

研究報告

航空機騒音測定における深層学習による音源識別の利用と課題*

大島 俊也(航空環境研究センター 主任研究員)

1. はじめに

航空機騒音に係る環境基準に準じた測定は原則として連続7日間行い、騒音レベルの最大値が暗騒音より10 dB以上大きい航空機騒音について、単発騒音暴露レベル(L_{AE})を計測し、夕方と夜間の補正をしたうえで1日分のデータをエネルギー平均した時間帯補正等価騒音レベル(L_{den})を基本評価量として算出する。

今日、騒音計は本体内部またはSDカードに大きなデータ保存容量を持ち、騒音レベルの数値データとともに長時間のWAV音声データも保存できる(録音できる)。航空機騒音の測定の様子を図1に示す。測定は基本的に無人で行い、空港周辺に複数の測定点を配置して、測定員がデータ回収やバッテリー交換のため定期的に見回る方法が用いられることが多い。測定者は録音データをあとから聞いて、航空機騒音の測定で対象としない自動車騒音や救急車のサイレンなどの影響を確認しながら分析することができる。しかし、データの容量が大きくなればなるほど音源を手動で識別する作業は膨大となり労力が増大する。

大量のデータから音源を自動的に識別する技術を向上させることは、このような分析作業の労力を軽減するばかりでなく、将来的には、分析作業自体も自動化することで、ある地域の音環境に対して航空機騒音がどの程度その環境の良し悪しに影響しているかを常時監視局の年間を通したデータから評価することにも繋がる。

筆者はこれまで小規模なディープニューラルネットワーク(Deep Neural Network ; DNN)を用いて環境音をリアルタイムに音源識別し測定しながら音源別に仕分けする方法について検討してきた¹⁾⁻³⁾。これを航空機騒音に特化した音源

識別に応用することを検討する。本論では、深層学習(ディープラーニング)による音源識別の考え方と利点を整理するとともに、実際の空港周辺で得られた測定データに対して、DNN識別器が航空機騒音を精度よく検出しているかどうかを確認し、測定場所の背景音の違いや風雨など気象条件の違いが識別結果にどのように影響しているかなど実用化に向けた今後の課題を整理する。




図1 航空機騒音の測定の様子

2. 深層学習による自動音源識別の基本的な考え方

図2に示すような生物の神経回路網を模倣したニューラルネットワークによる高度な情報処理を目指した研究は1940年代から始まったが、実際に図2下に示すような多段のネットワークの計算を行おうとすると計算誤差が蓄積して各ノードに繋がる係数(重み)を適切に計算することが難しかった。昨今、Hintonらの研究⁴⁾をきっかけに多層のネットワークを用いたディープラーニングが再び注目を集め、現在、画像検索、自動翻訳、自動車の自動運転など様々な分野で応用が進ん

* Advantages and current problems of sound source identification by deep learning in aircraft noise measurement

でいる。Hintonが用いた手法の考え方は、①すべての入力に対して自身を再現しようとする2層のネットワーク(自己符号化器)を多段化した教師なし学習によるプレトレーニングと、②それで得た係数を初期値として教師有り学習であるファインチューニングを行うことで、膨大な入力データに共通する特徴的な部品を中間的な層で抽出しながらそれらの組み合わせとして出力層の各ノードを結びつけるルートが効率よく学習される。

2.1. 深層学習による音源識別の特徴

従来から航空機騒音の音源識別で用いてきた線形判別分析(Linear Discriminant Analysis ; LDA)などの古典的な機械学習法では、基本的には識別するために用いる特徴量を人為的に見つける作業が必要であったが、昨今脚光を浴びているディープニューラルネットワーク(Deep Neural Network ; DNN)では、多くの教師データ





図2 神経細胞とそれを模倣したニューロンとディープニューラルネットワーク(全結合)

に内在する特徴量が学習の過程で自動的に抽出される。この特徴量の抽出能力の高さがDNNによる識別が優位性を示す要因と考えられる。

2.2. 主な深層学習の手法

一口に深層学習と言っても種々の手法が開発されており、日々研究が進んでいる。以下に、音源識別に利用できそうな代表的な深層学習の手法の概要を示す。図2下に示した入力層と出力層が複数の隠れ層で結び付いた構造は、各層のノードが次の層の各ノードにすべて結び付いた「全結合型」と呼ばれる。

