混响环境下基于卷积神经网络的方向选择性固定滤波器主动噪声控制

Boxiang Wang*、Zhengding Luo*、Haowen Li*、Dongyuan Shi†、Junwei Ji*、Ziyi Yang*、Woon-Seng Gan*
* 南洋理工大学电气与电子工程学院，新加坡 电子邮箱：{boxiang001, luoz0021, junwei002, ziyi016}@e.ntu.edu.sg，{haowen.li, ewsgan}@ntu.edu.sg
† 西北工业大学智能声学与沉浸式通信中心，中国 电子邮箱：dongyuan.shi@nwpu.edu.cn

arXiv:2601.06981v1 [cs.SD] 11 Jan 2026

摘要——**选择性固定滤波器主动噪声控制（SFANC）是一种新颖的方法，能够抑制频率特性各异的噪声。与传统自适应算法相比，该方法响应更快，计算效率更高。然而，空间因素，尤其是噪声源位置的影响，往往被忽视。已有一些研究探讨噪声源到达方向（DoA）对主动噪声控制性能的影响，但大多仅限于自由场条件，未考虑更复杂的室内混响环境。为弥补这一不足，本文提出一种基于学习的方向性选择性固定滤波器主动噪声控制方法，将混响环境中噪声源的到达方向纳入考量。在该框架中，多个参考信号由卷积神经网络（CNN）处理，用于估计噪声源的方位角和俯仰角，并识别最适合实现有效噪声消除的控制滤波器。与传统自适应算法相比，即使存在混响，所提出的方法也能以更短的响应时间实现更优的降噪效果。**

一、引言

主动噪声控制（ANC）是一种先进技术，能够有效衰减低频噪声，与传统被动噪声控制方法相比，它更紧凑、轻便 [1]。在主动噪声控制系统中，次级声源由控制信号驱动，产生与非期望噪声振幅相等、相位相反的反噪声，从而通过声波相消干涉原理降低干扰 [2]。凭借紧凑的尺寸和有效的降噪能力，主动噪声控制已广泛应用于各种场景 [3], [4]。为应对时变噪声和动态声学环境，通常采用滤波-x最小均方（FxLMS）等自适应算法，实时更新控制滤波器 [5], [6]。然而，这些算法通常计算复杂度高、收敛速度慢，并且存在发散风险 [7], [8]。为确保简便性和稳定性，许多商用主动噪声控制系统采用系数固定的预训练控制滤波器 [3]。然而，这类固定滤波器方法的性能对噪声源类型和到达方向（DoA）的变化十分敏感，因此，当其中任一因素发生变化时，效果往往不够理想。

为克服这些局限性，研究人员提出了选择性固定滤波器主动噪声控制（SFANC）方法，通过传统信号处理技术 [9], [10] 或基于深度学习的方法 [11], [12], [13]，为各种输入噪声类型选择最合适的控制滤波器。该方法在保持较低计算成本和快速响应时间的同时，能够更稳健地应对频率特性各异的噪声源。然而，SFANC方法主要关注噪声的频率成分，却忽视了到达方向（DoA）等空间信息，而事实证明，这些信息对主动噪声控制系统的性能也至关重要 [14]。

迄今为止，已有多位研究人员开发了将到达方向的影响纳入主动噪声控制系统的方法。一些研究旨在通过改善主动噪声控制系统的因果性，增强来自不同方向的噪声消除能力[15]。另一些研究则着眼于实现空间选择性，即抑制非期望噪声，同时保留期望声音。实现这一目标的方法有两种：先同时消除噪声和期望声音，再重新生成期望声音 [16], [17], ；或者选择性地控制非期望噪声，使期望声音不受影响 [18]。然而，这些技术依赖自适应算法来实时更新控制滤波器。Toyooka 等人提出了一种方法，可选择与不同噪声源位置相对应的固定滤波器 [19]。Su 等人则提出了另一种方法，在多通道主动噪声控制系统中，根据噪声源的频率和方向信息选择控制滤波器 [20], [21]。然而，这些方法仅适用于自由场环境，并依赖传统信号处理技术来估计到达方向，因此无法有效应对复杂混响环境中的噪声源。相比之下，深度神经网络（DNN）无需特定的建模假设，便能准确估计声源位置，是应对这类复杂声学条件的理想选择 [22]。

