音響解析と機械学習によるホーンの形状予測の検討 <sub>田之上 文彦</sub>\* 宇佐美 光\* 徳永 健一\*

# Investigation of Horn Shape Prediction Using Machine Learning with Acoustic Analysis

# Fumihiko Tanoue<sup>\*</sup>, Hikaru Usami<sup>\*</sup> and Ken-ichi Tokunaga<sup>\*</sup>

アドバンスソフトでは、シミュレーション技術と機械学習を組み合わせて、新しい技術の開発に取り 組んでいる。音響分野では、新たな試みとして、観測点の音圧レベルから伝搬経路の形状を予測する技 術を検討している。今回、音響解析ソフトウェア Advance/FrontNoise と機械学習を組み合わせて、ホー ンの形状を予測するための検討を行った。

https://doi.org/10.69290/j.001177-vol32 Keywords: 音響解析、機械学習、形状予測、逆解析

# 1. はじめに

「音」に関する分野では、音声や環境音の認識 [1][2][3]、雑音除去[4][5]、異常検知[6][7]や不正改 造の検知[8]、環境騒音予測[9][10][11]、サロゲート モデルの作成[12][13]などに機械学習が用いられ ている。音響解析の分野では環境騒音の評価に需 要があり、例えば、対象の形状や材料などを変え たときに、騒音レベルが基準値を満たすかどうか 予測するために利用される。しかし、複雑な問題 では、目的とする形状や材料を見つけることが困 難な場合がある。弊社ではこの問題に対して、音 響解析と機械学習を組み合わせた逆解析を用い て解決できないか研究を行っている。機械学習は 大量の教師データが必要であるが、音響解析によ って補うことができる。今回、ホーンを題材とし て、機械学習により、観測点の音圧レベルからホ ーンの形状を予測できるか検討した。

## 2. 学習させるホーンの形状

学習させるホーンの断面形状を図 1 に示す。ホ ーンの 3 次元形状は、断面形状を回転軸周りに回

\*アドバンスソフト株式会社 第2事業部

2<sup>nd</sup> Computational Science and Engineering Group, AdvanceSoft Corporation

ベ	スロート マウス	
ッセルホーン		36 ケース $r = r_0 (1 + \alpha x)^{\frac{n}{2}}$ $r_0 = 0.05$ $0.5 \le n \le 18$
ステッ。	$\stackrel{l_1}{\longleftrightarrow} \stackrel{l_2}{\longleftrightarrow} \rightarrow$	19 ケース 0 < $l_1 \le 0.45$ $l_2 = 0.5 - l_1$
プ関数形状のホーン	$\xrightarrow{l_1} \stackrel{l_2}{\longleftrightarrow} d$	$\begin{array}{l} 144 \ \mathcal{F} \frown \varXi \\ 0.1 < d \leq 0.6, \\ d \neq 0.4 \\ 0.05 \leq l_1 \leq 0.4 \\ 0.05 \leq l_2 < 0.4 \\ l_1 + l_2 \leq 0.45 \end{array}$
折れ線形状	$\stackrel{l_1}{\longleftrightarrow}$	9 ケース $0.05 \le l_1 \le 0.4$
のホーン	$ \begin{array}{c} l_1 \\ \longleftrightarrow \\ l_2 \\ \end{array} $	43 ケース 0.05 $\leq l_1 \leq 0.4$ 0.05 $\leq l_2 \leq 0.4$

図 1 ホーンの断面形状(寸法の単位は m)



図 2 音圧レベルが取得される観測点の位置

転させた回転体である。図 1のベッセルホーンに 示すように、回転軸は鉛直方向の中心に設定され ている。各ホーンは左側がスロート、右側がマウ スで、スロートの直径は 0.1 m、マウスの直径は 0.4 m、スロートからマウスまでの長さは 0.5 m で ある。ホーンの側面はホーンごとに異なり、図 1 の右側に示す形状変数で表現される。形状変数を 変化させ、ベッセルホーンを 36 ケース、ステップ 関数形状のホーンを 163 ケース、折れ線形状のホ ーンを 52 ケース作成した。