一方、昨今、画像認識などでよく用いられるDNNの構造は図3に示す「CNN (Convolutional Neural Network)」と呼ばれるもので、画像などの二次元データを入力とする。カメラで用いられる種々のフィルタに相当する畳み込み層のあと、空間的な位置ずれなどの影響を緩和するプーリング層の組み合わせを一つの単位としてこれを何度か繰り返し、入力画像群の特徴量を抽出し、後段の全結合層の出力として識別情報を得る。環境騒音の識別の場合も、ある時刻の周波数スペクトルを一定の時間間隔で並べたスペクトログラム

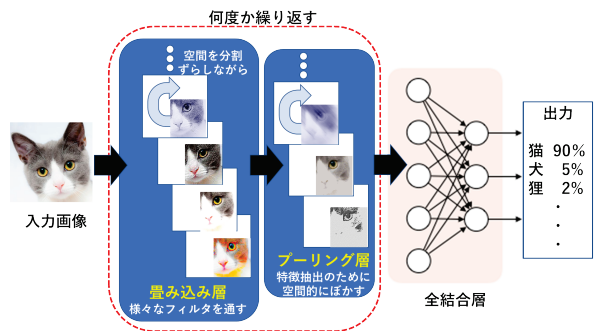


図3 画像認識に用いられるCNNの構造

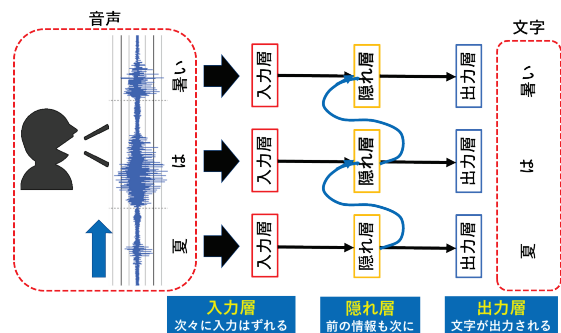


図4 音声認識に用いられるRNNの構造

を画像入力とすることで音源識別の機能を持たせることができる。

他方、音声認識などでは、言葉の一連の時間的な繋がりから次の言葉がある程度推測できることを模擬した「RNN (Recurrent Neural Network)」が頻繁に用いられる。図4にRNNの基本的な構造の概念図を示す。前の文節の情報を次の音節の判定にも一部含めることで自然な音節の繋がり学習される。

全結合だけを用いるより、ある程度の時間間隔の情報を持つCNNの方が識別能力は高い、さらに時間的な繋がり情報も特徴量とするRNNの方がさらに高い識別能力を持つと考えられる。しかし、航空機騒音単独であれば、時間的なスペクトル変化が特徴的に表れる場合でも、予期せぬ自動車騒音やカラスの声などのランダムな重畳が環境騒音の場合は頻繁に現れるため、学習データには出現可能性のあるあらゆる音源と、それらの時間的なずれ具合も含むあらゆる組み合わせのデータが必要となる。またDNNの構造が複雑になればなるほどそれに見合った大量の学習データが必要となる。このようにDNN構造の規模と学習データの量との関係で、どの手法を用いるのが適切かは状況に応じて検討する必要があると考えられる。

たとえば、防災放送が住宅地域にどのように伝搬していくのかを多数の測定点で観測する例⁵⁾で

は、音を測定している傍からリアルタイムで識別結果を次から次へと表示する必要がある。このような場合にはDNNの構造はむしろ小規模として識別能力を多少抑えたとしてもリアルタイム性をより重視する方が有利と考えられる。また学習データの良し悪しなど様々な検討を行う場合でも小規模なDNNで計算時間を抑えて多くのケースを試算した方が有利な場合もある。

3. 一般環境騒音用の音源識別器の作成

航空機騒音を含む環境音には様々な音源が含まれ、複数の音が混在することも少なくない。また、同じ航空機騒音でも、背景に小鳥の声が微妙に含まれる、あるいは風雨の音が重なる場合もあり単純ではない。DNNなどの機械学習による識別器の作成には一般に大量の学習データが必要となるが、長時間の測定後に得られた音データに対して音源種類のラベル付けを行う作業(アノテーションと呼ばれる)は人手で行うため非常に負荷が高く時間が掛かる。このアノテーション作



