

航空交通管制交信における自動異常検知の手法に関する検討

A Study on Methods for Automatic Error Detection
in Air Traffic Control Communications堤 羅馬[†] 高辻 優太[†] 富田 賢志[†] 鶴岡 慶雅[‡]
Roma Tsutsumi Yuta Takatsuji Kenji Tomita Yoshimasa Tsuruoka

1 はじめに

航空交通管制 (Air Traffic Control, ATC) は、安全かつ円滑な航空交通を確保するために航空機に対して指示を行う業務である。この管制業務の中でも、航空管制官とパイロットとの間で交わされる航空交通管制交信 (ATC Communications, ATCC) は、現在でも音声を用いた無線通信が主流であり、指示をいかに迅速かつ正確に航空機の運航に反映させるかは、管制官とパイロットの能力に依存している [1]。

ATCC において、過去のインシデントや事故には、交信中の誤認識や言い間違いなどのヒューマンエラーが要因となつた例もあり [2, 3]、依然として重大なリスク要因となっている。Moon ら [4] は、空の交通量と航空管制におけるヒューマンエラーには強い関係があることを示した。国内定期航空輸送量は増加傾向にある [5] ことから、ATCC における異常を早期に発見し、管制官やパイロットを支援する仕組みの必要性が高まっている。

これまでにも ATCC の高度化に関する研究が進められており、音声認識 (Automated Speech Recognition, ASR) や自然言語処理を用いた ATCC の文字起こしやコールサインの識別が行われてきた [6, 7]。しかし、従来の研究は復唱やコールサインなど特定の要素に限定されており、長期的な文脈に基づく異常や潜在的リスクの検出には十分対応していない。例えば、ある航空機から着陸のやり直しや離陸準備時間の要求がなされた場合、追加対応が必要となり、その間に他の航空機との交信が滞るため、迅速な指示が求められる ATC では、リスクとなる可能性がある。

本研究では、ATCC に含まれる顕在的な異常に加えて潜在的な異常及びリスクの自動検出を目的として、固有表現抽出 (Named Entity Recognition, NER) モデル [6] の適用によるデータの作成と機械学習を用いた分析手法を検討する。具体的には、交信内容を文字起こしたデータを対象とし、文脈的な不自然さや典型的な誤りパターンを学習したモデルによって、致命的な事故に発展し得る異常な交信を検出する仕組みを構築する。本研究により、ATCC におけるリスクの早期発見と管制支援の自動化に向けた新たな可能性を示すことを目指す。

[†] 東京大学工学部

Faculty of Engineering, The University of Tokyo

[‡] 東京大学大学院情報理工学系研究科Graduate School of Information Science and Technology,
The University of Tokyo

表 1: データ収集のための傍受の対象及び環境

周波数	124.350 MHz (羽田空港タワー管制, C 滑走路)
日時	自: 2025 年 2 月 4 日 15 時 02 分 54 秒 至: 同日 17 時 03 分 26 秒
場所	羽田空港第 2 ターミナル展望デッキ
使用機材	受信機: IC-R6 (アイコム株式会社) PC: MacBook Pro 14-inch, 2021

2 関連研究

ASR によってテキスト化された ATCC には言葉の揺れが含まれるが、Helmke ら [8] は、単語レベルから概念レベルへの変換を行い、この正規化が復唱過誤に信頼性及び頑健性をもたせるために必要であると論じた。Lin ら [9] は、ATCC の音声データをもとにして、音声認識、意味抽出、安全監視からなるフレームワークを提案した。安全監視については、復唱過誤の検出、航空機の整合性の監視、衝突可能性の検知を行った。なお、航空機の整合性の監視と、衝突可能性の検知については、実際の飛行データを用いて行った。Pilmannová ら [10] は、汎用 ASR を用いて復唱過誤の検出を行った。

これらは、いずれも前後の交信での顕在的な復唱過誤の検出に限定しており、3 つ以上の複数の交信にわたる潜在的異常や、混線による音声欠落、応答順序の入れ替えなど、より広範な異常及びリスクの検出には対応していない。本研究ではこれらを補完し、より時間的に長い範囲、及び幅広い異常及びリスクの検出手法を検討する。

