

# AI手法を用いた自動車用HVACのBPF騒音予測技術\*

BPF noise prediction technology for automotive HVAC using AI methodology

鈴木 拓哉  
Takuya SUZUKI

To apply conventional acoustic calculations to primary fan rotational noise (BPF noise) generated by an HVAC blower at the mass production design stage, calculation costs must be reduced and calculation speed must be improved. This paper presents a technique for predicting BPF noise by combining accumulated experimental evaluation data and analytical result data.

Key words :

Neural network, AI, CNN, HVAC, CFD, BPF, NV

## 1. まえがき

近年の社会的なエネルギー動向から電動車の需要が高まっており、BEVやPHEVなどの静かなパワートレインを搭載した車種が増える中、自動車向け空調システムにも静粛性が求められている。また自動車の電動化に伴い、部品数の減少、開発競争の激化により車両、部品の開発期間も短縮化が進んでおり、空調システムの開発期間を短縮するためには実機評価を主体とした開発からデジタル技術を活用した開発への変革が必要不可欠である。

自動車用HVACは吸込み口から空気を吸込み、ファンで加圧、エバポレータで冷却した空気とヒータコアで加熱した空気とを混ぜ、ダクトを通して乗員に快適な風量・温度の空気を供給する。HVAC内で生じた騒音や異音はダクトを通して乗員に届くため抑制するための設計が重要である。

本研究で対象としている現象はHVACのファン部で発生するBPF (Blade Passing Frequency) 騒音である (Fig. 1)。BPF騒音は回転するブレード(羽翼)によって圧力変動や空気の乱れで生ずる異音である。ブレード枚数と回転数に応じて特定の周波数で発生するピーク音で乗員の不快感につながる。HVACは作動条件が広く、また限られたスペースに搭載するため、発生要因を完全に抑制することは難しく、設計の最適化などによって軽減させる必要がある。

従来は実機による計測や人の聴感により判断されてきたが、製品設計が進んだ段階での確認となるため、NGとなった場合は設計リードタイムに大きな影響を及ぼす。そこで近年ではCFD (Computational Fluid Dynamics) や、CAA (Computational Aero Acoustic) を用いた非定常解析によりファン周りやHVAC全体の流れや音響を計算することで現象の解明や改良方針を立てる手法が一般的となってきている。しかし、原

Table 1 Prediction Technology Selection

Method	Conventional			Approach to this time
	①Transient Analysis Level Up	②Sound Analysis/Reduction modeling	③Machine Learning (linear regression)	④AI method (Deep Learning)
Requirements	Improved performance of transient acoustic analysis	Create low-dimensional models from unsteady analysis results	Prediction from design parameters	Prediction from wind flow (steady-state fluid analysis)
Technology Overview				
Calculation Time	×	○	○	○
Accuracy	×	×	×	Verification
Judge	×	× Unprecedented New technology development is needed	× Parameters are Difficult to identify	? Widely used in other fields

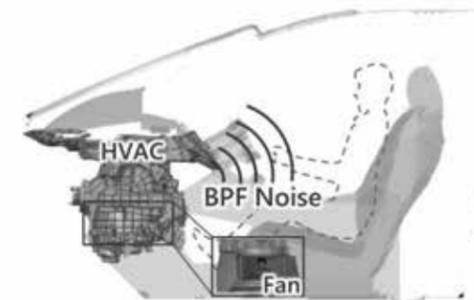


Fig. 1 BPF noise in Vehicle

理原則に基づいた予測が可能一方で計算時間が膨大にかかるため、詳細設計段階での予測手法としては適していない。

本研究では製品の開発後期での設計で活用できる計算時間を実現するため、AI手法を利用した予測技術を検証、開発し、その精度活用のフローを策定した。

## 2. 予測技術の構築

### 2.1 予測技術の選定

当社では従来手法である非定常音響解析の開発活用を進めてきたが<sup>1)</sup>、計算時間が膨大で精度が実測に及ばないことが課題である。近年急速に発展しているサロゲートモデル (Surrogate Model) 化が一つの手段として考えられる。しかし、基となるデータは非定常音響解析から機械学習や統計モデリング手法により構築されるため、計算時間短縮は可能であるが精度は元の解析精度に依存し、実測レベルには到達できず適用が難しい。その他の手法として一般的な機械学習が考え