図5 MIDIキーボードを利用した
現場アノテーション用ツール




図6 環境音のリアルタイム自動音源識別のための
DNNの構造と入出力のイメージ

業の負荷を多少なりとも避けるひとつの方法として、現場で数時間程度、実際の音を目と耳で確かめながらその場で教師情報を入力することを検討した²⁾。図5に示すような入力デバイスにテンキー端末あるいはMIDI端末を用い、各キーに音源を対応付けて音源の発生状況に応じてキーを1つまたは複数同時に押すことでそれらの音源のフラグを立ててタイムスタンプとともに記録する。

3.1. DNN 音源識別器の作成方法

今回用いた音源自動識別では、初期段階の検討ということで、分析機能付き騒音計本体でリアルタイム演算可能な1/3オクターブバンドレベルを特徴量として入力する全結合型の小規模のDNNを用いる(図6)。DNNの入力層には1/3オクターブバンド毎の短時間 $L_{eq,1s}$ のレベル値を0~1に正規化した値を入力し、出力層には学習時に正解情報として各音源カテゴリの発生有無を表す1または0のフラグを与える。DNNの構造は、入力層33ノード、第一隠れ層20、第二隠れ層10、出力層55の全結合型の4層構造とした。入力データは1/3オクターブ12.5~20 kHzの33バンドの値である。出力層の55ノードには各音源カテゴリ番号が対応する。なお、同時に発生した複数音源の各々を検出させるため、出力層の活性化関数をシグモイド関数としてマルチラベル分類を行う。なお、DNNの構造は全結合型に拘るわけではなく、目的に応じてより識別精度の向上が見込めるCNNやRNNの構造に順次更新していく予定である。

3.2. 一般環境騒音の学習データ取得

今回、一般環境騒音の基本的な音源識別器を作成するのに用いた学習データの取得場所4箇所の音源内容を表1に示す。表1の①に示すデータが道路交通騒音、鉄道騒音、航空機騒音、自然音などがバランス良く入ったベースとなる学習データであり、不足する音源データを順次これに追加することになる。

4. 航空機騒音測定データへの音源識別の適用と利点

前章に示した一般環境騒音の音源識別用の学習データに、さらに民間空港の飛行経路直下のデータを加えたのち作成したDNNを用いた音源識別を、二つの空港A、Bの周辺の複数の測定点で夏季と冬季に実施した騒音測定の結果に適用し、識別器がうまく機能するかどうかを確認する。なお、測定は夏季と冬季にそれぞれ1週間実施した。

4.1. 飛行経路直下の航空機騒音の追加学習

前章で説明した環境騒音全般を対象とする識別器を作成する際に用いた学習データには、民間空港周辺の飛行経路直下のデータがほとんど含まれていなかったため、今回識別対象とした空港とは異なるC空港周辺で過去に測定したデータを既存の学習データに追加して、改めてDNN識別器を作成した。C空港は様々な航空機の機種が飛来するため、航空機騒音の学習データを作成するのに都合が良い。用いたデータは、C空港の南ランウェイ端から2 km程度の飛行経路直下の測定

表1 一般環境騒音用の学習データの取得場所と内容

地域	主な音源	概要
①都立公園を中心としたエリアの外周道路	道路交通騒音、鉄道騒音、航空機騒音、鳥の声等の自然音や話し声等の人の活動に伴う音などの多様な環境音	外周道路(2車線)の歩道上などに設けた計15点(Pt.1~15)の時間を同期した多点測定を実施し、代表する2点で現場アノテーションを行って学習データに用いた。
②民間空港のランウェイ側方	航空機の地上騒音と飛行騒音	①の測定データには空港近傍で観測される騒音レベルの大きい航空機騒音のデータが不足していたため、民間空港の近傍で測定した。測定時期は初夏であったがセミはまだ鳴いていなかった。
③軍用飛行場の飛行経路直下	騒音レベルの大きい戦闘機などの航空機騒音	上記と同様の理由で、特に騒音レベルが極端に大きい軍用航空機の騒音データを取得した。
④セミが多く鳴く林のある地域	複数のセミの声	セミの声が複数聞こえる場所であるが、他の騒音源との重畳データは取得しにくい。