## 3. データセット

機械学習では、予測する変数である目的変数と、 目的変数を予測するための説明変数が必要であ る。本解析では、観測点の音圧レベルを説明変数、 ホーンの半径を目的変数とした。音圧レベルが取 得される観測点の位置を図 2 に示す。ホーン内部 は5 cm おきに9 点の観測点を配置し、ホーン外 部は軸対称性を考慮して、XY 平面上の1 m×1 m に、X と Y 方向それぞれ 10 cm おきに、合計 121 点の観測点を配置した。したがって、1 つのホー ンにつき説明変数の数は 130 である。目的変数で ある半径の定義位置の例を図 3 に示す。半径はホ ーンの中心軸に沿って1 cm 毎に配置し、合計 51 点の半径を目的変数とした。

学習に用いるトレーニングデータセットは3章 で説明した252セットで、予測に用いるテストデ ータセットは別途18セット作成した。テストデ ータは図1の6つの代表的な形状に対して、形状 変数にランダムな値を与えて3ケースずつ作成し た。予測精度を高めるために、440 Hz から1072



項目	値	単位
音速	346.5	m/s
空気密度	1.1845	kg/m <sup>3</sup>

Hz までの 10 周波数の解析結果を使用した。

#### 4. 音響解析

#### 4.1. 解析条件

解析ではホーンの振動は考慮せず、音が伝搬す る空気のみを解析対象とした。解析領域では、空 気の物性は一様であるとし、音速と空気密度は表 1 に示した値を使用した。解析する周波数は、440 ~1100 Hz の範囲で 10 周波数となるように、1/7 オクターブバンドとした。

#### 4.2. メッシュおよび境界条件

Advance/FrontNoise では、形状適合性の高い四 面体要素が採用されている。最大周波数を考慮し て、要素の寸法はおよそ 2.5 cm となるようにメッ シュを作成した。トレーニングデータセットとテ ストデータセットそれぞれに対してメッシュ、境 界条件、音源を作成した。作成したメッシュの例 を図 4 に示す。解析領域は放射領域である右側の 半球と、半球の左側に接続されたホーン内部で構 成される。放射領域は、無限要素を利用して観測 点の物理量を計算するために半球とした。放射領 域の境界条件は、半球面に無限要素境界、半球の 底面でマウスが接続されていない面に pc 境界を 設定した。無限要素の詳細は、文献[14]をご覧いた だきたい。

音源は、スロートの断面に面音源を設定した。 面音源に与える音圧は、スロート断面の音圧レベ ルが100dBとなるように設定した。

## 4.3. 解析結果

ホーン断面のコンター図を図 5~図 9 に示す。 コンター図はテストデータセットの中から代表 的な形状を選んだ。マウスの先の長方形の領域で は、解析領域(放射領域)と重複する場所は解析 結果の値を使用し、外部領域は無限要素から物性 値を算出してコンター図を作成した。

880 Hz より低い周波数(図 5、図 6、図 7)で は、ホーン外側の音圧レベルは異なるものの、音 圧レベルの広がり方に大きな違いは見られなか った。解析した周波数と波長の関係を表 2 に示す。 880 Hz 未満の周波数では、マウスの直径 40 cm よ りも波長が長いため、880Hzより低い周波数では 外部領域における音圧レベルの広がり方に大き な違いは見られなかったと考えられる。したがっ て、外部領域のみを説明変数として使用する場合、 880 Hz 未満の周波数は形状をうまく再現できな い可能性が高いと考えられる。一方、ホーン内部 では、ホーンの形状によって音圧レベルに変化が 見られた。ベッセルホーンでは音圧レベルは緩や かに変化したが、ステップ関数形状や折れ線状の ホーンでは、ホーン内部の音圧レベルは比較的大 きく変化する様子が観測された。

