

航空機騒音の音響情報を用いた機械学習による機種識別

森長 誠*

Aircraft model identification using acoustic information of aircraft noise by machine learning

Makoto MORINAGA*

1. はじめに

近年、欧米諸国を中心として、環境騒音による生理ストレス反応が心血管系疾患の罹患リスクを増大させるとの見解を示す研究が盛んに報告されている[1]。この背景の下、2018年にWHO欧州事務局が環境騒音ガイドライン[2]を策定し、騒音レベルの勧告値が示された。一方、我が国における各種の交通騒音の環境基準は、いずれも制定から数十年が経過しており、2020年に環境省は、騒音の環境基準の再評価を行うための検討業務を実施し、欧米とは身体的・社会文化的な違いがありWHOの勧告値をそのまま我が国に適用することは困難であるため、我が国独自のデータに基づいて騒音の曝露-反応関係を構築することが必要不可欠であるとの意見がなされた。特に航空機騒音に関しては調査事例が殆ど無く、調査の実施と騒音曝露量に対する各種アウトカムの発生割合（曝露-反応関係）の把握が喫緊の課題とされている[3]。

騒音の曝露-反応関係は社会調査や疫学調査によって反応データを収集するのはもちろん、長期間を代表する騒音の曝露量を推計する必要がある。民間空港や自衛隊・米軍飛行場の周辺において、長期間を代表する航空機騒音の曝露状況を面的に推定するためには、機種別および離着陸別の音源データ、飛行経路、飛行回数をパラメータとした予測計算によるノイズマップの作成が必要である。これらのパラメータの内、機種別および離着陸別の飛行回数に関して、国または航空会社が主体の調査では実際の運行記録を使用できるが研究ベースでの調査の多くは、空港の時刻表やWeb上で公開されているAutomatic Dependent Surveillance-Broadcast (ADS-B)の記録等により回数を推定している。しかしながら、時刻表は必ずしも実績と一致しないことやADS-Bでの捕捉に必要なMode Sのトランスポンダ信号を発信していない航空機も存在するなど、いずれの推定にも誤差が生じる。自衛隊の飛行場周辺の調査でも、米軍飛行場の場合は、飛行実績に関する情報の入手が困難であると考えられ、また、自衛隊機・米軍機ともに、一部の輸送機以外はMode Sのトランスポンダ信号を発信しておらず、ADS-Bを利用した回数の推定は不可能である。このため、我々は、航空機騒音の発生源となる機種を無人で識別することを目的として、音響情報を用いた機械学習による機種

識別システムの開発を進めている。本稿では大阪国際空港および成田国際空港の周辺で取得した騒音データから機種識別を試みた結果を紹介する。

2. 本稿で使用している機械学習の手法

本稿で紹介する手法は、教示あり学習であるConvolutional Neural Network (CNN)を使用している。CNNは主として画像識別の分野で用いられる手法であり、画像の色の濃淡を2次元の数値データに変換することで分析が可能となる。色のRGBも考慮する場合、3次元の配列による数値データでの分析となる。本稿の分析では、単発騒音イベントにおける1s間隔の1/3オクターブバンドレベルの数値データを使用しており、最大騒音レベル($L_{A, Smax}$)の時点を中心として前後30sの1分間のデータを用いた(計60コマのデータ)。1/3オクターブバンドレベルの中心周波数は20Hzから16kHzまでの30帯域である。これらの 30×60 (周波数 \times 時間)の2次元マトリクスの数値データを用いて分析に使用した。CNNには様々なアーキテクチャが提案されているが、本稿ではResidual Neural Networkの一種である、ResNet-50を使用し、学習のフレームワークにはMXNetを使用した。その構成の概要をFig.1に示す。ResNet-50の仕様上の関係で、入力データは 224×224 のサイズに変換している。