点で10月のある1日分の航空機騒音である。周辺の暗騒音が小さく航空機騒音がS/N良く測定できているため、一日分の測定データのうち、騒音レベル60 dB以上の区間を航空機騒音の単独のデータとしてフラグ付けして既存の学習データに追加した。ここでは詳しく述べないが、一般環境騒音用の識別器に比べて、航空機騒音に対する誤識別は、夏季と冬季双方で大幅に減り正解率が向上した。

4.2. 実測データに対する識別率の算定

飛行経路直下の航空機騒音のデータを追加して新たに作成したDNN識別器を用いて、各空港周辺の測定点に配置した騒音計で昼夜を問わず一週間連続で計測されたデータを1秒毎にすべて識別した。具体的には、時定数1秒 (Slow) とした1/3octバンドレベルの0.1秒毎のサンプル値を10個ずつパワー合成して、 $L_{eq,1s}$ の近似値とした12.5 Hz~20 kHzの33バンドの値を入力としてDNN識別器に通して数十種類の音源に対する存在確率を計算した。結果は、20分毎に分割した時系列データを各音源に対する確率を色分けして整理した。

識別結果から航空機騒音の識別率を算定する際のルールを以下に示す。なお、あるイベント区間が航空機騒音であるかどうかの正解値は、レベル波形の形状や実際に録音データを耳で確認するなどの作業を行って判定している。

- (1) 航空機騒音イベント区間の航空機騒音の識別確率が概ね0.8以上である場合を○とする。
- (2) 航空機騒音の識別確率が0.5程度である場合を△として○とともに正解とする。
- (3) 航空機騒音の識別確率がそれ以下の場合×として不正解とする。

このルールに従ってA、B空港のデータを識別した結果をそれぞれ表2.1と表2.2に示す。表中でグレーに網掛けしたデータ総数が10個に満たない測定点を除いてみると、ほとどの測定点でも正解率が95%を超えている。ただし、A空港の測定点bとdだけは正解率がそれぞれ81.3%と71.4%と低い値となっている。これは後で課題として述べるが、背景騒音としてセミの声の騒音レベルが大きい条件である。

表2.1 A空港測定データに対する航空機騒音識別結果

測定点	夏季のある1日				冬季のある1日			
	○	△	×	正解率	○	△	×	正解率
a	—	—	—	—	37	1	0	100.0
b	23	3	6	81.3	33	1	0	100.0
c	49	2	0	100.0	59	0	3	95.2
d	6	4	4	71.4	46	3	1	98.0
e	18	0	0	100.0	—	—	—	—
f	15	0	0	100.0	34	0	0	100.0
g	—	—	—	—	30	0	0	100.0
h	3	0	0	100.0	16	0	0	100.0
i	3	0	0	100.0	0	0	0	—

表2.2 B空港測定データに対する航空機騒音識別結果

測定点	夏季のある1日				冬季のある1日			
	○	△	×	正解率	○	△	×	正解率
a	0	0	0	—	6	1	0	100.0
b	15	1	0	100.0	14	1	0	100.0
c	16	1	1	94.4	20	1	0	100.0
d	12	2	0	100.0	15	1	0	100.0
e	5	0	0	100.0	1	2	0	100.0
f	15	1	0	100.0	0	2	1	66.7