No.	周波数 (Hz)	波長 (cm)
1.	440.00	78.75
2.	485.80	71.33
3.	536.37	64.60
4.	592.20	58.51
5.	653.84	52.99
6.	721.90	48.00
7.	797.04	43.47
8.	880.00	39.38
9.	971.60	35.66
10.	1072.73	32.30

表	2	解析	周波数	と波	長の	関係
---	---	----	-----	----	----	----



1 シ

]

折

] ン

図 4 音響解析メッシュの例(マウスの外側の 半球は放射を計算するための解析領域 で、球面は無限要素境界、底面は pc 境界 を設定し、スロートは面音源を設定)











#### 5. 機械学習

畳み込み層と線形層を組み合わせた深層学習 モデルを構築し、機械学習を行った。

#### 5.1. モデル

本モデルは1次元畳み込み層部、2次元畳み込 み層部、線形層部から構成される。モデルの概念 図を図 10に示す。1次元畳み込み層部は「1d conv」 と「Flatten」、2次元畳み込み層部は「2d conv」と 「Flatten」、線形層部は「Linear Layer」で表されて いる。各層部の構成要素を表 3に示す。表3に示 したように、本モデルは主に、線形層、畳み込み 層、マックスプーリング層、バッチ正規化層から 構成される。それぞれの層は以下の特徴を持つ。

線形層は前層のすべてのニューロンと現在の層のすべてのニューロンが接続されるような構造を持つ多層ニューラルネットワークの基礎的な構成要素である。



図 10 モデルの概念図

表 3 1次元畳み込み層部(左上)、2次元畳み込み層部(左下)、線形層部(右側)の構成要素(() 内はカーネルサイズ、chは出力チャネル数を示す)

16 ch		32 ch			32 ch		64 ch			128 ch		51 ch									
1 氷元畳み込み層(3)	バッチ正規化層	マックスプーリング層(3)	1 次元畳み込み層(3)	バッチ正規化層	マックスプーリング層(3)	ドロップアウト層	1 次元畳み込み層(3)	バッチ正規化層	マックスプーリング層(3)	線形層、ReLU関数	バッチ正規化層	ドロップアウト層	128	関数	関数	U 関数	U 関数	U 関数	〕 関数	」	1)
						Fla	tten (一次元化) ↓ merge →			eLU	規化	田 大									
	16 ch			16	ch 16 ch			16 ch 256 ch			, R	■ 「	) 圉								
2 次元畳み込み層(3)	バッチ正規化層	マックスプーリング層(3×3)	2 次元畳み込み層(3)	バッチ正規化層	マックスプーリング層(3×3)	ドロップアウト層	2 次元畳み込み層(3)	バッチ正規化層	マックスプーリング層(3×3)	線形層、ReLU 関数	バッチ正規化層	ドロップアウト層	線形層	(~). (~).	<b></b>						

- 畳み込み層は特定サイズのカーネルを用いて空間的な畳み込み処理を行う層であり、特に、空間的に隣接する観測点間に関係性がある場合に、有用な特徴抽出層となる。本タスクにおいて、隣接する観測点間は関係性を持つと考えられるため、畳み込み層を採用した。
- マックスプーリング層は特定のカーネルサ イズ内の局所領域から最大値を採用する処 理を、カーネルを一定のストライドで移動さ せながら連続的に行う。これにより、ダウン サンプリングをしつつ、空間的なずれに対す るロバスト性を高めることができる。
- バッチ正規化層は学習中の際にミニバッチ 集合に対して平均0、標準偏差1となるよう に正規化を行う。これにより、特徴量のスケ ールを揃え、学習を安定させることができる。

損失関数は smooth L1 loss を採用する。Smooth L1 loss は各バッチに対して式 (1) の計算を行い バッチごとの損失 *l<sub>n</sub>* を求める。

 $l_n = \begin{cases} 0.5(x_n - y_n)^2 / \beta, & \text{if } |x_n - y_n| < \beta \\ |x_n - y_n| - 0.5\beta, & otherwise \end{cases}$ (1)