3 航空交通管制交信データのベクトル化

3.1 使用したデータ

ATCC というデータの性質上、長時間の ATCC データセットは (特に日本国内においては) 公開されていなかったため、著者の一人が航空無線を傍受し、録音を行った。この点について、電波法第 59 条 [11] を考慮し、傍受した内容は本実験のみに用い、データの公開は行わず、本稿においての説明については仮名化したコールサインを用いる。また、雑音や混線によって音声欠損し得ることについては留意が必要である。

傍受した無線の対象及び環境については、表 1 に示すとおりである。本研究で、データの収集及び実験の

ATCCのテキストデータ	
15:04:00, 管制官,	ab air one two three contact departure one two zero decimal eight
15:04:02, パイロット,	one two zero eight ab air one two three good bye
15:04:38, パイロット,	cd four five six on your frequency we are not ready
15:04:41, 管制官,	cd four five six tokyo tower taxi to holding point charlie two hold short of runway three four right
⋮	



正規化

時刻	話者	コールサイン	指示1	指示2	滑走路	風	セクター	周波数	交差点
15:04:00	管制官	AB123	HANDOFF	None	None	None	DEPARTURE	120.8	None
15:04:02	パイロット	AB123	None	None	None	None	None	120.8	None
15:04:38	パイロット	CD456	None	None	None	None	None	None	None
15:04:41	管制官	CD456	TAXI_TO	HOLD_SHORT_OF	34R	None	None	None	C2
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

図 1: 正規化済みデータの例

対象としたのは、羽田空港のタワー管制で、そのうち C 滑走路を担当する周波数 124.350 MHz である。広帯域ハンディレシーバー (IC-R6 [12]) を 3.5 mm オーディオケーブルで PC (MacBook Pro 14-inch, 2021) へ接続し、Sound eXchange で録音した。録音時の設定は、16 bit, モノラル, 符号付き整数エンコーディング, サンプリング周波数 16 kHz, WAV 形式とした。また、silence オプションを使用し、silence 1 0.1 1% 1 0.5 1% とすることで、無音部分を自動的に除去した。録音した音声と発話開始時間を合わせて記録した。傍受した交信は約 2 時間分で、発話の総数は 535 であった。

3.2 ATCC テキストへの NER 適用

録音した音声を聞き取り、テキスト化した。音声不明瞭な部分については、前後のやり取りから明らかな場合は補完し、不明な場合や音声欠落した部分は空いたままとした。Zuluaga-Gomez ら [6] が公開している NER モデルに、滑走路や風、通信セクター、周波数、交差点のタグを追加して学習したモデルを、収集したテキストに適用し、テキストの単語をコールサイン (航空会社及び便名)、指示、滑走路、風の方向及び速度、セクター (タワー、ディパーチャー、グラウンド等)、周波数、交差点の 7 つと、その他に分類した。NER 結果が誤っている箇所については、著者の一人が目視で修正を行った。

3.3 NER 適用済みデータのベクトル化

ATCC では、発話におけるルールが決まっている。しかし、録音から直接得られたテキストデータには、話者の癖や言い直し等によって、同じ意味を示すが、表現が異なるものが含まれていた。そこで、Helmke ら [8] と同様に、単語レベルから概念レベルへのデータの正規化を行った。正規化の例を表 2、変換後のデータ例を図 1 に示す。なお、None はその列に対応するデータが存在しないことを表す。全ての列で None となる行 (例えば “Good day.” や “Thank you.” など) は情報を含まない

表 2: 正規化の例

NER タグ	単語レベル	概念レベル
周波数	one one eight two two one one eight decimal two two one one eight point two two	118.22
コールサイン	xyz seven eight niner xyz seven eight nine	XA789
交差点	charlie one zero charlie ten	C10

として除外し、全機に対するアナウンスである行は他のデータ行と直接関係のない情報として除外した。発話の総数 535 に対して、正規化後のデータの総数は 507 であった。

概念レベルに変換されたデータを、後述する異常検知手法で扱うためにワンホットベクトルに変換した。また、指定されたウィンドウ幅で、1 つずつスライドさせるスライディングウィンドウ方式で以下の 2 つの設定において複数行を 1 つのベクトルとした。ウィンドウの中で最後の行のラベルをそのベクトルのラベルとした。