为解决这一局限，本文提出一种基于卷积神经网络（CNN）的定向 SFANC 方法，该方法将混响环境中噪声源的到达方向（DoA）信息纳入其中。为此，本文在协处理器上部署了一个采用多任务学习训练的 CNN，以估计

基于多个参考信号的噪声源俯仰角和方位角，并以帧为单位选择最合适的控制滤波器。随后逐样本应用所选控制滤波器，实现无延迟噪声控制。

本文其余部分安排如下：第二节介绍基于深度神经网络的到达方向估计和多参考主动噪声控制系统的基础知识。第三节阐述所提出的定向 SFANC 方法的总体框架和具体细节。第四节通过数值仿真评估所提算法的性能。最后，第五节总结全文并展望未来研究方向。

II. 基于深度神经网络的定向主动噪声控制预备知识

A. 基于深度神经网络的到达方向估计的一般原理

基于深度神经网络的到达方向估计依赖于由环境中空间分布的 J 个麦克风阵列所采集的多通道信号，这些信号共同捕获声源的方向信息。在混响环境中，第 j个麦克风接收到的信号可建模为

$$r_j(n) = q_j(n) * x(n), \tag{1}$$

其中， $r_j(n)$ 表示第 j 个麦克风接收到的信号， $x(n)$ 表示声源信号， $q_j(n)$ 表示声源与第 j 个麦克风之间的房间脉冲响应（RIR）， $*$ 表示线性卷积算子。

由于声源位置、麦克风位置和室内声学条件各不相同，每个麦克风捕获的声源信号都与一个不同的房间脉冲响应（RIR）卷积。这些变化导致通道间存在时延和幅度差异，其中编码了声源相对于麦克风阵列的到达方向空间信息。深度神经网络（DNN）能够自动识别多通道信号特征与声源位置之间的关系。与传统的到达方向估计技术相比，这一方法具有显著优势；传统技术通常依赖特定的建模假设，在复杂室内环境中的表现往往较差。因此，所提出的定向 SFANC 框架采用卷积神经网络来估计噪声源的到达方向，具体包括方位角 θ 和仰角 ϕ 。

B. 多参考主动噪声控制系统

除了到达方向估计外，多通道信号还可用作主动噪声控制系统的参考输入。图 1 展示了多参考主动噪声控制系统的框图，该系统由 J 个参考麦克风、1 个次级声源和 1 个误差麦克风组成。用于驱动次级声源的控制信号表示为

$$y(n) = \sum_{j=1}^{J} \mathbf{r}_j^{\mathrm{T}}(n)\mathbf{w}_j(n), \tag{2}$$

其中 $\mathbf{r}_j(n) = [r_j(n)\ r_j(n-1)\ \cdots,\ r_j(n-L+1)]^{\mathrm{T}}$是第$j$个参考信号向量，$\mathbf{w}_j(n) = [w_{j,1}(n)\ w_{j,2}(n)\ \cdots,\ w_{j,L}(n)]^{\mathrm{T}}$ 是第 j个控制滤波器

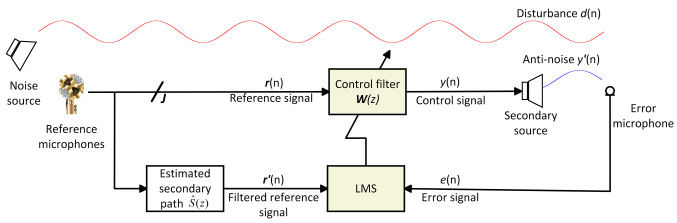

Fig. 1. 多参考主动噪声控制系统框图 。

向量， L是控制滤波器长度，T 表示矩阵转置算子。

误差麦克风拾取的误差信号表示为

as

$$e(n) = d(n) - \mathbf{y}^{\mathrm{T}}(n)\mathbf{s}(n), \tag{3}$$

其中， $d(n)$ 是误差麦克风处的干扰，$\mathbf{y}(n) = [y(n)\ y(n-1)\ \cdots,\ y(n-L_s+1)]^{\mathrm{T}}$ 是控制信号向量，$\mathbf{s}(n) = [s_1(n)\ s_2(n)\ \cdots,\ s_{L_s}(n)]^{\mathrm{T}}$ 是次级通道脉冲响应， L_s 是次级通道长度。