られる。蓄積された実測データとその実測データに紐づいた設計変数により自動的にパターンや関係性を見出し、現象を予測する手法であるが、HVACの内部形状が複雑であり、設計パラメータの特定が困難であるためHVACに対して適用が難しい (Table 1)。

本研究では社内に蓄積されている定常流体解析の結果と、実測の結果を用いてモデルを学習させることで、新規形状を設計する際には定常流体解析の結果からBPF騒音を予測できる手法を考案した。定常解析は非定常解析と比較して計算時間も短く開発後期の検討スピードが求められるフェーズにおいても活用可能である。予測精度の目標値は実測同等の±1dB以内とした。

### 2.2 技術コンセプトと開発ステップ

本技術のコンセプトは「蓄積した実験評価データ」と「定常CFDによる解析結果画像」を学習データとして使いBPF騒音を予測することである。AI技術により詳細設計段階において定常解析結果からBPF騒音を予測することが可能となる (Fig. 2)。

今回使用するAI技術は畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) で、主に画像認識に使われるニューラルネットワーク技術である。畳み込み層 (Convolutional Layer)、プーリング層 (Pooling Layer)、全結合層 (Fully Connected Layer) などから構成されており、畳み込み層によって局所的な特徴を抽出し、プーリング層で特徴を圧縮、全結合層を通じて最終的な予測や分類を行うことができ、高い予測性能を持つ。モデルの入力は二次元画像

\* (公社)自動車技術会の了解を得て、「2023年秋大会学術講演会講演予稿集」No. 20236242より一部加筆して転載。

が一般的である。

予測技術開発の進め方としては、初めに今回予測する BPF 騒音の指標を明確に定義し必要なデータを収集、整理する。その後今回選択した畳み込みニューラルネットワークを課題に合わせモデリングし、収集した解析結果と実測結果を使いモデルを学習させる。訓練データでの精度目標（実測同等  $\pm 1\text{dB}$ ）を達成するためにモデルを修正し、最後に訓練されたモデルを実際の未学習のデータに適用し予測精度を検証する。

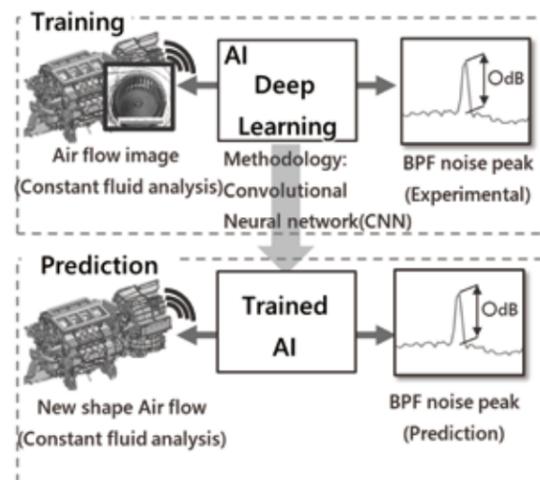


Fig. 2 Prediction Concept

### 2.3 評価指標の定義

BPF 騒音は人が聞いた時の不快感（聴感）により判定を行っている。目標となる指標の一つとして突出量がある。突出量は BPF 騒音によるピーク音が他の帯域と比較してどの程度（dB）突出しているかを表す指標である。この指標を予測できれば製品の良否判断を行うことができるため今回の予測対象は、BPF 騒音の突出量と定義した（Fig. 3）。