- 設定 A: 全ての航空機のデータの中で、時系列順に複数行を 1 つにまとめる (図 2)
- 設定 B: コールサインが等しい (各航空機ごとの) データの中で、時系列順に複数行を 1 つにまとめる (図 3)

時間的特徴量として、最初のデータ記録 (1 行目) を基準時刻 (0 秒) とし、そこからの経過時間 (秒) を使用した。時間差にばらつきが多いことから、この経過時間に 1 秒を加算した値の対数を算出し、得られた対数値を訓練データセットにおける最大値で除することにより、0 から 1 の範囲に正規化した。

先頭のデータや設定 B において交信の数が少ないデータなど、ウィンドウ幅に満たないデータは、データがな

時刻	話者	コールサイン	
15:04:00	管制官	AB123	...
15:04:02	パイロット	AB123	...
15:04:38	パイロット	CD456	...
15:04:41	管制官	CD456	...
⋮	⋮	⋮	⋮

図 2: 設定 A のウィンドウ例 (ウィンドウ幅 = 2)

時刻	話者	コールサイン	
15:04:00	管制官	AB123	...
15:04:02	パイロット	AB123	...
15:04:48	管制官	AB123	...
⋮	⋮	⋮	⋮
15:04:38	パイロット	CD456	...
15:04:41	管制官	CD456	...
15:05:02	パイロット	CD456	...
⋮	⋮	⋮	⋮

図 3: 設定 B のウィンドウ例 (ウィンドウ幅 = 2)

いことを表す値を入れたダミーデータを不足した行数分、先頭に挿入し、他データとの次元数を揃えた。

3.4 アノテーションポリシー

モデル評価のために、以下の方針を基に各データに対して「正常」または「異常」のラベルを付した。

因果律より、その行よりも後に起こったやり取りは考慮せず、それまでの交信から判断して以下の何れかのカテゴリに分類されるとき、異常とした。

カテゴリ 1: 「復唱の間違い、欠け」またはそれに伴う追加の交信があるとき

例えば、図 4 では、“TAXI TO HOLDING POINT C1” と “HOLD SHORT OF RWY (RUNWAY) 34R” という管制官からの 2 つの指示に対し、該当機は 1 つの指示のみを復唱しており、復唱に欠けがあるため 2 行目は「復唱の間違い、欠け」に該当し、異常とする。改めて指示を出している 3 行目、及びその復唱である 4 行目は「復唱の間違い、欠け」に伴う追加の交信に該当するため、異常とする。1 行目が観測された時点では、その後の復唱が欠けることは不明であるため、正常とする。




図 4: 復唱の欠け

カテゴリ 2: 混線によって音声欠落している、または変則的な交信順序であるとき

例えば、図 5 では、“DEF123” の航空機の呼びかけに対し、管制官は “STANDBY BREAK BREAK” と待機指示を出し、“XYZ789” への指示を先に行っている。これは、変則的な順序に該当するため異常とする。3 行目は、2 行目に対する適切な応答であるため正常とするが、4 行目は、後回しにされた 1 行目に対する応答であり、変則的な順序に該当するため異常とする。




図 5: 応答の保留

カテゴリ 3: 着陸復行や風の情報など変則的な要求を行ったとき

例えば、図 6 では、進入中断という変則的な要求及びそれに対する応答があるため、異常としている。

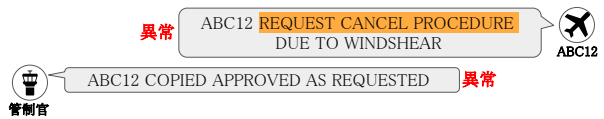


図 6: 進入中断の要求

カテゴリ 4: その他、明らかな誤りや変則的な交信のとき

例えば、図 7 では、交信において必要なコールサインを欠いているため異常としている。



図 7: プロトコル上の誤り

4 航空交通管制交信データの異常検知手法

ウィンドウ幅に関しては、各手法共通で 1 から 9 の範囲で探索を行った。

4.1 Autoencoder

Autoencoder は符号器と復号器を組み合わせたモデルであり、入力データと出力データができるだけ近くなるように学習させることで、異常データについては再構成誤差が大きくなることにより、教師なしでの異常検知が可能な手法である [14]。