注記: ある測定点でデータ数が10個に満たないときはグレー網掛け
○が10個以上のとき青の網掛け

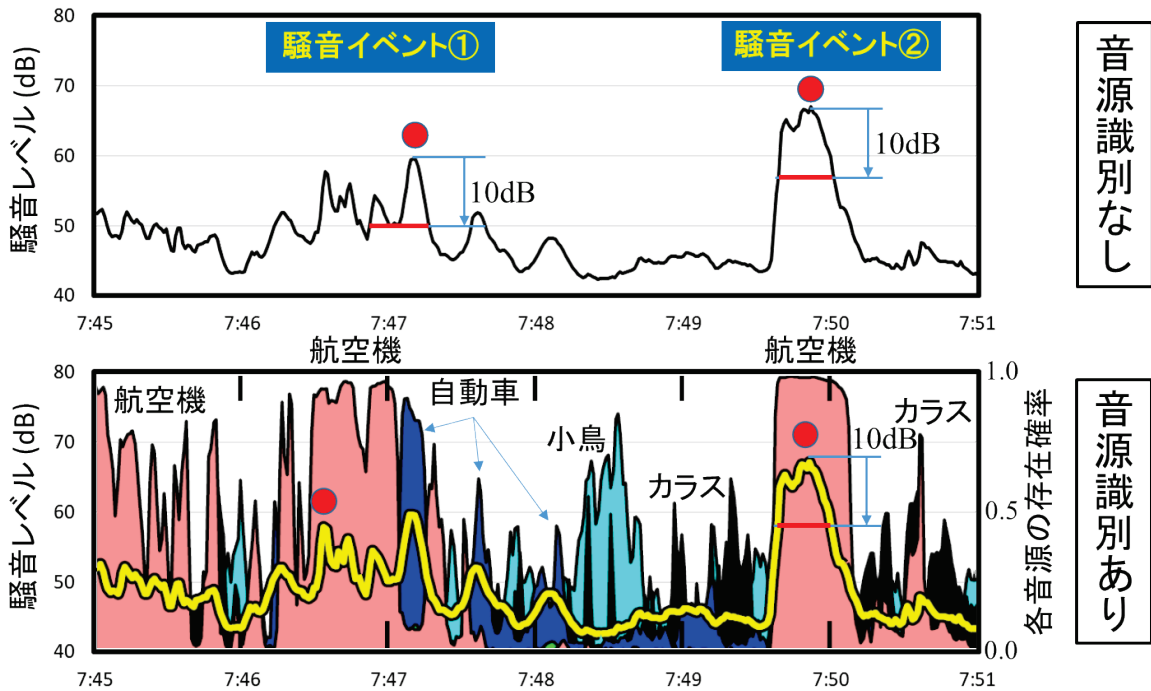


図8 航空機騒音と近接して自動車騒音が発生している結果の一例

2空港に対する識別が間違っているデータの誤識別の理由については次章で整理し、識別率を向上させるための今後の課題についても述べる。この章ではDNNによる音源識別を用いることの利点を以下に整理する。

4.3.DNN 識別の利点①：他の騒音との重なり具合の可視化

航空機騒音と自動車騒音やカラスの声などの発生区間を時間的に区別することが容易に行える。また録音データを確認しなくても航空機騒音区間の検出が効率的に行える。図8は、航空機騒音の発生時刻に近いタイミングで自動車騒音が発生し、両者の区別が騒音レベルの時間変化を見ただけでは困難な例である。図8下に示すように音源識別の存在確率を色付けして加えることにより、航空機騒音による騒音発生個所の途中で自動車騒音があることが容易にわかり、騒音イベント①の最大位置の読み取りの誤りを検出している。

4.4.DNN 識別の利点②：エンジンテストなど長時間にわたる地上騒音区間の検出

エンジンテストなど長時間にわたる地上騒音があり、背景騒音との騒音レベルが10dB以上なく、イベント検出が難しい区間でも、航空機騒音の識別結果を色分けして他と区別することで検

出が可能である。また、自動車のアイドリングなども同じように比較的定常的な騒音であるが、音源識別することによりその発生区間も容易にわかるようになる。一例を図9下に示す。図9上は航空機騒音の発生区間を比較するための比較的近い測定点の結果である。




図9 自動車のアイドリング音の識別結果の一例

4.5.DNN 識別の利点③：調査データ全体を概観して航空機騒音区間の検索支援

たとえば昼夜を含む1週間の調査データ全体を概観して航空機騒音がどこに含まれているかを比較的簡単に検索できる。測定時の周辺状況などを書き込む野帳の代わりのようなイメージで用いることができる。たとえば12時間分の識別結果を1ページに凝縮して一覧したデータを概観す

ることで、日中の航空機騒音の発生状況がおおよそわかり航空機の発着が多い時間帯が何時頃であるかなどの情報を読み取ることができる。

4.6.DNN識別の利点④：多点測定データによる航空機騒音の可視化

観測された騒音レベル波形を識別結果とともに地図上の位置に対応させて並べて表示することにより、航空機騒音が各測定点に時間的にずれて移動していく様子をわかりやすく可視化することができる。D空港の複数の測定点(a~h)のデータを南北の順番に並べて表示した例を図10に示す。航空機騒音と識別された区間はピンク色で示されており、その高さは航空機騒音である確率の大きさを表している。この例では、航空機が北から南方向にレベルフライトしているデータであるが、航空機の移動の様子を識別結果からおおよそ読み取ることができる。逆に言えば、複数点を並べた多点の識別結果の時間的な連続性の情報を、航空機騒音の飛行経路データとともに識別情報として利用できる可能性があると考えられる。