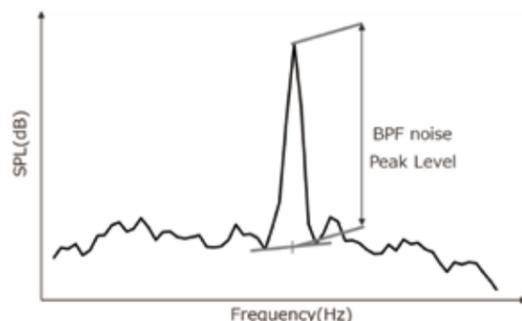


Fig. 3 BPF noise Peak Level Definition

### 2.4 収集データの設定

次にモデルに学習させるデータ形式を設定する。実測データは HVAC 実機による突出量の計測データとする。解析結果は BPF 騒音が発生するメカニズムから 2次元画像を取得する位置を検討した。BPF 騒音はファンに流入する風の不均一性によって翼に圧力変動が生じ音となることが過去知見から分かっているため、ファン入口部分の流速コンター図とした（Fig. 4）。

機械学習やニューラルネットワーク技術開発では学習させた内挿領域を広くすることで適用範囲が広がり、密度を高くすることで精度が向上する。社内には BPF 騒音に関するデータが蓄積されており、そのデータから BPF 騒音に影響を及ぼす複数の形状の寸法や位置をパラメータとする。また市場で使われている風量の範囲内を網羅する条件を設定し、それらの組み合わせにより計 2,000 条件とした。

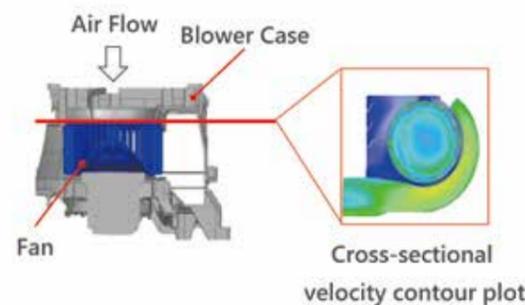


Fig. 4 Input data format

### 2.5 畳み込みニューラルネットワークのモデリング

今回のモデルは畳み込み層、プーリング層を繰り返す一般的な構成を用いており、最終的な出力として定量値を出力させる回帰手法を利用した。

### 2.6 モデルの学習

収集したデータを用いてモデルを学習させる。畳み込みニューラルネットワークの中には画像を処理するフィルタが多数あり、その処理により最終的にある定量値を出力する。その定量値を訓練データ（実測値）に合わせ込む作業を学習という。学習の後、学習させたデータ自身で精度  $\pm 1\text{dB}$  を満足するまで、畳み込みニューラルネットワーク内の層の数や組み合わせ、サイズ等を変えながら精度向上させる。

精度向上の指標として畳み込みニューラルネットワーク内の処理を可視化する技術を使う。AI の出力に対する寄与度を画像上に表示できるため、BPF 騒音の過去の知見と比較しながら内部処理の設定を見直す。

## 3. 結果

### 3.1 予測精度の検証

本技術を製品開発で利用する際には学習されていない条件、現象を扱うことが主となる。そのため、予測精度の検証においても未学習のデータを学習データ数の約 1 割（200 データ）準備した。未学習データ選定の考え方としては、BPF 騒音のパラメータとなる形状・位置・風量を偏りなく条件設定し精度検証を行った。

精度検証の結果を Fig. 5 に示す。横軸を実測結果（dB）、縦軸を予測結果（dB）とし予測技術による結果をプロットしている。図中の黒実線は目標としている  $\pm 1\text{dB}$  を表している。

グラフから予測は実測に対し、 $\pm 1\text{dB}$  を満足できず、最大で  $-5\text{dB} \sim +4\text{dB}$  誤差が生じることが分かった。しかし、予測の相関係数は 0.77 と高く、全体的には傾向を捉えられることが分かった（Fig. 5）。