本研究におけるモデルは、全結合層と Dropout 層を組み合わせて作成し、活性化関数は ReLU を使

用した。入力するデータの次元はウィンドウ幅によって可変であり、各全結合層の出力次元は符号器については 256, 128, <隠れ層の次元> の順、復号器については <隠れ層の次元>, 128, 256, 入力データの次元の順とした。ハイパーパラメータは、Dropout 率を 0.1, バッチサイズを 128, エポック数を 50 で固定し、隠れ層の次元, 学習率, 異常と判定する閾値について探索を行った。

4.2 One-Class SVM

One-Class SVM は、クラスを 1 つとしたサポートベクターマシンであり、高次元特徴空間で原点からの距離によって正常・異常を判定するという考え方に基づき異常検知を行う手法である。

Scikit-learn の OneClassSVM クラスを使用した。ハイパーパラメータは、kernel を rbf で固定し、nu, gamma について探索を行った。学習には、異常とラベル付けされているデータを含めたまま学習を行った。

4.3 全結合ニューラルネットワーク

作成したベクトルをニューラルネットワーク (NN) の入力とし、正常または異常の二値分類タスクを行うモデルとして学習させることで異常検知を行うことが可能である。

本研究においては、5 層の全結合層を用いた NN を作成し、活性化関数は ReLU を使用した。各全結合層の出力次元は 512, 256, 128, 64 の順とした。ハイパーパラメータは、Dropout 率を 0.3, バッチサイズを 128, エポック数を 100 で固定し、学習率, 異常と判定する閾値について探索を行った。

4.4 Random Forest

Random Forest は、多数の決定木を組み合わせたアンサンブル学習の手法であり、正常と異常の 2 値分類を教師あり学習で行うことで、異常検知が可能である。

Scikit-learn の RandomForestClassifier クラスを使用した。ハイパーパラメータは、n_estimators, max_depth, max_features, class_weight について探索を行った。

5 ATCC データの異常検知結果

5.1 評価方法

5 分割交差検証を行い、後述の各異常検知手法で正解率, 適合率, 再現率, F1 スコアを計算し、Optuna ライブラリ [13] を用いて各分割の F1 スコアの平均が最大となるパラメータを探索し、その時の平均 F1 スコアを評価基準とした。Optuna の探索において、サンプラーには TPESampler を使用し、ランダムサンプリングを行う試行回数 n_startup_trials を 500 回, 全体の試行回数 n_trials を 1500 回に設定した。

5.2 最高平均 F1 スコアとそのパラメータ

教師なし学習の Autoencoder と One-Class SVM において、最も高い F1 スコアを記録したときの各スコアを表 3 に示す。

Autoencoder は設定 A で F1 スコア 0.339, 設定 B で 0.379 を記録した。そのときのパラメータは、設定 A で隠れ層の次元=64, 学習率=0.00295, 閾値=0.00853,

表 3: 教師なし学習手法の結果

異常検知手法	項目	設定 A	設定 B
Autoencoder	正解率	0.661	0.740
	適合率	0.234	0.275
	再現率	0.785	0.730
	F1 スコア	0.339	0.379
One-Class SVM	正解率	0.505	0.639
	適合率	0.185	0.226
	再現率	0.921	0.848
	F1 スコア	0.294	0.339

表 4: 教師あり学習手法の結果

異常検知手法	項目	設定 A	設定 B
全結合 NN	正解率	0.893	0.913
	適合率	0.513	0.631
	再現率	0.557	0.498
	F1 スコア	0.519	0.548
Random Forest	正解率	0.901	0.915
	適合率	0.480	0.682
	再現率	0.435	0.415
	F1 スコア	0.448	0.468

ウィンドウ幅=3 であり、設定 B で隠れ層の次元=8, 学習率=0.00111, 閾値=0.00984, ウィンドウ幅=4 であった。

One-Class SVM は設定 A で F1 スコア 0.294, 設定 B で 0.339 を記録した。そのときのパラメータは、設定 A で nu=0.161, gamma=0.611, ウィンドウ幅=2 であり、設定 B で nu=0.171, gamma=0.514, ウィンドウ幅=2 であった。