3. ケーススタディ1:1地点の着陸音のみを対象とした事例

3-1. 入力データ

CNNは教示あり学習であるため、機械学習の入力データである音響情報に加え、その音源が何であるか定義するための正解ラベルを付与する必要がある。これらの情報を収集するため、大阪国際空港の着陸経路の直下(滑走路端から5km離れた地点)に該当する位置においてフィールド調査を行い、長期間の録音と、ADS-Bによる機体情報の収集をおこなった。フィールド調査は2017年12月~2018年2月までの69日間、無人で連続記録をおこなった。全て、着陸の音である。録音は全天候型ウィンドスクリーンを装着したサウンドレベルメータ(Rion, NL-52)をPCに接続してハードディスクに記録した。周波数重み特性はZである。

*助教 建築学科

Assistant Professor, Dept. of Architecture

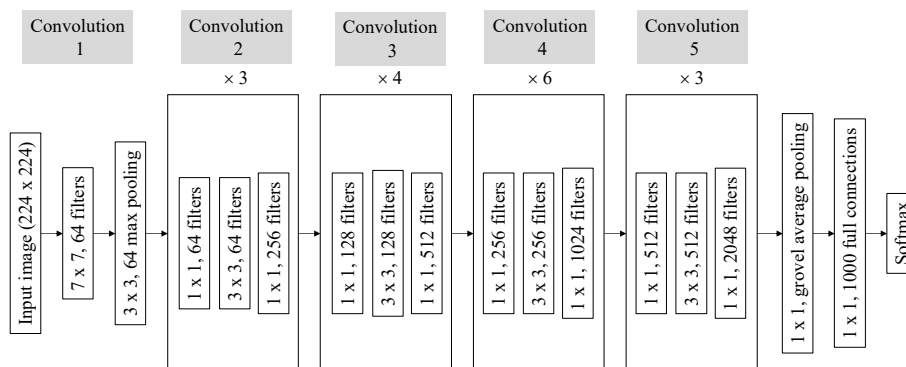


Fig. 1 Structure of CNN used in this study (ResNet-50)

Table 1 Targeted noise sources used for classification in case study 1

No.	Classification ID	Aircraft model	Engine type	Number of data
1-1	B737_CFM56_LD	B737-700 B737-800	CFM56-7	1821
1-2	B767_CF6_LD	B767-300	CF6-80	989
1-3	B777_PW4000_LD	B777-200 B777-300	PW4000	771
1-4	B787_TR1000_LD	B787-8 B787-9	Trent 1000	361
1-5	CRJ700_CF34_LD	CRJ700	CF34	298
1-6	A32_CFM56_LD	A320 A321	CFM56-5	52
1-7	ATR42_PW100_LD	ATR42	PW100	52

ケーススタディ 1 で対象とした音源を Table 1 に示す。表中の No. 1-1～1-6 はジェット機であり、No. 1-7 はターボプロップ機である。総データ数は 4344 である。一般的に、同じ機種であっても、搭載しているエンジンが異なれば音響情報も異なる。このため、フィールド調査で収集した ADS-B 情報から、個々の航空機騒音イベントにおける機体の固有情報を入手し、搭載しているエンジンの型式を同定し、識別の分類を構築した。Table 1 で示した No. 1-1～No. 1-7 の音源について、入力したサウンドスペクトログラム画像のサンプルを Fig. 2 に示す。図の横軸は時間、縦軸は周波数、色の濃淡は音圧レベルの強さを意味する。いずれの音源も広帯域ノイズであることがわかる。また、目視でそれぞれの特徴を把握することは非常に困難である。

3-2. 識別制度を評価する方法

分析は 10 分割交差検定を採用し各音源の識別精度を評価した。すなわち、学習とテストのデータ比は 9:1 であり、この比率でランダムに選択された学習データとテストデータの組み合わせによる分析を 10 回繰り返した。識別精度の評価には、全体の正答率 (Accuracy)、各音源の適合率 (Precision)、再現率 (Recall)、F-measure を指標とした。Accuracy は、予測と実測が一致した回数を全サンプル数で割った値である。この値は、入力された全てのデータのうち、何割のデータを正しく識別できたかを表している。Precision と Recall, F-measure の算出方法を以下の式で示す。TP (True Positive) は、ある音源に属するデータを正しく識別した数であり、FN (False Negative) は、その音源には属しないと誤識別した数であ