また、情報公開のわかりやすい表示手法としてもDNNによる音源識別の機能が利用できると考える。空港周辺の多点の監視データにこの自動音源識別機能を追加することにより、マップ上に示された騒音レベルだけでなく、どの音源の音が主要であるかを色分けして表示することができる。

5. 誤識別の傾向と今後の課題

表3に、表2.1と表2.2に示したA空港とB空港

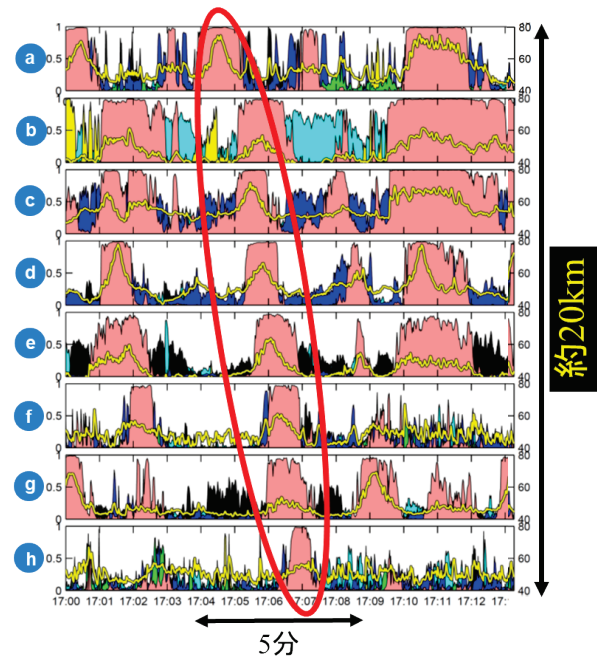


図10 音源識別結果と飛行経路の対応の一例
(約20kmある測定点a~h間のレベルフライト)

に対する識別結果のうち、航空機騒音区間を他の音源と誤識別していたデータの詳細を示す。A空港の夏季の調査結果のうち、測定点bとdの正解率が他の測定点と比較して低い値となっている原因は、この2地点の周辺に緑が多いためセミの声が背景騒音として含まれているからであった。図11に両測定点を含む4箇所について、航空機が通過した区間の識別結果を示す。セミの声を示す黄色が多い測定点bとdでは航空機騒音が自動車騒音と誤識別されている。対処法としては、航空機騒音とセミの音が含まれるデータを学習データに追加することであるが、両者の相対的なレベルが様々に異なるデータを準備する必要がある。そ

表3 識別が誤判断だった音の内容

空港	季節	Pt	時刻	機種	態様	他の音	誤判断の原因と考えられる要因
A空港	夏	c	12:10	B-737	T/O	セミ	セミの声BGN大
〃	〃	〃	14:49	B-737	T/O	アブラゼミ	セミの声、航空機キーンという高い音
〃	〃	〃	17:34	B-737	L/D	セミ	セミの声BGN大
〃	〃	〃	18:10	B-767	T/O	セミ	セミの声BGN大
〃	〃	〃	18:23	B-787	L/D	セミ	セミの声BGN大
〃	〃	〃	18:36	B-737	L/D	セミ	セミの声BGN大
〃	夏	e	17:21	B-767	L/D	セミ	セミの声BGN大
〃	〃	〃	17:29	単発ターボプロップ	T/O	セミ	セミの声BGN大
〃	〃	〃	18:10	B-767	T/O	セミ	セミの声BGN大
〃	〃	〃	20:23	A-320	L/D	特になし	航空機低レベル約60dB、周波数ディップ
〃	冬	d	9:22	小型双発ジェット	L/D	特になし	L/D後のTAXI音
〃	〃	〃	13:31	小型双発ジェット	L/D	特になし	L/D後のTAXI音、ヒーンという高い音
〃	〃	〃	15:05	単発ターボプロップ	L/D	特になし	プロペラ機TAXI音、ブィーンという純音性
〃	冬	e	14:48	B-767	L/D	小鳥	小鳥の声
B空港	夏	d	14:09	双発ターボプロップ	L/D	雨音、カラス	プロペラ機100Hz純音、雨音
〃	冬	f	12:54	A-320	T/O	風、波浪	風、波浪の音

