

能動騒音制御のための適応学習における事前情報の活用

代表研究者 山 岸 昌 夫 東京工業大学 大学院理工学研究科 助教

1 はじめに

雑音源や騒音源が伴う状況下において快適な環境を実現するには、能動騒音制御などの雑音・騒音抑制システムが重要である。例えば、自動車・電車・航空機内や、農場・工場・工事現場・医療現場などの環境下において、我々は日々厳しい騒音にさらされている。それらの騒音に対して、能動騒音制御[1][2]は逆位相の音を生成し、音を重ね合わせることで消音を実現する技術である。

フィードフォワード型制御の場合、消音を行いたい場所（制御対象位置）を決め、騒音を生成する一次音源の近傍に騒音を測定する参照マイクを設置し、逆位相の音（擬似騒音）をスピーカ（二次音源と呼ぶ）から生成する。制御対象位置と参照マイクは空間的に離れているため、参照マイクで測定した騒音が、制御対象位置までそのまま到達するとは限らず、変化することが知られている。同様に、二次音源が生成する擬似騒音についても、制御対象位置にそのまま到達するとは限らない。そのため、これらの音の変化を考慮し、制御対象位置における騒音の音圧を小さくなるように擬似騒音を生成する必要がある。

多くの場合、擬似騒音は、騒音制御フィルタと呼ばれる線形適応フィルタを用いて、参照マイクで観測した信号（参照信号）を加工することにより生成される。この生成過程は、音響経路の線形性に基づいている。「参照マイクから制御対象位置までの一次音響経路」は、線形フィルタとしてモデル化される。同様に、「二次音源から制御対象位置までの二次音響経路」も線形フィルタとしてモデル化される。そのため、騒音制御フィルタを線形フィルタに限定することが可能となる。一方、二次音響経路に比べ、一次音響経路は周囲の環境に対して影響を受け、時々刻々と変化する。この一次音響経路の変動に追従するために、適応フィルタを選択することが適切である。以上の議論から、騒音制御フィルタとして、線形適応フィルタが採用されている。そのため、騒音制御フィルタに対して「高い騒音制御性能を安定実現する学習アルゴリズム」を設計することが重要な鍵となる。

本研究課題では、望ましい学習アルゴリズムを実現するため、事前情報を活用することを提案し、学習アルゴリズムを導出している。具体的には、能動騒音制御で暗に用いられている線形モデルを明らかにし、通常の適応フィルタに関する種々の結果を能動騒音制御に対して適切に活用する方法を明確にしている。また、導出した線形モデルに対して、適応フィルタの学習アルゴリズムの一つである適応 Douglas-Rachford 分離法[3]を適用し、事前情報を柔軟に活用できる学習アルゴリズムを提案している。

上述の枠組みの具体例として、一次音響経路のスパース性を活用することも提案している。スパース性とは、フィルタの係数の多くが零であり、大きな絶対値を持つ係数の数が少ないことを指している。典型的な音響経路はスパース性を持つことが知られている[4]。そのため、一次音響経路に対してスパース性を仮定することが出来る。このスパース性を学習アルゴリズムの設計に活用している。最後に、その効果を数値実験により確認している。

2 準備

2-1 フィードフォワード型能動騒音制御

実数全体の集合と非負整数全体の集合をそれぞれ \mathbb{R} 、 \mathbb{N} とする。また、行列の転置を $(\cdot)^T$ で表す。フィードフォワード型能動騒音制御では、制御対象位置に誤差マイクを設置し、誤差信号 $(e_k)_{k \in \mathbb{N}} \subset \mathbb{R}$

$$e_k = (\mathbf{p}_k^*)^T \mathbf{x}_k - (\mathbf{s}_k^*)^T \mathbf{y}_k + v_k \quad (1)$$

を観測する。ここで $k \in \mathbb{N}$ は時刻である。参照信号 $(\mathbf{x}_k)_{k \in \mathbb{N}} \subset \mathbb{R}^N$ ($\mathbf{x}_k := [\mathbf{x}_k, \mathbf{x}_{k-1}, \dots, \mathbf{x}_{k-N_1+1}]^T \in \mathbb{R}^{N_1}$)は未知の一次音響経路 $\mathbf{p}_k^* \in \mathbb{R}^{N_1}$ を通り、誤差マイクに到達する。二次音源から生成された擬似騒音 $(\mathbf{y}_k)_{k \in \mathbb{N}} \subset \mathbb{R}^{N_2}$ ($\mathbf{y}_k := [\mathbf{y}_k, \mathbf{y}_{k-1}, \dots, \mathbf{y}_{k-N_2+1}]^T \in \mathbb{R}^{N_2}$)は未知の二次音響経路 $\mathbf{s}_k^* \in \mathbb{R}^{N_2}$ を通る。一般に、擬似騒音は参照信号に対して、騒音制御フィルタ $\mathbf{h}_k \in \mathbb{R}^{N_0}$ を適用することによって生成される。