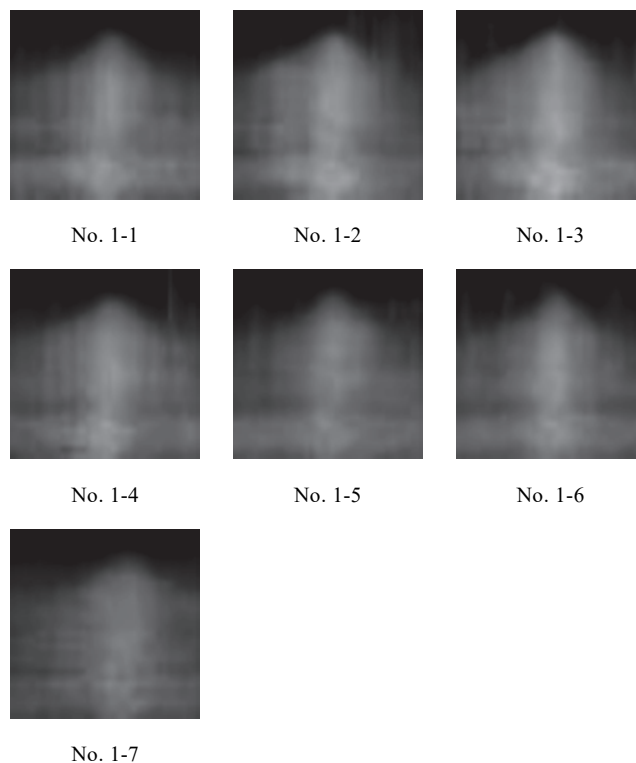


Fig. 2 Images of time-frequency characteristics of aircraft noises used as input data to CNN in case study 1

Table 2 Correspondence of test-data prediction and correct answer in 10-fold cross validation in case study 1

No.	Classification ID	N	Precision	Recall	F-measure
1-1	B737_CFM56_LD	1821	0.995	0.996	0.995
1-2	B767_CF6_LD	989	0.993	0.995	0.994
1-3	B777_PW4000_LD	771	0.994	0.994	0.994
1-4	B787_TR1000_LD	361	0.989	0.983	0.986
1-5	CRJ700_CF34_LD	298	0.990	0.990	0.990
1-6	A32_CFM56_LD	52	0.981	0.981	0.981
1-7	ATR42_PW100_LD	52	1.000	0.981	0.990
Accuracy = 0.996					

る．一方で TN (True Negative) は、ある音源に属さないデータをその音源ではないと正しく識別した数であり、FP (False Positive) はその音源に属すると誤識別した数である．ここで記号「 i 」は音源番号を意味する．

$$\text{Precision}_i = \frac{TP_i}{TP_i + FP_i} \quad (1)$$

$$\text{Recall}_i = \frac{TP_i}{TP_i + FN_i} \quad (2)$$

$$\text{F-measure}_i = \frac{2 \times \text{Precision}_i \times \text{Recall}_i}{\text{Precision}_i + \text{Recall}_i} \quad (3)$$

3-3. 識別結果

テスト結果を Table 2 に示す．Accuracy は 99.6% と非常に高い値であり、諸外国における機械学習を用いた先行研究[4-7]の結果と比較しても正解率が高い結果であった．また、Accuracy だけでなく、Precision や Recall, F-measure のいずれも非常に高い値となっていることが分かる．