ここで、 $x_n$ は推定値、 $y_n$ は正解値、 $\beta$  はハイパパ ラメータである。

#### 6. 形状の予測結果

テストデータセットを用いて、正解形状と推定 した節点をプロットした結果を図 11~図 16 に 示す。ステップ関数形状のホーンでは、段差を認 識できている結果が見られたものの、満足な結果 が得られなかったと結論付けられた。









図 12 ステップ関数形状のホーンのテスト結果 (2 段)







図 13 ステップ関数形状のホーンのテスト結果 (3 段、d < 0.40)







図 14 ステップ関数形状のホーンのテスト結果 (3 段、d>0.40)







図 15 折れ線形状のホーンのテスト結果(1)







図 16 折れ線形状のホーンのテスト結果(2)

# 7. 結論

#### 7.1. 結果の考察

今回の CNN による手法では、満足な結果を得る ことはできなかった。主にタスクの困難さ、トレー ニングデータ不足が起因していると考えられる。

**タスクの困難さ**:本タスクは、推定する節点数は 少ないが、生成タスクに分類される。多くの生成 タスクは深層学習による推定問題の中でも非常 に困難なタスクとして位置づけられている。生成 タスクにおいて、多くの手法はドメイン特有の仮 定や推定する値に制約を設けるなどして、その困 難さを緩和する。しかし、本手法においてはその ような工夫は導入されていない。また、4章の音 響解析結果では、音圧レベルの広がり方に大きな 違いが見られず、今回設定した周波数帯とホーン の寸法では、予測が難しいことも挙げられる。

トレーニングデータ不足:本手法は252 個のデー タを用いてトレーニングを行っているが、多くの 深層学習タスクにおいてこれはデータ不足に該 当する。多くの学習不足のタスクでは、データの 拡充、データ拡張、事前学習済みモデルの活用な どの対策を講じるが、本タスクではいずれも行う ことが困難である。

## 7.2. 将来的な取り組み

上記を踏まえて今後の取り組み方針はタスク の緩和とトレーニングデータ作成方法の見直し による学習データの拡充である。

タスクの緩和:上記でも述べたように、複数の観 測位置における振幅からホーンの形状を求める タスクは有用であるが、生成タスクに該当するた め非常に困難である。有用性を残しつつ、困難さ を緩和する方針は例えば、入力形状に統一的な条 件を設けたり、より高い周波数で分解能を高めた りすることが考えられる。ただし、高い周波数を 用いる場合は、音響解析においてメッシュサイズ を小さくしなければならない要請から計算コス トが大きくなる問題がある。

トレーニングデータ作成方法の見直しによる学 習データの拡充:本タスクは形状の生成、メッシ ユと境界条件の生成、音響解析、機械学習の4つ のタスクを実行し学習データを得ている。このう ち、メッシュと境界条件の生成において、人間に よる確認作業が必要であり、この確認作業が大量 の学習データを生成するにあたってボトルネッ クとなっている。メッシュと境界条件の生成を完 全に自動化することで、十分なトレーニングデー タを得ることができると考えられる。