根据 FxLMS 算法，第 j 个控制滤波器系数按以下方式更新:

$$\mathbf{w}_j(n+1) = \mathbf{w}_j(n) + \mu\mathbf{r}'_j(n)e(n), \tag{4}$$

其中， μ是步长，$\mathbf{r}'_j(n)$ 是滤波参考信号，它由参考信号通过估计的次级通道得到，表示为

$$\mathbf{r}'_j(n) = \hat{s}(n) * \mathbf{r}_j(n) \tag{5}$$

然而，自适应FxLMS算法需要时间才能收敛，不合适的步长甚至可能导致噪声放大。为改善响应时间并增强系统稳定性，所提出的定向 SFANC 方法根据噪声源的到达方向选择预训练的固定滤波器。

III. 所提出的定向 SFANC 方法 D

所提出的定向SFANC技术的框图如图2所示。该系统由两个主要部分组成：用于噪声抵消的实时控制器，以及用于控制滤波器选择的协处理器。如图2所示，控制器以采样率运行以生成控制信号。与此同时，参考信号在每一帧被采集并传输至协处理器。其目标是利用参考信号中蕴含的信息，估计噪声源相对于参考麦克风阵列的方位角和俯仰角。基于这些输入，卷积神经网络输出每个方位角类别和仰角类别的预测概率，如下

$$(\hat{\mathbf{p}}_{\mathrm{azim}}, \hat{\mathbf{p}}_{\mathrm{elev}}) = CNN(\mathbf{R}; \Theta^*) \tag{6}$$

其中$\mathbf{R}$ 表示 J通道参考信号在一帧上的短时傅里叶变换（STFT）频谱图， Θ^* 表示训练后的卷积神经网络参数，$\hat{}\mathbf{p}_{\mathrm{azim}} = [\hat{}p_{\mathrm{azim},1}, \hat{}p_{\mathrm{azim},2},..., \hat{}p_{\mathrm{azim,A}}]$表示方位角类别上的预测概率分布，$\hat{}\mathbf{p}_{\mathrm{elev}} = [\hat{}p_{\mathrm{elev},1}, \hat{}p_{\mathrm{elev},2},..., \hat{}p_{\mathrm{elev,B}}]$ 表示仰角类别上的预测概率分布。

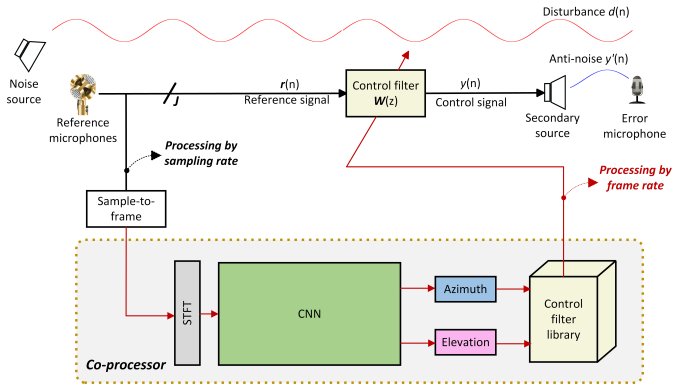

图 2. 所提出的定向 SFANC 方法的框图。

然后，估计得到的方位角索引$\hat{a}$ 可表示为

$$\hat{a} = \underset{i\in\{1,2,\ldots,A\}}{\arg\max}\ \hat{p}_{\mathrm{azim,i}}. \tag{7}$$

其中，$\hat{p}_{\mathrm{azim,\ i}}$ 表示第 i 个方位角类别的预测概率。

$\hat{}$ 估计的仰角索引 b 可由下式得到：

$$\hat{b} = \underset{k\in\{1,2,\ldots,B\}}{\arg\max}\ \hat{p}_{\mathrm{elev,k}}. \tag{8}$$

其中，$\hat{p}_{\mathrm{elev,\ k}}$ 表示第 k 个仰角类别的预测概率。

最后，根据预测的方位角索引和仰角索引，所选控制滤波器的系数以帧率更新。通过促进实时噪声控制器与协处理器之间的协作，所提出的定向 SFANC 方法实现了无延迟噪声控制。