4. ケーススタディ 2：離着陸音が混在する条件での事例

4-1. 入力データ

分析に用いた音源とそのデータ数を Table 3 に示す．これらは成田国際空港の飛行経路の直下付近における 3 カ所において、延べ 10 日間の測定で得られたデータ数である．測定はいずれも冬期に実施されたものであり、2016 年および 2017 年の 12 月に測定されたデータを用いた．測定機器はケーススタディ 1 と同じサウンドレベルメータを用いている．測定地点は滑走路端から 1 km ～ 20 km の範囲に位置し、いずれも飛行経路の直下に位置する．ケーススタディ 1 とは異なり、測定期間中の風向きの変化により、離着陸音と着陸音が混在している．このため、ケーススタディ 2 では、エンジン型式のみならず、離着陸の違いも考慮した分類をおこなった．表中に示す「Classification ID」は、分析で識別対象とした「機種・エンジン型式・離着陸」の音源種別である．今回は、全 52 種類の音源の中から、データ数が 100 以上であった 18 種類の音源を採用して分析を行った．ここでのデータは有人測定によって得られたものであり、正解ラベルは人が測定中に目で判断して記録したものである．Table 3 で示した No. 2-1 ～ No. 2-18 の音源について、入力したサウンドスペクトログラム画像のサンプルを Fig. 3 に示す．図の横軸は時間、縦軸は周波数、色の濃淡は音圧レベルの強さを意味する．

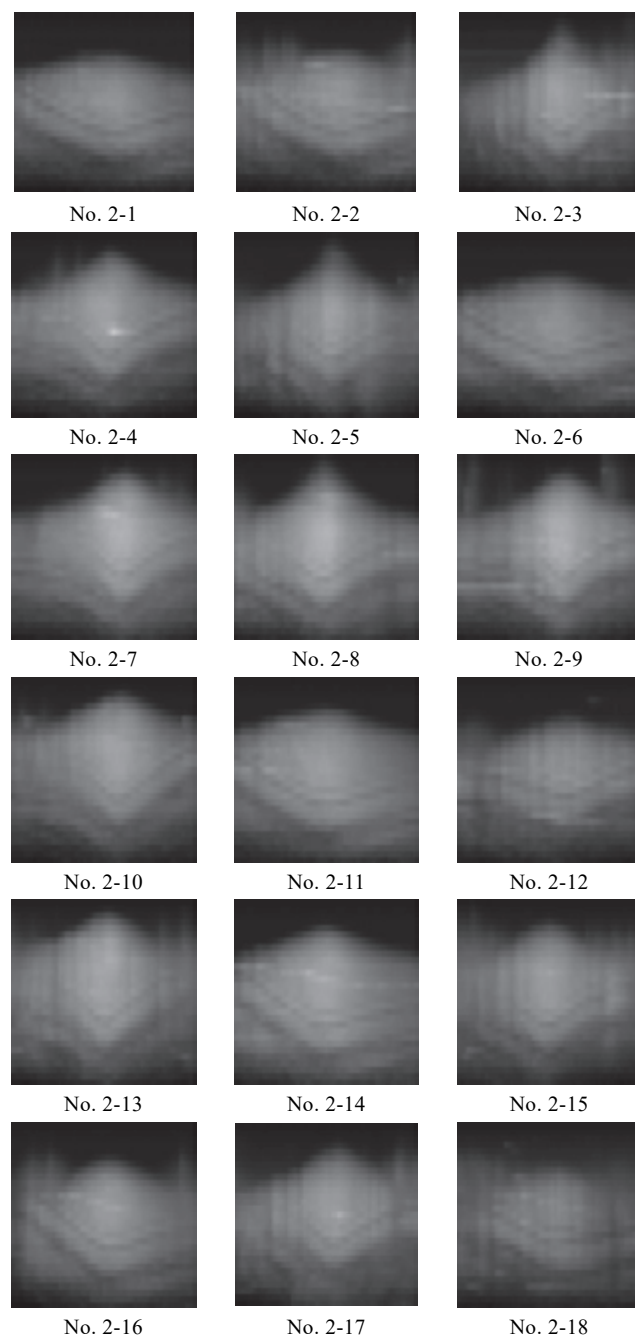


Fig. 3 Images of time-frequency characteristics of aircraft noises used as input data to CNN in case study 2