$$\mathbf{y}_k = \mathbf{h}_k^T \mathbf{x}_k$$

また、誤差マイクでの観測雑音を $(v_k)_{k \in \mathbb{N}} \subset \mathbb{R}$ としている（図1を御参照）。

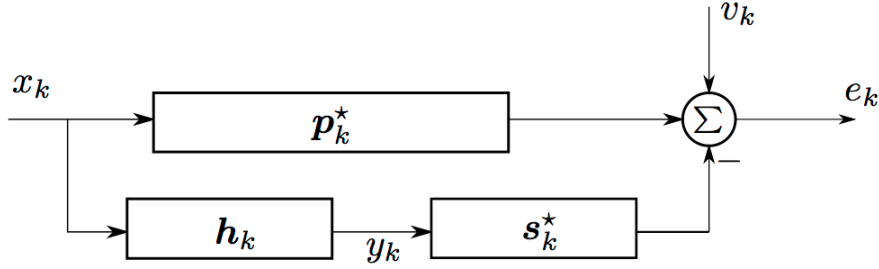


図 1 フィードフォワード型能動騒音制御

能動騒音制御の目的は、誤差マイクの近傍において消音を実現することである。言い換えると、消音に適切な騒音制御フィルタの学習アルゴリズムを設計することである。線形モデルに対して適応フィルタの学習アルゴリズムを設計する方法は広く知られているため、能動騒音制御における線形モデルを明らかにすることで、適応学習を設計する指針を与える。簡単のため、一次二次音響経路が時不変な場合 $(\mathbf{p}_k^*, \mathbf{s}_k^*) = (\mathbf{p}_*, \mathbf{s}_*)$ を考える。理想的な騒音制御フィルタを誤差信号の二乗の平均を最小にするものとして定義する。

$$\mathbf{h}_* \in \arg \min_{\mathbf{h} \in \mathbb{R}^{N_0}} E[\{(\tilde{\mathbf{p}}_*^\top - \mathbf{h}^\top \tilde{\mathbf{S}}_*) \tilde{\mathbf{x}}_k + v_k\}^2]$$

ここで、

$$\begin{aligned} \tilde{\mathbf{x}}_k &:= [\mathbf{x}_k, \mathbf{x}_{k-1}, \dots, \mathbf{x}_{k-(N_0+N_2)}]^\top \in \mathbb{R}^{\tilde{N}} \\ \tilde{N} &:= N_0 + N_2 - 1 \\ \tilde{\mathbf{p}}_* &:= [p_*^{(0)}, p_*^{(1)}, \dots, p_*^{(N_1-1)}, 0, 0, \dots, 0]^\top \in \mathbb{R}^{\tilde{N}} \\ \tilde{\mathbf{s}}_* &:= [s_*^{(0)}, s_*^{(1)}, \dots, s_*^{(N_2-1)}, 0, 0, \dots, 0]^\top \in \mathbb{R}^{\tilde{N}} \end{aligned}$$

であり、 $\tilde{\mathbf{S}}_* \in \mathbb{R}^{N_0 \times \tilde{N}}$ は $\tilde{\mathbf{S}}_* \tilde{\mathbf{x}}_k$ が二次経路と参照信号の畳み込みとなるようなテプリッツ行列である。すなわち $\mathbf{h}^\top \tilde{\mathbf{S}}_*$ は騒音制御フィルタと二次音響経路の縦続接続を表している。以上より、理想的な騒音制御フィルタに対するモデル

$$\tilde{\mathbf{p}}_*^\top \tilde{\mathbf{x}}_k + v_k = \mathbf{h}_*^\top \tilde{\mathbf{S}}_* \tilde{\mathbf{x}}_k + n_k \quad (2)$$

を導入し、ノイズ n_k の平均二乗誤差を小さくするフィルタを見つけ出すことが有望な指針となることが分かる。残念ながら、モデル (2) は未知量の数が多く、標準的な線形モデルとしての取扱いには向かないため、未知量の数を減らす必要がある。幸いにも、(1) をモデル (2) の左辺に代入することにより、未知量の数を削減することができる。

$$\mathbf{e}_k + \mathbf{s}_*^\top \mathbf{y}_k = \mathbf{h}_*^\top \tilde{\mathbf{S}}_* \tilde{\mathbf{x}}_k + n_k$$