A. 预训练控制滤波器库

在定向 SFANC 方法在线执行之前，必须预先训练一个控制滤波器库，以涵盖噪声源方位角和仰角的各种组合。具体而言，将参考麦克风阵列的水平面划分为 A 个方位角类别，并将垂直面划分为 B 个仰角类别。对于网格所定义的每个离散方向，均使用 FxLMS 算法针对宽带噪声预先训练一个控制滤波器。随后将这些控制滤波器存入库中，以供部署使用。

B. 使用多任务学习策略训练的卷积神经网络

在本研究中，我们采用卷积神经网络进行到达方向估计，研究发现这种方法在该任务中效果良好 [23]。所提出的卷积神经网络架构如图 3 所示。输入为一帧、 J通道的参考信号，使用短时傅里叶变换进行特征提取，将其转换为 J 幅度频谱图和 J相位频谱图。预处理后的数据依次通过三个卷积模块，每个模块均由卷积层、组归一化、ReLU 激活和最大池化组成。随后，采用自适应平均池化，对频率和时间维度进行平均，以缩减特征图。这些池化后的特征

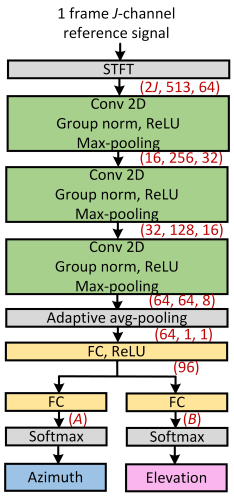

图 3. 所提出的卷积神经网络架构。

随后输入两个全连接（FC）层，以估计 A方位角和 B 仰角的类别概率。最终预测结果通过 Softmax 层获得。

如前所述，所选控制滤波器由卷积神经网络预测的方位角和仰角索引决定。为此，卷积神经网络采用多任务学习策略进行训练，同时执行方位角分类和仰角分类。这两个任务的损失函数均为交叉熵损失函数，分别记为 $Loss_{\mathrm{azim}}$ 和 $Loss_{\mathrm{elev}}$。用于训练卷积神经网络的联合损失函数表示为

$$Loss = Loss_{\mathrm{azim}} + Loss_{\mathrm{elev}} \tag{9}$$

这种联合损失使网络能够学习共享表示，同时兼顾两个任务的学习，从而提供了一种比单独训练多个模型更高效的替代方案 [24]。

IV. 数值仿真

在混响环境下的 4×1×1 多参考主动噪声控制系统中评估所提出的定向 SFANC 方法的有效性。系统采用直径为 2.5 cm 的四通道四面体麦克风阵列作为参考麦克风阵列，以有效捕捉噪声源的空间特征 [25]。如图 4 所示，为构建预训练控制滤波器库，将麦克风阵列的水平面划分为六个方位角类别：0°、60°、120°、180°、240° 和 300°；将垂直面划分为三个仰角类别：90°、30° 和 -30°。噪声源与麦克风阵列之间的距离固定为 0.2 m。在该空间网格所定义的每个离散方向上，使用 FxLMS 算法，以 20–2020 Hz 范围内的宽带噪声预训练一个控制滤波器，目标频段为主动噪声控制系统通常处理的低频带。总共训练了 13 个控制滤波器，并将其存储在滤波器库中。短时傅里叶变换采用 1024 个采样点的汉宁窗，帧移为 64 个采样点，系统的采样频率为 16 kHz。

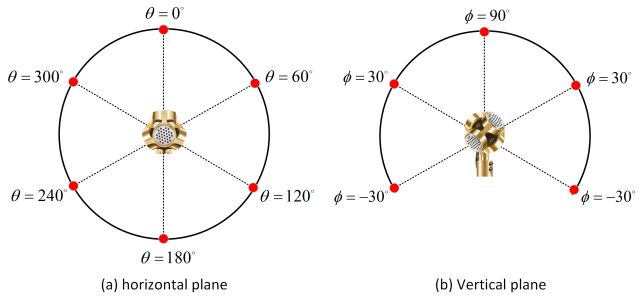

图 4. 预训练控制滤波器库示意图：(a) 水平面上定义的方位角类别；(b) 垂直面上定义的仰角类别。

表 I 训练、验证和测试数据集的配置。

训练和验证数据集	
噪声信号	合成噪声和真实噪声
房间尺寸（米）	R1：（6x4x3）；R2：（12x8x3.5）；R3：（16x14x4）
阵列位置	每个房间中的 8 个任意位置
RT_{60}（秒）	R1：0.1、0.2、0.3；R2：0.4、0.5、0.6；R3：0.7、0.8、0.9
信噪比（dB）	在 30 到 50 之间均匀采样
测试数据集	
噪声信号	合成噪声与真实噪声
房间尺寸（米）	（11x9x3.2）
阵列位置	每个房间内的4个任意位置
RT_{60}（秒）	0.48
信噪比（dB）	30、40、50