これらは、全て異常と判断するモデル (F1 スコア: 0.219) や異常の数が全体に対して占める割合を確率としてランダムに判断するモデル (F1 スコア: 0.210) よりは良いスコアを記録しているため、一定の学習はできていると言える。

教師あり学習の全結合 NN と Random Forest において、最も高い F1 スコアを記録したときの各スコアを表 4 に示す。

全結合 NN は設定 A で F1 スコア 0.519, 設定 B で 0.548 を記録した。そのときのパラメータは、設定 A で学習率=0.00904, 閾値=0.171, ウィンドウ幅=3 であり、設定 B で学習率=0.00443, 閾値=0.580, ウィンドウ幅=3 であった。

Random Forest は設定 A で F1 スコア 0.448, 設定 B で 0.468 を記録した。そのときのパラメータは、設定 A で n_estimators=158, max_depth=10, max_features=None, class_weight='balanced', ウィンドウ幅=2 であり、設定 B で n_estimators=181, max_depth=11, max_features=None, class_weight=None, ウィンドウ幅=3 であった。

全ての手法において、航空機ごとにウィンドウでベクトルを作成した設定 B における F1 スコアが高くなるという結果が得られ、Autoencoder で 4%, One-Class SVM で 4.5%, 全結合 NN で 2.9%, Random Forest で

表 5: 各手法・設定における異常カテゴリ別再現率

手法	設定	異常カテゴリ 1 (全 19 件)	異常カテゴリ 2 (全 7 件)	異常カテゴリ 3 (全 36 件)	異常カテゴリ 4 (全 3 件)	適合率 (全体)
Autoencoder	A	17/19 = 89.5%	5/7 = 71.4%	23/36 = 63.9%	3/3 = 100.0%	23.4%
	B	17/19 = 89.5%	2/7 = 28.6%	27/36 = 75.0%	0/3 = 0.0%	27.5%
One-Class SVM	A	19/19 = 100.0%	7/7 = 100.0%	28/36 = 77.8%	3/3 = 100.0%	18.5%
	B	18/19 = 94.7%	4/7 = 57.1%	26/36 = 72.2%	3/3 = 100.0%	22.6%
全結合 NN	A	6/19 = 31.6%	1/7 = 14.3%	31/36 = 86.1%	1/3 = 33.3%	51.3%
	B	5/19 = 26.3%	1/7 = 14.3%	29/36 = 80.6%	1/3 = 33.3%	63.1%
Random Forest	A	5/19 = 26.3%	2/7 = 28.6%	26/36 = 72.2%	0/3 = 0.0%	48.0%
	B	4/19 = 21.1%	1/7 = 14.3%	24/36 = 66.7%	1/3 = 33.3%	68.2%

2.0% 高かった。

また、ウィンドウ幅は 1 から 9 の範囲で探索を行ったが、Autoencoder の設定 B の 4 が最高であり、異常を精度良く検知するためにはこれより大きなウィンドウ幅は必要ない可能性が高いということがわかった。また、ウィンドウ幅については設定 A と設定 B での大きな違いは見られず、手法ごとに違いが見られた。

5.3 異常カテゴリごとの検出結果

それぞれの異常検知手法が異常と予測したうち、3.4 節で述べた異常カテゴリに対してどの程度検知できているか（再現率）を表 5 に示す。

One-Class SVM は設定 A、B ともにすべてのカテゴリで比較的高い再現率となっており、広範な異常の検知が可能である一方、正常データを異常と判断してしまうことが多いため、適合率が著しく低く、F1 スコアは最も低くなっている。

全結合 NN や Random Forest といった教師ありの手法は、カテゴリ 1、2 と比べてカテゴリ 3 の異常の検知に有効であると言える。これはカテゴリ 1、2 を検知するためには内容の欠落や順序の異常のような交信における構造的な異常を検知することが必要であるのに対し、カテゴリ 3 は変則的な要求という意味内容の異常を検知することが必要であるという違いがあることによると考えられる。変則的な要求の際に“request”のような特定のフレーズが現れ、内容に特徴が現れるため、教師あり学習ではその特徴を異常であるとして学習することにより検知の精度が比較的高いと考えられる。