Table 3 Targeted noise sources used for classification in case study 2

No.	Classification ID	Aircraft model	Engine type	Number of data
2-1	A32_CFM56_TO	A320	CFM56-5	195
2-2	A32_V25_TO	A320 A321	V2527 V2530 V2533	302
2-3	A32_V25_LD	A321	V2530 V2533	110
2-4	A33_TR772_LD	A332 A333	TRENT 772	132
2-5	B737_CFM56_LD	B737-700 B737-800 B737-900	CFM56-7	191
2-6	B737_CFM56_TO	B737-700 B737-800 B737-900	CFM56-7	224
2-7	B747_CF6_LD	B747-400	CF6-80	146
2-8	B747_PW40_LD	B747-400	PW4056	144
2-9	B747_GEnx-2_LD	B747-8	GEnx-2	186
2-10	B767_CF6_LD	B767-300	CF6-80	631
2-11	B767_CF6_TO	B767-300	CF6-80	437
2-12	B777_GE90_LD	B777-200 B777-200LR/F B777-300ER	GE90-90 GE90-110 GE90-115	788
2-13	B777_PW40_LD	B777-200	PW4077 PW4090	189
2-14	B777_GE90_TO	B777-200 B777-200LR/F B777-300ER	GE90-90 GE90-110 GE90-115	265
2-15	B787_GEnx-1_LD	B787-8 B787-9	GEnx-1	249
2-16	B787_GEnx-1_TO	B787-8 B787-9	GEnx-1	245
2-17	B787_TR1000_LD	B787-8 B787-9	TRENT 1000	328
2-18	B787_TR1000_TO	B787-8 B787-9	TRENT 1000	162

4-2. 識別精度を評価する方法

ケーススタディ 1 と同じ方法で、識別精度を評価した。

4-3. 識別結果

テスト結果を Table 4 に示す。ケーススタディ 1 と同様に、Accuracy は 98.3% と非常に高い値であった。ケーススタディ 1 と比較すると、F-measure はわずかに低下したが、それでも 95.5～99.8% の範囲であり、非常に高い識別性能を有しているといえる。No. 2-7 と No. 2-8 の F-measures が相対的に低く、これらの音源における全 17 件の誤識別の内、47% に該当する 8 件はこの 2 つの音源を互いに誤識別したものであった。同じく、No. 2-15 と No. 2-17 における誤識別の総数 29 件のうち、48% に該当する 14 件は、やはりこの 2 つの音源を互いに誤識別したものであった。

ケーススタディ 2 では同じ機種・エンジン型式であっても、離陸と着陸を識別できるか検討したが、離陸音と着陸音の誤識別はほとんど見られなかった。

5. 考察

5-1. ノイズマップ作成における機械学習の有効性

本研究では、2 つの異なる飛行場それぞれでの測定環境で収集した音源データを用いて機械学習を行い、その有効性を検討した。いずれの飛行場も飛行経路の直下の測定点で得られた音響データを用いており、その範囲内では極めて高い識別が可能であることがわかった。しかしながら、ここでの学習結果が他の飛行場で測定したデータに適用可能であるか検討できていないことが一つの課題と

Table 4 Correspondence of test-data prediction and correct answer in 10-fold cross validation in case study 2