また、二次音響経路は、厳密には未知量であるが、時不変な線形フィルタとしてモデル化できることが多いため、事前に測定を行うことが広く行われている (例えば, [1], [2])。そのため、二次音響経路を既知であるとして、議論を進める。以下、既知であることを強調するため、 $\mathbf{s} := \mathbf{s}_*$, $\tilde{\mathbf{S}} := \tilde{\mathbf{S}}_*$ と表記する。

$$\mathbf{e}_k + \mathbf{s}^\top \mathbf{y}_k = (\tilde{\mathbf{S}} \tilde{\mathbf{x}}_k)^\top \mathbf{h}_* + n_k \quad (3)$$

以上により、標準的な線形モデルとして取り扱うことができる。この線形モデルに対して、線形適応フィルタの種々の手法を適用することにより、様々な能動騒音制御の手法を導出することが可能となる。実際、この線形モデル (3) に対して標準的な学習アルゴリズムである LMS 法 [5] を適用することにより、修正 filtered-x LMS 法 (MFxLMS) [6] を導出することが出来る。

以下では、簡単のため、一次二次音響経路が時不変であるとし、二次音響経路が既知であるとする。

2-2 適応 Douglas-Rachford 分離法

線形モデルに対して、適応学習アルゴリズムを設計する統一的な枠組みとして、適応 Douglas-Rachford 分離法に着目する [3]。この枠組みでは、時々刻々変動するコスト関数を導入し、それらの関数値の逐次抑圧を実現する。 \mathbb{R}^N の内積とノルムをそれぞれ $\langle \mathbf{x}, \mathbf{y} \rangle := \mathbf{x}^\top \mathbf{y}$, $\|\mathbf{x}\| := \sqrt{\langle \mathbf{x}, \mathbf{x} \rangle}$ ($\forall \mathbf{x}, \mathbf{y} \in \mathbb{R}^N$) とする。

コスト関数 $\Theta_k: \mathbb{R}^N \rightarrow (-\infty, \infty]$ が二つの関数の和で表現できるとする。

$$\Theta_k(\mathbf{h}) := \varphi_k(\mathbf{h}) + \psi_k(\mathbf{h})$$

ここで、 $\varphi_k: \mathbb{R}^N \rightarrow (-\infty, \infty]$ と $\psi_k: \mathbb{R}^N \rightarrow (-\infty, \infty]$ は下半連続な真凸関数である (例えば [7] をご参照)。

このコスト関数を抑圧するため、適応 Douglas-Rachford 分離法 [3] が提案されている。任意の初期ベクトル $\mathbf{g}_0 \in \mathbb{R}^N$ と任意の数列 $\gamma_k \in (0, \infty)$, $t_k \in (0, 2)$ に対して、適応 Douglas-Rachford 分離法は数列 $(\mathbf{h}_k)_{k \in \mathbb{N}} \subset \mathbb{R}^N$

$$\begin{aligned}\mathbf{h}_k &:= \text{prox}_{\gamma_k \psi_k}(\mathbf{g}_k) \\ \mathbf{g}_{k+1} &:= \mathbf{g}_k + t_k [\text{prox}_{\gamma_k \varphi_k}(2\mathbf{h}_k - \mathbf{g}_k) - \mathbf{h}_k]\end{aligned}\quad (4)$$

を生成する．ここで，下半連続な真凸関数 $f: \mathbb{R}^N \rightarrow (-\infty, \infty]$ と $\gamma > 0$ に対して，写像

$$\text{prox}_{\gamma f}: \mathbb{R}^N \rightarrow \mathbb{R}^N, \mathbf{x} \mapsto \arg \min_{\mathbf{z} \in \mathbb{R}^N} \left(\gamma f(\mathbf{z}) + \frac{1}{2} \|\mathbf{x} - \mathbf{z}\|^2 \right)$$

は近接点写像 [8] と呼ばれている．

適応 Douglas-Rachford 分離法は以下の性質を有する．ここでは，制約想定と呼ばれる条件，すなわち

$$\bigcup_{\lambda > 0} \{\lambda \mathbf{x} \mid \mathbf{x} \in \text{dom}(\varphi_k) - \text{dom}(\psi_k)\} \text{ が部分空間であること,}$$