# 参考文献

- K. Noda, Y. Yamaguchi, K. Nakadai, H. G. Okuno and T. Ogata, "Audio-Visual Speech Recognition Using Deep Learning," *Appl. Intell.*, vol. 42, no. 4, pp. 722-737, Dec. 2015, doi: <u>10.1007/s10489-014-0629-7</u>.
- [2] O. Abdel-Hamid, A. -r. Mohamed, H. Jiang, L. Deng, G. Penn and D. Yu, "Convolutional Neural Networks for Speech Recognition," *IEEE/ACM Trans. Audio, Speech, Language Process.*, vol. 22, no. 10, pp. 1533-1545, Oct. 2014, doi: <u>10.1109/TASLP.2014.2339736</u>.
- K. J. Piczak, "Environmental sound classification with convolutional neural networks," 2015 IEEE 25th Int. Workshop on Mach. Learn. for Signal Proc. (MLSP), Boston, MA, USA, 2015, pp. 1-6, doi: <u>10.1109/MLSP.2015.7324337</u>.
- [4] P. V. Kartik and J. Gb, "A Deep Learning Based System to Predict the Noise (Disturbance) in Audio Files," *Intell. Syst. and Comput. Technol.*, vol. 37, pp. 154-160, 2020, doi: <u>10.3233/APC200135</u>.
- [5] T. Zafar, K. Kamal, S. Mathavan, G. Hussain, M. Alkahtani, F.M. Alqahtani, M.K. Aboudaif, "A Hybrid Approach for Noise Reduction in Acoustic Signal of Machining Process Using Neural Networks and ARMA Model," *Sensors*, vol. 21, no. 23, 8023, Dec. 2021. doi: <u>10.3390/s21238023</u>.
- [6] 石川翔悟, 尾嶌裕隆, 小松敏大, 周立波, 金子和暉, 小貫哲平, 清水淳, "切削加工音による深層学習を用いた異常検知システムの開発,"砥粒加工学会誌, 2024 年度 68 巻2 号, p.82-87. doi: 10.11420/jsat.68.82.
- [7] 執行律和,野林大起,塚本和也,水町光徳, 池永全志,"遠隔異常検知システムのための機器稼働音の周期性に基づいた特徴量抽 出の検討,"電子情報通信学会,信学技報, Vol.123, No.193, IA2023-28, pp.105-108,

2023年.

- [8] 宝渦寛之, "AIを用いた走行騒音から不正 改造車両の判定方法,"交通安全環境研究所 フォーラム講演概要 / 交通安全環境研究 所, 2021 年度, p.13-16.
- [9] Zhang, Xue, Helmut Kuehnelt, and Wim De Roeck, "Traffic Noise Prediction Applying Multivariate Bi-Directional Recurrent Neural Network" *Appl. Sci.* vol. 11, no. 6, 2714, Mar. 2021. doi: <u>10.3390/app11062714</u>
- [10] N. Genaro, A. Torija, A. Ramos-Ridao, I. Requena, D. P. Ruiz, M. Zamorano, "A neural network based model for urban noise prediction," J. Acoust. Soc. Am., vol. 128, no. 4, pp. 1738-1746, Oct. 2010, doi: <u>10.1121/1.3473692</u>.
- [11] J.M. Navarro, R. Martínez-España, A. Bueno-Crespo, R. Martínez, J.M. Cecilia, "Sound Levels Forecasting in an Acoustic Sensor Network Using a Deep Neural Network," *Sensors*, vol. 20, no. 3, Feb. 2020, 903, doi: 10.3390/s20030903.
- [12] W. Peng, J. Zhang, M. Shi, J. Li, S. Guo, "Lowfrequency sound insulation optimisation design of membrane-type acoustic metamaterials based on Kriging surrogate model," Mater. Des. vol. 225, 111491, Jan. 2023, doi: <u>10.1016/j.matdes.2022.111491</u>.
- [13] 伊藤祐太,新谷浩平,森國洋平,菅井友駿, 安岡志朗,"生成 AI を用いた車体形状流 れに起因する空力騒音予測システムの開 発,"自動車技術会論文集,56 巻 1 号, pp.62-66,2025 年 1 月, doi:

10.11351/jsaeronbun.56.62.

- [14] 松原聖, 尾川慎介, "音響解析ソフトウェア Advance/FrontNoise への無限要素の導入," アドバンスシミュレーション vol. 23, pp. 55-87, 2016 年 12 月.
- ※ 技術情報誌アドバンスシミュレーションは、それぞれの文献タイトルの下に記載した DOI から、 PDF ファイル(カラー版)がダウンロードできます。また、本雑誌に記載された文献は、発行後に、JDREAMIII(日本最大級の科学技術文献情報データベース)に登録されます。