表II 不同信噪比下卷积神经网络的分类准确率。

指标	**信噪比 = 30dB**	**信噪比 = 40dB**	**信噪比 = 50 dB**
方位角准确率	96.4%	96.4%	96.4%
仰角准确率	90.7%	90.8%	91.0%

A. 基于卷积神经网络的到达方向估计

1) 数据集生成：首先构建一个同时包含合成和真实噪声信号的噪声数据集。合成噪声是通过带宽各异的带限白噪声生成的，而真实噪声则取自 UrbanSound8K 数据集 [26]。随后，将生成的噪声信号与各种房间脉冲响应进行卷积，以生成由四面体麦克风阵列采集的参考信号，并加入加性噪声。噪声源相对于麦克风阵列的方位角从 [0°、360°]，范围内随机选取；仰角从 [-60°、90°], 范围内随机选取；声源到阵列的距离从 [0。1 m、0.6 m], 范围内随机选取，同时确保阵列与表面的距离大于 1 m。根据图 4 的定义，将最近的方位角和仰角类别指定为相应标签。为增强系统在不利声学条件下的鲁棒性，训练数据集和验证数据集纳入了由不同房间尺寸、阵列位置、混响时间（RT_{60}）和信噪比（SNR）水平所产生的房间脉冲响应变化。测试数据集中的噪声类型和声学环境均不同于训练期间使用的类型和环境，从而确保对泛化性能进行公平评估。数据集概述

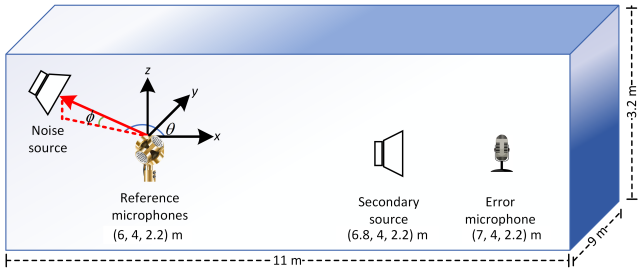

图 5. 4x1x1 多参考主动噪声控制系统的仿真布置。

配置见表 I。房间脉冲响应使用基于镜像法 [28]的 *gpuRIR* 库 [27] 生成。

该数据集共包含 46080 个训练样本（38400 个合成数据，7680 个真实样本）、5760 个验证样本（4800 个合成数据，960 个真实样本）和 4800 个测试样本（4000 个合成数据，800 个真实样本）。每个样本均为四通道、时长 0.5 秒的帧。

2) 未见声学环境和噪声类型下的分类准确率：如表 II所示，在不同信噪比水平下，所提出的卷积神经网络对方位角和仰角的分类准确率分别约为 96% 和 91%。值得注意的是，测试时使用了未见过的噪声类型和声学环境，这些结果凸显了模型出色的泛化能力和对现实世界变化的鲁棒性。此外，该卷积神经网络计算效率高，仅包含 0.03 百万个参数，CPU 运行时间为 7.83 ms，乘加运算（MAC）次数为 119.86 百万次，因此适合部署在嵌入式设备上。这些结果表明，所提出的方法能够有效地为具有不同到达方向的噪声源选择合适的控制滤波器，从而在混响环境中实现高效噪声控制。

B. 基于到达方向估计的噪声消除

在表 1 总结的测试环境中进行噪声消除仿真，采用图 5 所示的 4x1x1 多参考主动噪声控制系统布置。将所提出的定向 SFANC 方法与几种基线方法进行比较，包括传统的 FxLMS 算法、标准 SFANC [29], 和生成式固定滤波器主动噪声控制（GFANC） [30]。对于标准 SFANC 和 GFANC 方法，预训练的控制滤波器使用位于 ($\theta = 0°$, $\phi = 30°$) 的噪声源进行训练，该位置对应于参考麦克风阵列的中心。