を仮定する（実用上ほとんどの場合，制約想定は成立する）．

(i) 各時刻のコスト関数に対して $\Omega_{k+i}^* := \arg \min_{\mathbf{h} \in \mathbb{R}^N} \Theta_{k+i}(\mathbf{h})$ ($i = 0, 1$) とする．このとき，

$$\begin{cases} \left\| \mathbf{h}_{k+1} - \text{prox}_{\gamma_{k+1} \psi_{k+1}}(\mathbf{g}_{k+1}^*) \right\| \leq \|\mathbf{g}_{k+1} - \mathbf{g}_{k+1}^*\| \\ \|\mathbf{g}_{k+1} - \mathbf{g}_k^*\| \leq \|\mathbf{g}_k - \mathbf{g}_k^*\| \end{cases}$$

が任意の $\mathbf{g}_{k+i}^* \in \left(\text{prox}_{\gamma_{k+i} \psi_{k+i}} \right)^{-1}(\Omega_{k+i}^*)$ ($i = 0, 1$) に対して成立する．

(ii) ある $N' \in \mathbb{N}$ 以後の時刻において ψ_k と γ_k が時不変，すなわち $\psi_k = \psi, \gamma_k = \gamma$ ($\forall k \geq N'$)，であるとする．また， $\Omega_* := \bigcap_{i \geq N'} \Omega_i^* \neq \emptyset$ であるとする．このとき， $\forall k \geq N'$ に対して，

$$\left\| \mathbf{h}_{k+1} - \text{prox}_{\gamma \psi}(\mathbf{g}_*) \right\| \leq \|\mathbf{g}_{k+1} - \mathbf{g}_*\| \leq \|\mathbf{g}_k - \mathbf{g}_*\| \quad (\forall \mathbf{g}_* \in \left(\text{prox}_{\gamma \psi} \right)^{-1}(\Omega_*))$$

が成立する．この不等式は，片方の関数が時変であったとしても，最小値の集合との距離の上界が単調減少することを意味している．この性質は，適応フィルタへの応用を考慮した際に，極めて有用である．

3 事前情報を活用する能動騒音制御アルゴリズム

線形モデル (3) に対して適切なコスト関数を設計し，適応 Douglas-Rachford 分離法 (4) を適用することによって，事前情報を活用する能動騒音制御アルゴリズムを提案する．すなわち，最小値集合の近傍に理想的なフィルタがあることが期待できるようにコスト関数を設計し，その関数値の逐次抑圧を実現する学習アルゴリズムを導出する．コスト関数の設計には十分な自由度があるため，その設計において事前情報を柔軟に活用することが可能である．典型的には，関数 φ_k を線形モデルへの整合性の評価関数とし，関数 ψ_k を事前情報への整合性の評価関数とすることにより，事前情報を適応学習に取り入れることが可能となる．

具体例として，一次音響経路のスパース性を活用する適応学習アルゴリズムを導出する．残念ながら，一次音響経路は線形モデル (3) に陽には現れない．しかし，以下の議論から，一次音響経路のスパース性は，「騒音制御フィルタと二次音響経路の縦続接続 $\mathbf{h}^T \tilde{\mathbf{S}}$ 」に引き継がれることが分かる．式 (2) から明らかのように， $\mathbf{h}^T \tilde{\mathbf{S}}$ が一次音響経路と一致する際に完全な消音を実現する．そのため，理想的な $\mathbf{h}_*^T \tilde{\mathbf{S}}$ は一次音響経路と似ていることが期待できる．すなわち，スパース性を有する $\mathbf{h}^T \tilde{\mathbf{S}}$ が有望である．以上の議論より， $\mathbf{h}^T \tilde{\mathbf{S}}$ のスパース性を適切な関数を用いて表現することにより，一次音響経路のスパース性を活用することができる．

理想的な騒音制御フィルタを探索するために，コスト関数の設計を行う．スパース性を促進する関数として，「 $\mathbf{h}^T \tilde{\mathbf{S}}$ の重み付き ℓ_1 ノルム」を採用する．

$$\lambda_k \|\tilde{\mathbf{S}}^T \mathbf{h}\|_1^{w_k} \quad (\forall \mathbf{h} \in \mathbb{R}^{N_0}) \quad (5)$$

ここで， $\lambda_k \geq 0$ は正則化パラメータであり，重み付き ℓ_1 ノルムは，重み $\mathbf{w}_k := (w_1^{(k)}, w_2^{(k)}, \dots, w_{\tilde{N}}^{(k)})^T \in \mathbb{R}^{\tilde{N}}$ を用いて，

$$\|\cdot\|_1^{w_k}: \mathbb{R}^{\tilde{N}} \rightarrow \mathbb{R}, \tilde{\mathbf{z}} = (\tilde{z}_1, \tilde{z}_2, \dots, \tilde{z}_{\tilde{N}}) \mapsto \sum_{i=1}^{\tilde{N}} w_i^{(k)} |\tilde{z}_i|$$

によって定義される．重み付き ℓ_1 ノルムはスパース性を促進する正則化関数として広く用いられている（例

えば[9], [10]等).