No.	Classification ID	N	Precision	Recall	F-measure
2-1	A32_CFM56_TO	195	0.974	0.969	0.972
2-2	A32_V25_TO	302	0.997	0.993	0.995
2-3	A32_V25_LD	110	0.991	1.000	0.995
2-4	A33_TR772_LD	132	0.992	0.955	0.973
2-5	B737_CFM56_LD	191	0.984	0.995	0.990
2-6	B737_CFM56_TO	224	0.987	0.987	0.987
2-7	B747_CF6_LD	146	0.953	0.966	0.959
2-8	B747_PW40_LD	144	0.958	0.951	0.955
2-9	B747_GEnx-2_LD	186	0.995	0.989	0.992
2-10	B767_CF6_LD	631	0.986	0.992	0.989
2-11	B767_CF6_TO	437	0.989	0.986	0.987
2-12	B777_GE90_LD	788	0.986	0.986	0.986
2-13	B777_PW40_LD	189	0.995	0.958	0.976
2-14	B777_GE90_TO	265	0.996	1.000	0.998
2-15	B787_GEnx-1_LD	249	0.960	0.964	0.962
2-16	B787_GEnx-1_TO	245	0.980	1.000	0.990
2-17	B787_TR1000_LD	328	0.961	0.966	0.964
2-18	B787_TR1000_TO	162	0.981	0.975	0.978
Accuracy = 0.983					

考えている。今回構築した学習機に別の飛行場周辺で測定された音源データを入力し、正しく判定がなされるか検証したい。

また、ノイズマップの作成には、飛行場周辺で広範囲に広がるあるゆる飛行経路ごとの機種別の飛行回数を把握する必要があるが、必ずしも飛行経路の直下で測定できないような環境もあり得る。そのような測定環境の場合、音の伝搬過程において地表面影響による音の超過減衰が生じ、受音点における周波数特性に変化が生じる(主に、高周波数帯域の減衰が生じる)。同じく、今回の分析で用いたデータはいずれも冬季に収集されたデータであるが、音の空気吸収は季節によって異なる(正確には気圧、湿度により吸収量が異なる)。このような、同じ飛行場の周辺であっても、異なる測定環境で学習機を汎用的に利用可能といえるか検討することも重要である。ただし、広い範囲を対象とした汎用的な学習に関しては、実測データのみでは限界があるため、シミュレーションを活用した学習データの構築に取り組んでおり、今後の重要課題の一つと位置づけている。

5-2. 誤識別に見られた特徴

ケーススタディ 2 では、いくつかの音源で、やや識別制度が低いものが見られ、No. 2-7 と No. 2-8 を相互に間違え、また No. 2-15 と No. 2-17 を相互に間違えるケースがいくつか見られた。この 2 組には、同型機種で異なるエンジンを搭載した着陸音という共通の特徴がある。一方で同型機の離陸音である No. 2-16 と No. 2-18 の F-measure はいずれも高い識別率となっている。航空機は着陸時に推力を絞るため、様々な音源で構成される航空機騒音全体に対するエンジン音の寄与が相対的に低下し、空力音等のエンジンに由来しない音の寄与が増加する。このため、特に着陸音に関してはエンジンのジェットノイズだけでなく、機体の空力音も主たる音源である可能性があり、今回、そのことが識別率の低下の原因であるかもしれない。

5-3. 入力データの作成方法の検討課題

今回の分析では、1 s 間隔の 1/3 オクターブバンドノイズレベルを用いたが、時間間隔を 0.1 s など、さらに細かい間隔で入力することにより、識別精度を向上できる可能性がある。また、筆者らの先行研究[8]で行ったような、FFT による入力データの分析は行っていない。このような、より精緻な入力データによる分析は、今後の課題である。入力データの時間範囲に関しては、今回は経験則的に 60 s を採用したが、最適化計算を行うことで、どの程度の長さが良いか、検討する余地も残されている。これは周波数範囲に関しても同様のことが言える。森長ら (2018) [9]では、ジェット航空機の識別には、画像の中心付近である $L_{A, Smax}$ 時点の周辺の特徴だけでなく、接近時の高域の情報も特徴的であり、この傾向は、とりわけ離陸音で顕著であることを示している。これらも参考に、適切な周波数・時間範囲の検討が必要であると考えられる。