1）宽带噪声消除：为评估所提出的定向 SFANC 方法对宽带噪声的降噪性能，首先将频率范围为 100–700 Hz 的初级噪声信号放置在相对于参考麦克风阵列的 ($\theta = 120°$, $\phi = 30°$) 处。应用 FxLMS、SFANC、GFANC 和定向 SFANC 方法后得到的残余噪声功率谱密度（PSD）如图 6(a) 所示。PSD 通过对信号的整个持续时间取平均计算得出，FxLMS 算法的步长设为 1×10^{-4}。此外，四种方法每 0.5 秒的平均降噪水平

参考文献

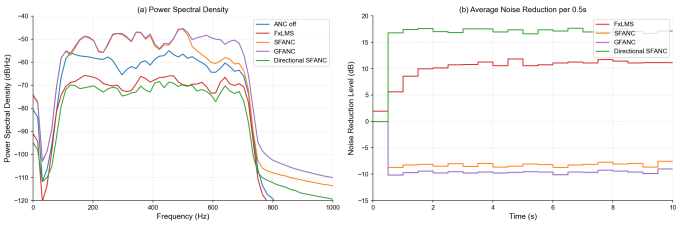

图 6。（a）相对于参考麦克风阵列，位于（$\theta = 120°$，$\phi = 30°$）的 100–700 Hz 宽带噪声经不同主动噪声控制算法衰减后的功率谱密度（PSD）；（b）每 0.5 秒的平均降噪水平。

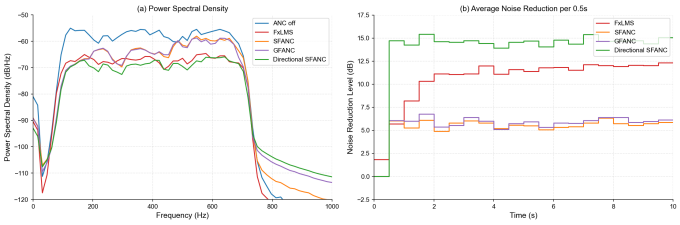

图 7。（a）相对于参考麦克风阵列，位于（$\theta = 0°$，$\phi = -30°$）的 100–700 Hz 宽带噪声经不同主动噪声控制算法衰减后的功率谱密度（PSD）；（b）每 0.5 秒的平均降噪水平。

如图 6(b) 所示。对于位于相对于参考麦克风阵列的 ($\theta = 0°$，$\phi = -30°$) 处的噪声源，也进行了类似的评估，结果如图 7 所示。如图 6 和图 7 所示，与传统 FxLMS 算法相比，所提出的定向 SFANC 方法在响应时间和降噪性能方面均表现更优。此外，当噪声源的方位角或仰角偏离 SFANC 和 GFANC 方法所用预训练滤波器的位置时，这些方法的噪声消除能力有限，甚至可能放大噪声。这种性能下降是由于它们无法跟踪噪声源到达方向的变化。

2）真实环境噪声消除： 为评估所提出的定向 SFANC 方法对真实环境噪声的降噪性能，将一个洗衣机噪声源放置在相对于参考麦克风阵列的（$\theta = 110°$，$\phi = -15°$）位置。采用 FxLMS、SFANC、GFANC 和定向 SFANC 方法后残余噪声的功率谱密度（PSD）如图 8（a）所示。此外，四种方法在每个 0.5 秒时间间隔内实现的平均降噪水平如图 8（b）所示。可以观察到，即使噪声源位于预训练控制滤波器库未包含的位置，所提出的定向 SFANC 方法与 FxLMS算法相比仍能实现更优的降噪性能和更快的响应时间。相比之下，由于无法适应噪声源到达方向（DoA）的变化，SFANC 和 GFANC 方法往往会放大噪声。

V. 结论

本文提出一种新颖的定向 SFANC 方法，以应对复杂混响

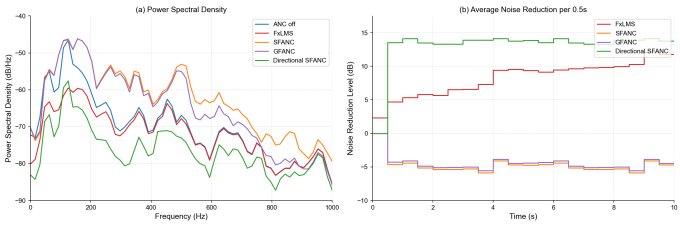

图 8. 相对于参考麦克风阵列，位于 ($\theta = 110°$，$\phi = -15°$) 的洗衣机噪声经不同主动噪声控制算法衰减后的 (a) 功率谱密度和 (b) 每 0.5 秒的平均噪声降低量。