カテゴリ 2 において、全てのモデルで設定 A の再現率が設定 B のそれ以上という結果になった。これはカテゴリ 2 の異常は複数の航空機間にわたる音声の欠落や不自然な交信順序を表すため、航空機ごとではなく全体的な流れを把握することができる設定 A の方が適していることを示唆していると言える。

5.4 教師なし学習の結果

3.4 節で示した正解ラベルに基づいて計算した教師なし学習の F1 スコアは、最高でも Autoencoder の設定 B の 0.379 であり、教師あり学習ほど高いスコアにはなら

なかった。しかし、アノテーション時には見つけるに至らなかった異常またはリスクの発見につながった。

例として、アノテーションでは正常としてラベルづけされている ATCC の一部を以下に示す：

① 15:09:21, 管制官：

AB98 TOKYO TWR RWY34R AT C2 LINE-UP-AND-WAIT EXPECTED DEPARTURE IN 2 MIN.

② 15:09:28, パイロット：

ROGER, C2 RWY34R LINE-UP-AND-WAIT AB98.

③ 15:10:39, 管制官：

AB98 WIND 320 AT 9 RWY34R AT C2 CLEARED-FOR-TAKEOFF.

④ 15:10:45, パイロット：

AB98 RWY34R C2 CLEARED-FOR-TAKEOFF.

この ATCC は、管制官が AB98 便に対して離陸のための滑走路待機の指示 (LINE-UP-AND-WAIT) と離陸許可 (CLEARED-FOR-TAKEOFF) をしている部分である。パイロットは、管制官の指示に対して正しく復唱しており、順序にも問題はないため、正常データとしてラベル付けをし、全ての教師あり学習手法において正常として分類された。しかし、3 行目と 4 行目に対して、全ての教師なし学習手法が異常として分類した。ここで、該当箇所注目してみると、1 行目で管制官は滑走路待機の指示をしているが、同時に下線部で出発に 2 分かかることを述べている。実際、2 行目と 3 行目の時間を見てみると、離陸許可が出るまでに 1 分以上経過していることがわかる。したがって、滑走路待機から離陸許可までに時間がかかることは、その航空機が滑走路を長時間占有することを意味し、リスクになりうる。

6 おわりに

本研究では、著者自身で ATCC の録音を行い、これを文字起こししたテキストデータに対して、NER と正規化の処理を適用し、全航空機を時系列順にウィンドウでまとめる設定 A と航空機ごとに時系列順にウィン

ドウでまとめる設定 B の 2 つの設定においてベクトルを作成した。それを入力とし、教師なし学習として Autoencoder と One-Class SVM, 教師あり学習として全結合 NN と Random Forest を用いた異常検知を試みた。実験の結果, 全結合 NN の設定 B において最も高い F1 スコア (0.548) を記録し, 有効性の一端が確認された。教師なし学習では, 高い再現率を記録したが, 適合率が低くなり, F1 スコアとしては低いものであった。ただし, 今回のデータのアノテーションにおいては, 時間差を考慮したラベル付けを行っていないため, 異常とラベル付けはされていないが潜在的なリスクである箇所を検知できている可能性を示した。

従来研究では, 復唱過誤やコールサインの誤認といった単一発話内の明示的な異常に焦点を当てるものが多かったのに対し, 本研究では, 応答順の乱れや補完的なやり取り, 変則的な要求など, 複数発話にわたる文脈的・潜在的な異常, 及びリスクも含めて検出対象とし, 異常カテゴリごとの再現率を示した。2 つの設定や各手法によるスコアの違いが見られ, 複数の手法を組み合わせた異常検知も有効であると考えられる。

一方で, 使用したデータは約 2 時間分, 535 発話に限られており, モデルの汎化性能や異常パターンの網羅性には限界がある。今後, より多くのデータを収集及び学習に活用することで, 検出精度のさらなる向上が期待される。また, 異常の定義やラベリングには航空管制業務に関する専門的知識が不可欠であり, 専門家との連携によるアノテーションの精度向上も重要な課題である。

