anschließende Verifikationsstudie wurden wesentliche Grundlagen für den Aufbau eines Zertifizierungskonzept gelegt. Zusammenfassend kann außerdem angemerkt werden, dass die Ergebnisse der Testphase als auch erste Ergebnisse der Verifikationsstudie

gezeigt haben, dass das neue ML basierte Prädiktionsverfahren im KI-AMAN Anflugsequenzen mit deutlich besseren Ergebnissen der Anflugreihenfolge als die eines konventionellen AMANs berechnet kann. Damit ist zu erwarten, dass mit dem ML basierten Ansatz eine noch bessere Akzeptanz bei Approach Lotsen als mit dem konventionellen AMAN erreicht werden kann. Ein weiterer Vorteil ist, dass der KI-AMAN nicht mehr durch Programmierung an einen neuen Standort angepasst werden muss. Dies geschieht ausschließlich durch die Trainingsdaten ohne weiteren Programmieraufwand. Die Implementierung für einen neuen Standort kann damit im Gegensatz zu heute, in nur wenigen Tagen durchgeführt werden, wohingegen die Implementierung eines neuen Flughafens mit dem konventionellen AMAN einige Monate dauern kann.

Kontaktadresse:

nils.ahrenhold@dlr.de

Literatur

- [1] Frahofer-Gesellschaft. Maschinelles Lernen. Eine Analyse zu Kompetenzen, Forschung und Anwendung. Standard, Munich, Deutschland, 2018.
- [2] EUROPEAN Aviation Artificial Intelligence High Level Group. The FLY AI Report. Standard, Brussels, Belgium, apr 2020.
- [3] BITKOM e.V. Künstliche Intelligenz Wirtschaftliche Bedeutung, gesellschaftliche Herausforderungen, menschliche Verantwortung. Standard, apr 2017.
- [4] Europeans Union Aviation Safety Agency. Artificial Intelligence Roadmap: A human-centric approach to AI in aviation. Standard, February 2020.
- [5] Europeans Union Aviation Safety Agency. Concept Paper: First usable guidance for Level 1 machine learning application. Standard, April 2021.
- [6] Deutsches Zentrum für Luft- und Raumfahrt e.V., Institut für Flugführung. Air Traffic Management and Operations Simulator (ATMOS). Standard, Braunschweig, Germany, 2019.
- [7] J.M. ten Have, National Aerospace Laboratory NLR, Flight Division. The development of the nlr atc research simulator (narsim). Standard, Amsterdam, Dezember 1992.
- [8] Eurocontrol EEC Technical Report No. 2009-008. Eurocontrol, base of aircraft data (bada) product management document. Standard, Amsterdam, March 2009.

- [9] Deutsche Flugsicherung GmbH. Luffahrthandbuch Deutschland, Düsseldorf EDDL 3-1-6. Standard, Langen, Deutschland, Januar 2018.
- [10] European Organisation for the Safety of Air Navigation. Asterix part 9 category 062 appendix a coding rules for reserved expansion field, edition 1.2. Standard, Juli 2011.
- [11] European Organisation for the Safety of Air Navigation. Eurocontrol specification for on-line data interchange (oldi), edition 5.0, eurocontrol-spec-106. Standard, July 2020.
- [12] Daniel Seidel. Prädiktion von Anflugsequenzen mit Verfahren des maschinellen Lernens. *Innovation im Fokus*, April 2022.