环境中到达方向不断变化的噪声源。该方法采用通过多任务学习训练的轻量级卷积神经网络，根据参考信号动态选择最优控制滤波器。仿真结果表明，对于各种到达方向下的宽带噪声和真实噪声，所提出的方法均显著优于传统 FxLMS 算法，在混响条件下响应更快、降噪效果更佳。相比之下，许多现有的基于学习的主动噪声控制方法难以适应噪声源方向的变化。

尽管当前方法具有诸多优点，但尚未考虑声源到阵列的距离，而该距离也可能影响主动噪声控制性能。未来的工作将通过将距离估计整合到控制框架中来解决这一问题。

参考文献

[1] S. J. Elliott 和 P. A. Nelson，“主动噪声控制”，*IEEE Signal Processing Magazine*，第 10 卷，第 4 期，第 12–35 页，1993 年。[2] S. M. Kuo 和 D. R. Morgan，“主动噪声控制：教程综述”，*Proceedingsof the IEEE*，第 87 卷，第 6 期，第 943–973 页，1999 年。[3] X. Shen、D. Shi、W.-S. Gan 和 S. Peksi，“应用于主动降噪耳机的固定滤波器自适应增益算法”，*Mechanical Systems and Signal Processing*，第 169 卷，文章编号 108641，2022 年。[4] W. Jung、S. J. Elliott 和 J. Cheer，“车辆内部道路噪声的局部主动控制”，*Mechanical Systems andSignal Processing*，第 121 卷，第 144–157 页，2019 年。[5] D. Morgan，“辅助通道中带滤波器的多重相关消除环路分析”，*IEEE Transactions on Acoustics, Speech, andSignalProcessing*，第 28 卷，第 4 期，第 454–467 页，1980 年。[6] J. Ji、D. Shi、Z. Luo、B. Wang 和 W.-S. Gan，“自增强权重约束 FXLMS：一种无需节点间通信的鲁棒分布式主动噪声控制算法”，*IEEESignal Processing Letters*，2025 年。[7] B. Wang、J. Ji、X. Shen、D. Shi 和 W.-S. Gan，“采用多通道伴随最小均方算法的计算高效虚拟传感方法”，载于 *INTER-NOISE and NOISE-CON Congress and Conference Proceedings*，噪声控制工程学会，第 270 卷，2024 年，第 1638–1650 页。

[8] J. Ji、D. Shi、B. Wang、X. Shen、Z. Luo 和 W.-S. Gan，“主动噪声控制中的输出饱和预防：一种输出约束卡尔曼滤波器方法”，载于*ICASSP2025-2025IEEE International Conference on Acoustics,Speech and SignalProcessing (ICASSP)*，IEEE，2025 年，第 1–5 页。[9] D. Shi、W.-S. Gan、B. Lam 和 S. Wen，“前馈选择性固定滤波器主动噪声控制：算法与实现”，*IEEE/ACM*音频、语音与语言处理汇刊，第 28 卷，第 1479–1492 页，2020 年。[10] C. Shi、R. Xie、N. Jiang、H. Li 和 Y. Kajikawa，“多通道前馈主动噪声控制系统的选择性虚拟传感技术”，载于*ICASSP2019-2019IEEE International Conference on Acoustics,Speech and SignalProcessing (ICASSP)*，IEEE，2019 年，第 8489–8493 页。[11] Z. Luo、D. Shi 和 W.-S. Gan，“一种基于深度学习的主动噪声控制混合 SFANC-FxNLMS 算法”，*IEEE*信号处理快报，第 29 卷，第 1102–1106 页，2022 年。[12] B. Wang 等，“基于深度学习的主动饰板：提升飞机舱内噪声控制效果”，载于第*31*届国际声与振动大会，韩国噪声与振动工程学会，2025 年。[13] B. Wang、D. Shi、Z. Luo、X. Shen、J. Ji 和 W.-S. Gan，“基于度量学习的可迁移选择性虚拟传感主动噪声控制技术”，载于*ICASSP2025-2025IEEE International Conference on Acoustics,Speech and SignalProcessing (ICASSP)*，IEEE，2025 年，第 1–5 页。[14] S. Liebich、J.-G. Richter、J. Fabry、C. Durand、J. Fels 和 P. Jax，“主动降噪耳机对到达方向的依赖性”，载于噪声控制与声学分部会议，美国机械工程师学会，第 51425 卷，2018 年，V001T08A003。[15] L. Zhang 和 X. Qiu，“自由场中不同噪声入射方向下前馈主动噪声控制耳机的因果关系研究”，应用声学，第 80 卷，第 36–44 页，2014 年。[16] V. Patel、J. Cheer 和 S. Fontana，“具有定向环境声通透功能的主动降噪耳机设计与实现”，*IEEE*消费电子汇刊，第 66 卷，第 1 期，第 32–40 页，2019 年。[17] H. Zhang、J. Zhang、F. Ma、H. Sun 和 P. N. Samarasinghe，“采用声场分离算法的定向空间主动噪声控制系统”，美国声学学会期刊，第 154 卷，第 4 期增刊，A162–A162，2023 年。[18] T. Xiao、B. Xu 和 C. Zhao，“空间选择性主动噪声控制系统”，美国声学学会期刊