一方で, 線形モデル (3) への整合性を評価する関数として, 二次関数

$$f_k(\langle \tilde{\mathbf{S}}\tilde{\mathbf{x}}_k, \mathbf{h} \rangle) \quad (\forall \mathbf{h} \in \mathbb{R}^{N_0})$$

を採用する. ここで, $f_k: \mathbb{R} \rightarrow \mathbb{R}, r \mapsto (e_k + \mathbf{s}^\top \mathbf{y}_k - r)^2$ とした. つまり, コスト関数

$$f_k(\langle \tilde{\mathbf{S}}\tilde{\mathbf{x}}_k, \mathbf{h} \rangle) + \lambda_k \|\tilde{\mathbf{S}}^\top \mathbf{h}\|_1^{w_k} \quad (6)$$

に対して, 最適解の集合の近傍に理想的な騒音制御フィルタの係数があることが期待し, 適応 Douglas-Rachford 分離法 (4) を適用する.

学習アルゴリズムの導出の基本方針は上述した通りである. しかし, コスト関数 (6) に対して適応 Douglas-Rachford 分離法 (4) を適用した場合, スパース性を促進する関数 (5) の近接点写像の計算が困難となる. 原因は重み付き ℓ_1 ノルムの中にテプリッツ行列が合成されていることである. そこで, 最適解の集合を変化させることなく, テプリッツ行列を扱いやすい行列に置き換えることにより, 低計算量のアルゴリズムを導出する. この置き換えを実現するために, 補助変数を導入すると共に, テプリッツ行列を巡回行列の一部に埋め込むことによって, 「巡回行列が離散フーリエ変換によって対角化できる事実[11]」を活用する. 部分行列として $\tilde{\mathbf{S}}^\top$ を持つ巡回行列を $\mathbf{C}(\tilde{\mathbf{S}}^\top)$ とする. ここでは, [11]に従い,

$$\mathbf{C}(\tilde{\mathbf{S}}^\top) = \begin{pmatrix} \tilde{\mathbf{S}}^\top & * \\ * & * \end{pmatrix}$$

となる行列を選ぶ. このとき, 単位行列と零行列を並べた行列 $\mathbf{\Pi} := [\mathbf{I}_{N_0} \ \mathbf{O}] \in \mathbb{R}^{N_0 \times \hat{N}}$ を定義し, $\mathbf{h} = \mathbf{\Pi}\hat{\mathbf{h}}$ を満たすような補助変数 $\hat{\mathbf{h}} \in \mathbb{R}^{\hat{N}}$ を導入すると, 以下が成立する.

$$\tilde{\mathbf{S}}^\top \mathbf{h} = \mathbf{\Pi}_{\hat{N}} \mathbf{C}(\tilde{\mathbf{S}}^\top) \hat{\mathbf{h}} \quad (\forall \hat{\mathbf{h}} \in C_0)$$

ここで, $\mathbf{\Pi}_{\hat{N}} := [\mathbf{I}_{\hat{N}} \ \mathbf{O}] \in \mathbb{R}^{\hat{N} \times \hat{N}}$ ($\hat{N} := \tilde{N} + N_0 - 1$), $C_0 := \{\hat{\mathbf{h}} \in \mathbb{R}^{\hat{N}} \mid \hat{h}_{N_0+i} = 0, \forall i \in \{1, 2, \dots, \hat{N} - N_0\}\}$ とした.

さらに, $\hat{\boldsymbol{\xi}} = \mathbf{C}(\tilde{\mathbf{S}}^\top) \hat{\mathbf{h}}$ を満たすような補助変数 $\hat{\boldsymbol{\xi}} \in \mathbb{R}^{\hat{N}}$ を導入することにより, コスト関数 (6) の最小化問題と本質的に等価な問題

$$\min_{(\hat{\mathbf{h}}, \hat{\boldsymbol{\xi}}) \in \mathbb{R}^{\hat{N}} \times \mathbb{R}^{\hat{N}}} f_k(\langle \mathbf{\Pi}^\top \tilde{\mathbf{S}}\tilde{\mathbf{x}}_k, \hat{\mathbf{h}} \rangle) + \lambda_k \|\mathbf{\Pi}_{\hat{N}} \hat{\boldsymbol{\xi}}\|_1^{w_k} + \iota_{C_0}(\hat{\mathbf{h}}) + \iota_{C_1}(\hat{\mathbf{h}}, \hat{\boldsymbol{\xi}}) \quad (7)$$