のための有効な方法として、2種類の音の単独音同士をコンピュータ内で人工的に混合することで不足する学習データを増強する方法について過去に報告している⁵⁾。二つの音を混合する場合、どちらかが極端に小さいときは当然のことながらマスキングによって人間の耳には聞こえなくなる場合があり、これを、マスキングを考慮したラウドネスの計算により自動化するものである。

なお、今回の識別結果のうち、航空機騒音とスペクトルの形状が似ている風雨や波浪の音がある時、航空機騒音の有無に関わらず常に航空機騒音の確率が高い状態となる傾向があった。このような気象条件による背景騒音の影響についても、人工的な学習データを増強することで改善が可能かを今後検討する必要がある。

6. まとめ

近年の騒音測定は騒音計の機能の進展により無人で大量のデータを取得できるようになった。しかし得られた膨大なデータを分析するにはその分労力が掛かるため、分析対象とする航空機騒音のイベント区間の瞬時検索の機能を持つ作業支援ソフトが必須と考える。また、騒音測定にあまり精通していない人でも、データの取捨選択が容易となるような分析ツールも必要だと考えられる。

今回、深層学習を用いた自動音源識別を実際の航空機騒音の測定データに適応してみた結果、航空機騒音の発生イベント区間の検出はかなりの高い確率で行える可能性があることがわかった。DNNの構造を小規模としたこともあり、大量のデータを比較的短時間で音源識別することができるため、調査データ全体を概観して航空機騒音が発生している区間を瞬時に見つけることができる。また自動車騒音と時間的に重なった区間の検出にも利用できるため、分析データとして採用できるかどうかを判断する際にも有効と考えられる。このように、DNNを用いた自動音源識別は前述の目的の達成のため非常に有用であることがわかった。

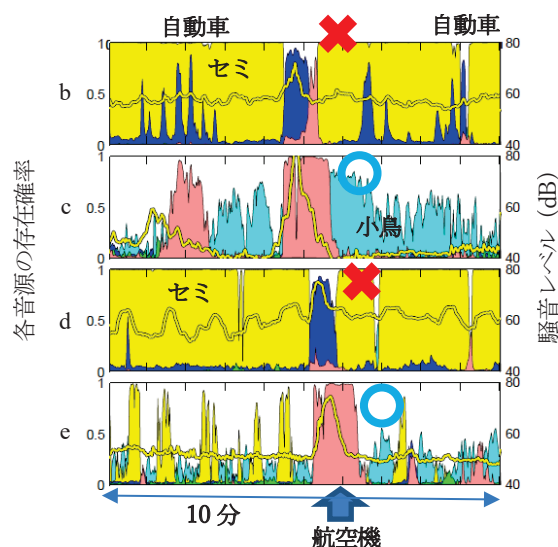


図11 航空機飛来区間の背景騒音の異なる4箇所での識別結果の一例

現状では、まだ学習データが様々な環境に対応するほどに充実しているとは言えず、更なる航空機騒音データの追加も必要と考えられる。また、背景騒音が夏のセミの声や風の強い時の風雨、波浪の音が重なった場合に識別率が低下する傾向があるため、人工的な混合音の導入も含めて学習データを充実させるなど、更なる識別率の向上のための検討を進めていきたい。

謝辞

本報告のうち、一般環境騒音のDNN識別器の設計、学習に係る項目は、著者がリオン株式会社に所属したときに検討したものである。リオン株式会社技術開発センターとともに研究開発に携わった関係諸氏に感謝いたします。

参考文献

- 1) 大島ら, 線形判別分析とディープニューラルネットワークを用いた環境音の識別, 騒音振動研究会 N-2016-10 (2016)
- 2) 内藤ら, 音源別環境音可視化に向けた機械学習による多点同期音源自動識別の試み, 音響学会 平成29年春季研究発表会 (2017)
- 3) 大島ら, 長時間多点同期モニタリングによる地域の音環境の可視化, 音響学会誌 76巻8号 (2020)
- 4) Hinton et al, A fast learning algorithm for deep belief nets, Neural Computation 18 (2006)
- 5) 大島, 防災拡声音のリアルタイム音達可視化に向けた基礎検討, アコースティックイメージング・騒音・振動研究会 N-2019-51 (2019)