美国声学学会, vol. 153, no. 5, pp. 2733–2733, 2023.[19] S. Toyooka and Y. Kajikawa, “具备抗噪声源移动能力的声源定位主动噪声控制系统,” *IEICE Transactions onFundamen-tals of Electronics, Communicationsand ComputerSci-ences*, vol. 108, no. 2, pp. 160–164, 2025.[20] X. Su, D. Shi, Z. Zhu, W.-S. Gan, and L. Ye, “基于空间频率的多通道主动噪声控制选择性固定滤波器算法,” *IEEE*信号处理快报, 2024.[21] X. Su, D. Shi, B. Wu, L. Ye, and W.-S. Gan, “基于动态因子图的选择性固定滤波器多通道主动噪声控制时变空间频率图联合预测,” *IEEE*音频、语音与语言处理汇刊, 2025.[22] H. Li, W. Zhang, and L. Zhang, “使用基于神经网络的多重信号分类算法估计室内反射的到达方向,” in*2023*亚太信号与信息处理协会年度峰会暨会议 *(APSIPA ASC)*, IEEE, 2023, pp. 1960–1965.[23] P.-A. Grumiaux, S. Kiti´c, L. Girin, and A. Gu´erin, “深度学习方法在声源定位中的研究综述,” 美国声学学会期刊, vol. 152, no. 1, pp. 107–151, 2022.[24] Y. Zhang and Q. Yang, “多任务学习综述,” *IEEE transactions on knowledgeand dataengi-neering*, vol. 34, no. 12, pp. 5586–5609, 2021.[25] S. S. Kushwaha, I. R. Roman, M. Fuentes, and J. P. Bello, “多种动态声学条件下的声源距离估计,” in *2023 IEEE*音频与声学信号处理应用研讨会 *(WASPAA)*, IEEE, 2023, pp. 1–5.[26] J. Salamon, C. Jacoby, and J. P. Bello, “城市声音研究的数据集与分类体系,” in 第*22*届*ACM*多媒体国际会议论文集, 2014, pp. 1041–1044.[27] D. Diaz-Guerra, A. Miguel, and J. R. Beltran, “Gpurir：用于房间脉冲响应仿真的GPU加速 Python库,” *Multimedia Tools andApplica-tions*, vol. 80, no. 4, pp. 5653–5671, 2021.[28] J. B. Allen and D. A. Berkley, “用于高效模拟小房间声学的镜像法,” 美国声学学会期刊, vol. 65, no. 4, pp. 943–950, 1979.[29] Z. Luo, D. Shi, J. Ji, X. Shen, and W.-S. Gan, “基于无延迟卷积神经网络的选择性固定滤波器主动噪声控制的实时实现与可解释人工智能分析,”*MechanicalSystemsandSignal Processing*, vol. 214, p. 111 364, 2024.[30] Z. Luo, J. Ji, B. Wang, D. Shi, H. Ma, and W.-S. Gan, “基于深度学习的生成式固定滤波器主动噪声控制：可迁移性与实现,” *Mechani-cal Systems and Signal Processing*, vol. 238, p. 113207, 2025