を得る. ここで, $C_1 := \{(\hat{\mathbf{h}}, \hat{\boldsymbol{\xi}}) \in \mathbb{R}^{\hat{N}} \times \mathbb{R}^{\hat{N}} \mid \hat{\boldsymbol{\xi}} = \mathbf{C}(\tilde{\mathbf{S}}^\top) \hat{\mathbf{h}}\}$ とした. また, 閉凸集合 C に対する指示関数を

$$\iota_C(x) = \begin{cases} 0 & x \in C \\ \infty & x \notin C \end{cases}$$

とした. このとき, 問題 (7) の最適解となる $(\hat{\mathbf{h}}, \hat{\boldsymbol{\xi}})$ ならば $\hat{\mathbf{h}}$ はコスト関数 (6) の最小化問題の最適解である. 問題 (7) に対して,

$$\begin{aligned} \varphi_k(\hat{\mathbf{h}}, \hat{\boldsymbol{\xi}}) &= f_k(\langle \mathbf{\Pi}^\top \tilde{\mathbf{S}}\tilde{\mathbf{x}}_k, \hat{\mathbf{h}} \rangle) + \lambda_k \|\mathbf{\Pi}_{\hat{N}} \hat{\boldsymbol{\xi}}\|_1^{w_k} + \iota_{C_0}(\hat{\mathbf{h}}) \\ \psi_k(\hat{\mathbf{h}}, \hat{\boldsymbol{\xi}}) &= \iota_{C_1}(\hat{\mathbf{h}}, \hat{\boldsymbol{\xi}}) \end{aligned}$$

とすることにより, 適応 Douglas-Rachford 分離法 (4) を適用した際に, それぞれの近接点写像の計算を効率的に行うことが可能となる. 何故ならば, 重み付き ℓ_1 ノルムの中の行列は単位行列と零行列を並べた扱いやすい行列となっているためである. 結果として, φ_k の近接点写像は MFxLMS[6] の更新式と同程度の計算量で実現でき, ψ_k の近接点写像は, 離散フーリエ変換とその逆変換が必要となるが, 高速に計算が可能である.

4 数値実験

数値実験を通して, 一次音響経路のスパース性を活用する能動騒音制御アルゴリズムの性能を確認する. スパース性の効果を明確にするため, 一次音響経路がスパースな場合と非スパースな場合のそれぞれに対し

表 1. パラメータの設定

	\mathbf{p}_* の長さ	N_1	100
	\mathbf{s}_* の長さ	N_2	20
	\mathbf{h}_* の長さ	N_0	100
ステップサイズ	FxLMS		4.0×10^{-5}
	MFxLMS		2.5×10^{-2}
	Sun のアルゴリズム		5.0×10^{-5}
	Akhtar のアルゴリズム		5.0×10^{-5}
	Proposed 1	$(\lambda_k, t_k, \gamma_k)$	(0.3, 1.0, 5.0×10^{-5})
	Proposed 2	$(\lambda_k, t_k, \gamma_k)$	(0.0, 1.0, 5.0×10^{-5})

て実験を行った。また、二次音響経路は真の値が得られているものとした。より現実的な状況を想定し、参照信号と誤差信号はガウス性雑音とインパルス性雑音の和を活用して生成した。

$$\begin{aligned} \mathbf{x}_k &= \mathbf{x}_k^G + \mathbf{x}_k^I \\ \mathbf{v}_k &= \mathbf{v}_k^G + 0.1 \times \mathbf{v}_k^I \end{aligned} \quad (8)$$

ここで、 \mathbf{x}_k^G と \mathbf{v}_k^G はガウス性雑音であり、 \mathbf{x}_k^I と \mathbf{v}_k^I はインパルス性の雑音として広く用いられている α 安定分布を用いて生成した。

以下の6つのアルゴリズムを比較した。FxLMS[12], MFxLMS[6], Sun のアルゴリズム[13], Akhtar のアルゴリズム[14], 提案アルゴリズム(Proposed 1), $\lambda_k = \mathbf{0}$ の場合の提案アルゴリズム(Proposed 2). 表1にパラメータの設定をまとめた。既存法のステップサイズは初期の抑圧速度が同じになるように設定した。Sun と Akhtar のアルゴリズムでは、参照信号に含まれる極端に大きな係数を処理し、インパルス性の参照信号に対して安定した動作を実現しようとする。このとき、大きな係数を判別するための閾値を設定する必要がある。今回は、参照信号のうち2%の係数が処理されるように、閾値を設定した。