5-4. 音以外の情報の併用

ジェット機を対象とした識別精度の向上には、機体の写真など、音響特徴量以外のデータを用いた分析も有効であると考えている。実際に、航空機の画像による機械学習で機種識別を行った先行研究が存在している[10-12]。これらの研究で分析対象とされている機種数は必ずしも多くなく、またその識別率は研究によって様々であるが、CNN を適用した結果も報告されている[13]。機体のサイズやドアの位置の違いなど、視覚情報においては比較的分かりやすい特徴を利用することが可能であると思われる。ただし、夜間や悪天候時、あるいは草木で空が見えづらい等、視認性の悪い環境も想定しておく必要があるため、音響情報による識別と視覚情報による識別の併用が望まれると考えている。

6. おわりに

著者らは機械学習による環境音の識別に取り組んできており、本稿では、Deep Neural Network の一手法である CNN を用いたジェット航空機の機種識別の事例を紹介した。エンジンの型式や離着陸の違いを考慮した 18 種類の音源の識別であっても、全体の Accuracy は非常に高い結果であった。現在は、本稿に示した課題を精査しつつ、道路交通騒音や鉄道騒音など、さらに異なる音源を対象としたケーススタディを実施しており、今後、より本システムの実用性や汎用性を高めていきたいと考えている。

参考文献

- [1] E. van Kempen, M. Casas, G. Pershagen and M. Foraster, WHO Environmental Noise Guidelines for the European Region: A Systematic Review on Environmental Noise and Cardiovascular and Metabolic Effects: A Summary, *Int. J. Environ. Res. Public Health*, 379, 15 (2018).
- [2] World Health Organization, Environmental Noise Guidelines for the European Region (2018).
- [3] 森長誠, 我が国の曝露反応関係に基づいた航空機騒音の基準についての考察, 日本騒音制御工学会秋季研究発表会, 115-118 (2020).
- [4] V. Quaranta, I. Dimino, Experimental Training and Validation of a System for Aircraft Acoustic Signature Identification, *Journal of Aircraft*, 44(4), 1196-1204 (2007).
- [5] L. A. Sanchez-Perez, L. P. Sanchez-Fernandez, S. Suarez-Guerra, M. G. Lopez-Pacheco, Dynamic hierarchical aggregation of parallel outputs for aircraft take-off noise identification, *Engineering Applications of Artificial Intelligence*, 46, 33-42 (2015).
- [6] L. A. Sánchez-Pérez, L. P. Sánchez-Fernández, S. Suárez-Guerra, J. J. Carbajal-Hernández, Aircraft class identification based on take-off noise signal segmentation in time, *Expert Systems with Applications*, 40, 5148-5159 (2013).
- [7] V. Quaranta, I. Dimino, A method for acoustic signature identification of aircraft, *Proc. ICSV 12 (Lisbon, 2005)*.
- [8] J. Mori, M. Morinaga, I. Yamamoto, T. Matsui, Development of a system for identifying aircraft type acoustically using a convolutional neural network, *Proc. Inter-Noise 2017 (Hong Kong, 2017)*.
- [9] 森長誠, 森淳一, 山元一平, 松井孝典, 川瀬康彰, 花香和之, Convolutional Neural Network によるジェット航空機の機種識別, 日本音響学会 2018 年 2 月騒音・振動研究会資料 (東京, 2018)
- [10] F. Saghafi, S. M. Khansari Zadeh, V. Etminan Bakhsh, Aircraft Visual Identification by Neural Networks, *Journal of Aerospace Science and Technology*, 5(3), 123-128 (2008).
- [11] A. G. Karacor, E. Torun, R. Abay, Aircraft classification using image processing techniques and artificial neural networks, *International Journal of Pattern Recognition and Artificial Intelligence*, 25(8), 1321-1335 (2011).
- [12] K. Roopa, T. V. Ramamurthy, Aircraft Recognition System Using Image Analysis, *Emerging Research in Electronics, Computer Science and Technology, Lecture Notes in Electrical Engineering*, 248, 195-204 (2014).
- [13] R. Mash, B. Borghetti, J. Pecarina, "Improved Aircraft Recognition for Aerial Refueling Through Data Augmentation in Convolutional Neural Networks", *ISVC 2016, Part I, LNCS 10072*, 113-122 (2016).