精度が低い要因としては内挿領域の訓練させたデータ数が足りておらず、訓練データから少しでも外れた場合に予測値がずれると考えられる。

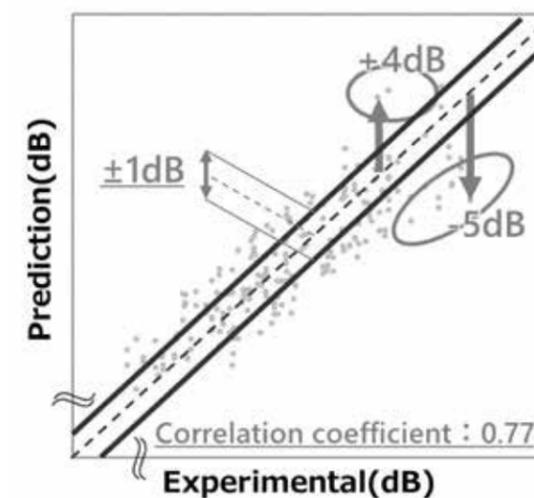


Fig. 5 Prediction result

### 3.2 製品開発における活用

BPF 騒音が高い領域では、 $-5\text{dB} \sim +4\text{dB}$  の誤差が生じているが、低い領域では、 $\pm 3\text{dB}$  となっていることから製品開発で適用する際の使い方を工夫することで、実用的な評価手法にできないか検討した。

BPF 騒音がある程度高い領域では必ず設計改良を行うため予測誤差は大きな問題とはならない。そのため従来判断している閾値より  $3\text{dB}$  安全側に予測閾値を設定し、本予測技術で判断できる領域を拡大する。

予測閾値と実測閾値の間の  $3\text{dB}$  については当技術では良否判断できない領域として、実機で視聴判断をするフローとすることで現状の精度でも BPF 騒音に関わる工数を 50% 低減できる見込みである（Fig. 6）。

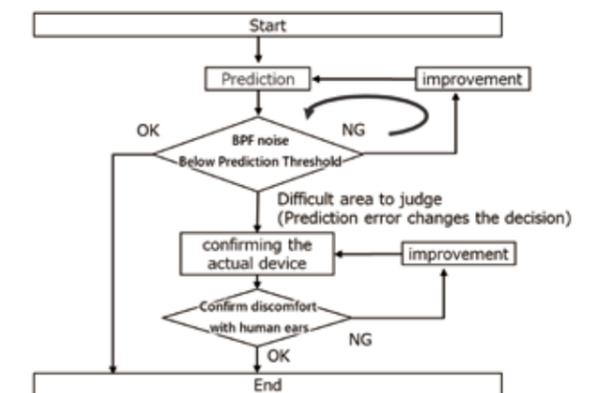


Fig. 6 Design flowchart

## 4. むすび

本論文では HVAC のファン部で発生する BPF 騒音に対し、製品の開発後期での設計で活用できる計算時間を実現するため従来の非常 CFD を用いた音響解析手法ではなく「蓄積した実験評価データ」と「定常解析の結果画像」を組み合わせ AI 技術を利用した予測手法を構築した。

従来手法に対し大幅に計算スピードを向上させた。また実用的な活用フローを定義することで製品開発に適用でき、設計工数の低減を実現した。

今後はさらなる精度向上のため内挿領域のデータを補完していくことで実測同等精度も実現可能と考える。

さらに、閾値によらず最適な設計を行うため、本手

法による予測結果と人間の聴感を紐づけ判断する手法  
を検討していく.

#### 参考文献

- 1) NORISADA Koji : HVAC Blower Aeroacoustic Predictions,  
SAE Technical Paper Series (Society of Automotive Engineers)  
(2013)

#### 著者



鈴木 拓哉  
すずき たくや

サーマルシステム性能開発部  
空調システムの予測技術開発に従事