提案アルゴリズムでの重み付 ℓ_1 ノルムの重みは[15]の設計を用いた。

$$\begin{aligned} w_i^{(k)} &:= \nu(\hat{\chi}_i^{(k)}), \\ \nu: \mathbb{R} &\rightarrow (0, \infty), \nu(x) := \begin{cases} \delta & \text{if } |x| > \tau \\ 1 & \text{otherwise} \end{cases} \end{aligned}$$

ここで、 $\delta = 10^{-9}$, $\tau = 0.02$ とした。

性能評価の尺度として、Noise Residual (NR)を用いた。

$$(\text{NR}) = 10 \log_{10} \left(\frac{A_{e'_k}}{A_{d_k}} \right)$$

NR は制御がある場合 ($\mathbf{d}_k := \mathbf{p}_*^t \mathbf{x}_k$) と制御がない場合 ($e'_k = \mathbf{d}_k - \mathbf{s}_*^t \mathbf{y}_k$) の誤差信号の二乗の比を用いて定義されており、小さい値が望ましい。グラフの振動を抑えて性能の比較をしやすくするため、それぞれの誤差信号に対して、低域通貨フィルタを適用した。

$$\begin{aligned} A_{e'_k} &:= \eta A_{e'_{k-1}} + (1 - \eta)(e'_k)^2 \\ A_{d_k} &:= \eta A_{d_{k-1}} + (1 - \eta)d_k^2 \end{aligned}$$

スパース性を有する一次音響経路に対して、NR性能の比較を図2に示した。FxLMS と Sun のアルゴリズムはインパルス性の参照信号に対して不安定であるが、他のアルゴリズムは安定した騒音制御を実現している。この実験では、Proposed 1 が最も良い性能を実現している。Proposed 2 と比較することで、スパース性の活用による4dB程度の性能改善が確認できた。

一方で、スパース性を有していない一次音響経路に対するNR性能の比較を図3に示した。この場合、スパース性の仮定が成立しないため、Proposed 1 の性能がProposed 2 に比べて僅かに劣化しているが、他の既存法には勝る性能を示している。以上より、提案アルゴリズムがスパース性の仮定が成立しない場合においても、優れた性能を実現することを確認できた。

5 まとめ

本研究課題では、事前情報を活用するフィードフォワード型能動騒音制御アルゴリズムを提案した。まず、フィードフォワード型能動騒音制御における線形モデルを陽に示した。次に、適応 Douglas-Rachford

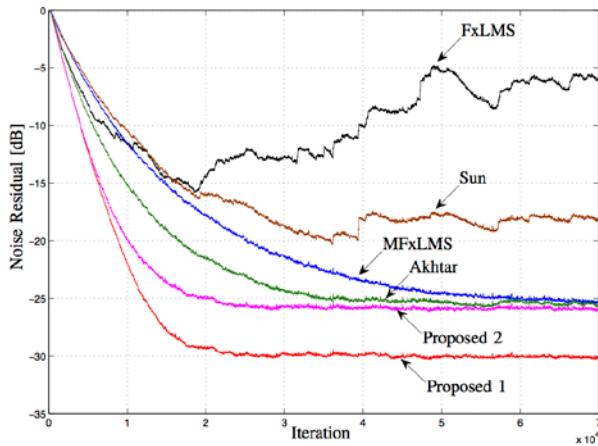


図 2 一次音響経路がスパースな場合

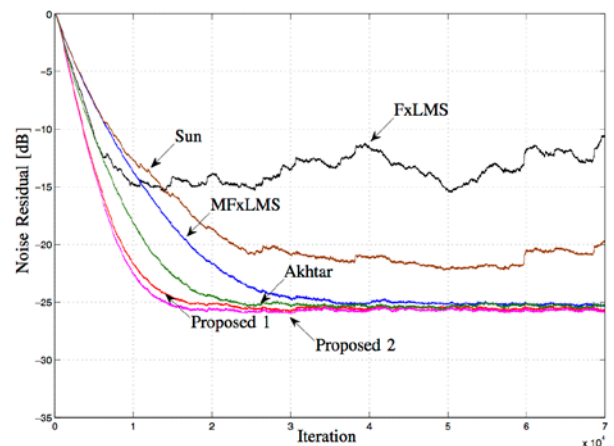


図 3 非スパースな場合

分離法を用いてアルゴリズムを導出し、事前情報を活用する自由度を担保した。また、その一例として、一次音響経路のスパース性を有効に活用する適応学習アルゴリズムを提案した。数値実験において、スパース性を活用することによって、騒音制御能力の向上を確認した。