今後は, 精度を向上させるために, 大規模データセットの用意, モデル構造の最適化を行い, 実用的な支援システム構築に取り組んでいきたい。

参考文献

- [1] 長岡栄, “航空管制技術の変遷,” 電気学会誌, vol.134, no.4, pp.220-223, April 2014.
- [2] W.J. Chang, E.M. Wang, W.L. Tsai, W. Hsu and J.R. Yen, “A Human Factors Analysis of Miscommunication Between Pilots and Air Traffic Controllers in Taiwan,” 2007 International Symposium on Aviation Psychology, pp.128-132, Dayton, Ohio, USA, April 2017.
- [3] 運輸安全委員会, “航空重大インシデント調査報告書 AI2010-7-1,” Oct. 2010.
- [4] W.C. Moon, K.E. Yoo and Y.C. Choi, “Air Traffic Volume and Air Traffic Control Human Errors,” Journal of Transportation Technologies, vol.1, no.3, pp.47-53, July 2011. DOI:10.4236/jtts.2011.13007
- [5] 国土交通省総合政策局情報政策課交通経済統計調査室, “航空輸送統計速報 (令和 6 年 (2024 年) 分),” March 2025.
- [6] J. Zuluaga-Gomez, K. Veselý, I. Szöke, A. Blatt, P. Motlicek, M. Kocour, M. Rigault, K. Choukri, A. Prasad, S. Saeed Sarfjoo, I. Nigmatulina, C. Cevenini, P. Kolčárek, A. Tart, J. Černocký and D. Klakow, “ATCO2 corpus: A Large-Scale Dataset for Research on Automatic Speech Recognition and Natural Language Understanding of Air Traffic Control Communications,” Nov. 2022. DOI:10.48550/arXiv.2211.04054
- [7] R. García, J. Albarrán, A. Fabio, F. Celorio, C.P. Oliveira and C. Bárcena, “Automatic Flight Callsign Identification on a Controller Working Position: Real-Time Simulation and Analysis of Operational Recordings,” Aerospace, vol.10, no.5, Article 433, May 2023. DOI:10.3390/aerospace10050433
- [8] H. Helmke, M. Kleinert, S. Shetty, O. Ohneiser, H. Ehr, H. Arilfusson, T.S. Simiganoschi, A. Prasad, P. Motlicek, K. Vesely, K. Ondřej, P. Smrz, J. Harfmann and C. Windisch, “Readback Error Detection by Automatic Speech Recognition to Increase ATM Safety,” Fourteenth USA/Europe Air Traffic Management Research and Development Seminar (ATM2021), Sep. 2021.
- [9] Y. Lin, L. Deng, Z. Chen, X. Wu, J. Zhang and B. Yang, “A Real-Time ATC Safety Monitoring Framework Using a Deep Learning Approach,” IEEE Transactions on Intelligent Transportation Systems, vol.21, no.11, pp.4572-4581, Nov. 2020. DOI:10.1109/TITS.2019.2940992
- [10] T. Pilmannová, A. Kalanin and S. Schmidt, “Incorrect Read-back Detection in Air Traffic Control,” Transportation Research Procedia, vol.81, pp.256-265, Jan. 2024, DOI:10.1016/j.trpro.2024.11.027
- [11] デジタル庁, “電波法第五十九条,” e-Gov ポータル, <https://laws.e-gov.go.jp/law/325AC000000131#Mp-Ch-5-Se.1-At.59>, 参照 April 3, 2025.
- [12] アイコム株式会社, “IC-R6 | 製品情報,” <https://www.icom.co.jp/lineup/products/IC-R6/>, 参照 April 3, 2025.
- [13] T. AKiba, S. Sano, T. Yanase, T. Ohta and M. Koyama, “Optuna: A Next-generation Hyperparameter Optimization Framework,” Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, pp.2623-2631, New York, USA, July 2019. DOI:10.48550/arXiv.1907.10902
- [14] C. Zhou and R.C. Paffenroth, “Anomaly Detection with Robust Deep Autoencoders,” Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 665-674, New York, USA, August 2017. DOI:10.1145/3097983.3098052