今後の課題として、(i) 種々の能動騒音制御に対し事前情報の活用を導入すること、(ii) 二次音響経路の動的推定手法との融合、(iii) スパース性活用の枠組みのさらなる性能改善などが挙げられる。(i) 周期性を有する騒音に特化した能動騒音制御や、複数の参照マイク・誤差マイクを活用するマルチチャンネル能動騒音制御など、種々の能動騒音制御がそれぞれの目的のために活用されていることを鑑み、これらの手法に対して事前情報の活用を導入し、さらなる性能の向上を実現したい。(ii) 本研究課題では、二次音響経路が変動しない状況を想定した。しかし、一般にはこの仮定が成立しない状況において能動騒音制御が必要となることもある。その場合には、二次音響経路の動的推定と組み合わせ、安定して動作する適応学習アルゴリズムが必要となる。これを実現し、提案手法の適応可能性を大きく広げたいと考えている。(iii) スパース性を活用する能動騒音制御において、各反復の計算に離散フーリエ変換が必要であるため、MFxLMSなどに比べて計算量が多い。そのため、計算量のさらなる削減が必要となる。

【参考文献】

- [1] P. A. Nelson and S. J. Elliot, *Active Control of Sound*, Academic Press, Inc., 1993.
- [2] S. M. Kuo and D. R. Morgan, *Active Noise Control Systems: Algorithms and DSP Implementation*, Wiley, New York, 1996.
- [3] I. Yamada, S. Gandy, and M. Yamagishi, "Sparsity-aware adaptive filtering based on a Douglas-Rachford splitting," in *Proc. EUSIPCO*, 2011, pp. 1929–1933.
- [4] C. Paleologu, J. Benesty, and S. Ciochina, *Sparse Adaptive Filters for Echo Cancellation*, Morgan and Claypool Publishers, 2010.
- [5] B. Widrow and S. D. Stearns, *Adaptive Signal Processing*, Prentice-Hall, 1985.
- [6] E. Bjarnason, "Active noise cancellation using a modified form of the filtered-x LMS algorithm," in *Proc. EUSIPCO*, 1992, pp. 1053–1056.
- [7] J. B. Hiriart-Urruty and C. Lemarechal, *Convex Analysis and Minimization Algorithms*, vol. 1–2, Springer-Verlag, 1993.
- [8] J. J. Moreau, "Fonctions convexes duales et points proximaux dans un espace hilbertien," *C. R. Acad. Sci. Paris Ser.*, vol. 255, pp. 2897–2899, 1962.
- [9] E. J. Candes, M. B. Wakin, and S. P. Boyd, "Enhancing sparsity by reweighted ℓ_1 minimization. *Journal of Fourier analysis and applications*," vol. 14, no. 5–6, pp. 877–905, 2008.
- [10] J. Huang, S. Ma, and C. H. Zhang, "Adaptive Lasso for sparse high-dimensional regression models." *Statistica Sinica*, vol. 18, no. 4, 30pp., 2008.
- [11] G. H. Golub and C. F. Van Loan, *Matrix Computations*, Johns Hopkins University Press, 3 edition, 1996.

- [12] D.R. Morgan, "An analysis of multiple correlation cancellation loops with a filter in the auxiliary path," IEEE Transactions on Acoustics, Speech and Signal Processing, vol. 28, no. 4, pp. 454–467, 1980.
- [13] X. Sun, S. M. Kuo, and G. Meng, "Adaptive algorithm for active control of impulsive noise," Journal of Sound and Vibration, vol. 291, no. 1, pp. 516–522, 2006.
- [14] M. T. Akhtar and W. Mitsuhashi, "Improving performance of FxLMS algorithm for active noise control of impulsive noise," Journal of Sound and Vibration, vol. 327, no. 3, pp. 647–656, 2009.
- [15] Y. Murakami, M. Yamagishi, M. Yukawa, and I. Yamada, "A sparse adaptive filtering using time-varying soft-thresholding techniques," in Proc. IEEE ICASSP, 2010, pp. 3734–3737.

〈発表資料〉

題名	掲載誌・学会名等	発表年月
Shrinkage Tuning Based on An Unbiased MSE Estimate for Sparsity-aware Adaptive Filtering	Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2014	2014年5月
Avoiding Local Trap in Nonlinear Acoustic Echo Cancellation with Clipping Compensation	Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2014	2014年5月
Mean-square performance of the hyperslab-based adaptive projected subgradient method	Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2014	2014年5月
Exploiting Sparsity in Feed-Forward Active Noise Control with Adaptive Douglas-Rachford Splitting	Proceedings of Asia-Pacific Signal and Information Processing Association (APSIPA) Annual Summit and Conference 2013	2013年8月