Journal of Applied Acoustics

◇ 研究报告 ◇

复合深度神经网络在直升机声目标识别中的研究

郭 洋^{1,2} 周 翊² 管鲁阳^{1†} 鲍 明¹

(1 中国科学院噪声与振动重点实验室(声学研究所) 北京 100190)(2 重庆邮电大学 重庆 400065)

摘要 针对直升机探测中目标运动过程连续识别的鲁棒性问题,提出了一种基于复合深度神经网络的直升机 声学特征提取和识别框架。复合深度神经网络由卷积神经网络和长短时记忆神经网络以并行结构组合,进行 直升机声学特征的优化,完成直升机类型识别。针对直升机声信号特性,对卷积神经网络进行了改进,使得该 复合深度神经网络在信号短时谱基础上优化声信号特征表征并提取前后帧之间的相关信息,弥补通常声目标 识别方法不能充分利用目标信号时间历程信息的缺陷。真实外场实验数据测试结果显示:相较于传统识别方 法,该算法显著提升了直升机进入有效探测范围后连续识别的鲁棒性和目标识别正确率。

关键词 深度神经网络,声目标识别,直升机识别

中图法分类号: TB535+.3 文献标识码: A 文章编号: 1000-310X(2019)01-0008-08 DOI: 10.11684/j.issn.1000-310X.2019.01.002

Research on combined deep neural network in acoustic helicopter target recognition

GUO Yang^{1,2} ZHOU Yi² GUAN Luyang¹ BAO Ming¹

(1 Key Laboratory of Noise and Vibration Research, Chinese Academy of Sciences, Beijing 100190, China)

(2 Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract To improve the performance of continuous recognition of acoustic targets, a novel combined deep neural network was proposed to extract features and recognize helicopters. In the framework of the combined deep neural network, a modified convolutional neural network and a long short-term memory neural network were combined primarily in a parallel manner to optimize the representation of helicopter's acoustic characteristics and implement helicopter type recognition. The optimized feature pattern extracted by the combined deep neural network included the current spectral characteristics and time series information hidden in the input short-term spectrum. It was designed to overcome the lack of time information of the target signal in the conventional acoustic target recognition methods. The proposed method was tested using the real helicopter acoustic signals from the field experiments. The results indicate that the proposed combined deep neural network significantly improves the recognition accuracy and the robustness of the continuous acoustic target recognition when the target is within the detection range.

Key words Deep neural network, Acoustic target recognition, Helicopter recognition

²⁰¹⁸⁻⁰⁵⁻⁰³ 收稿; 2018-09-04 定稿

作者简介: 郭洋 (1994-), 男, 四川达州人, 硕士研究生, 研究方向: 信号与信息处理。

[†]通讯作者 E-mail: guanluyang@mail.ioa.ac.cn

0 引言

声学探测根据目标自身噪声进行目标探测识 别,具有全向探测无盲区、被动探测隐蔽性好等优 势,是目标识别的重要手段之一,可成为雷达、光 学等传统目标探测方式的补充,提供更丰富的信息 和更好的环境适应能力^[1-2]。为了尽早发现目标, 并考虑到目标声信号的短时平稳性,现有的声目标 识别通常采用声信号分帧处理的方法。 借鉴声信号 处理技术,人工设计特征提取方法获得每帧信号的 特征并进行识别,从而快速更新识别结果。特征提 取主要有以下两种思路:第一种是直接检测目标的 物理参数作为判别依据,如文献[3]检测直升机声 信号的基频及谐频的频率。该方法物理意义明确, 但在低信噪比条件下难以准确估计上述参数,不能 适应复杂的实际应用环境。第二种,也是主流的方 法,通常是以各种信号处理或数据处理技术从直升 机声信号中抽象出特征再由分类器进行识别^[4]。其 与第一种方法的主要区别在于信号特征与直升机 型号参数之间的物理关系不明确,需要通过分类器 的训练建立信号特征与直升机型号之间的映射。传 统的声信号特征提取在声信号分析处理基础上进 行优化,寻找能有效识别目标且维数尽量低的特征 表征方法。典型的声信号特征包括短时傅里叶频 谱特征、小波特征、线性预测倒谱系数等信号处理 参数特征,以及Mel频率倒谱系数(Mel-frequency ceptral coefficients, MFCC)等反映人类听觉特性 的声学特征等。

近年来随着深度学习技术的快速发展,越来越 多的研究人员开始采用深度学习进行声目标识别 研究,并借助深度神经网络实现特征优化和目标识 别^[5-6]。如文献[6]利用稀疏自编码器从声信号短 时傅里叶谱中提取浅层目标特征,再结合堆叠自编 码器从浅层目标特征中进一步提取更抽象的目标 特征用于水下目标识别,由此得到的识别正确率相 较于传统方法有显著提升。但这种利用深度学习的 方法与传统方法类似,仅利用了当前数据帧的特征 进行识别得到当前识别结果,实际使用中通常需要 后处理环节以利用时间历程信息减少虚警和漏警。

本文在对直升机飞行噪声分析的基础上,利用 深度学习技术从直升机声信号短时谱图中自动进 行特征提取和分类识别,优化信号的局部时频信息 和时序相关信息的表征,以提高直升机飞行过程中 声信号连续识别的鲁棒性和正确率。

1 直升机声信号分析

直升机飞行噪声主要来自旋翼、发动机等部件的周期性运动及带动气流产生的气动噪声,其中旋 翼是主要的噪声来源^[7]。直升机从远处直线飞行经 过测点再飞离这一完整飞行事件的声信号短时谱 图如图1所示,线谱噪声主要分布在1.5 kHz以下, 是主旋翼周期性运动产生的一系列谐频信号。

基于声信号的直升机远距离连续探测识别中 存在不利因素:直升机在测点附近时,宽带气动噪声 增强,导致直升机谐频信号的信噪比明显下降;直升 机高速运动导致的多普勒效应使声信号发生频移, 如图1所示短时谱图上第35s直升机经过测点上空 时谐频信号的频率出现整体下降;同时,在近场情况 下多径传播导致直达声与反射声之间的相位差变 化明显,信号在某些频率上相互抵消或增强,短时谱 图中产生多个波谷、波峰^[8]。这些波谷、波峰改变了 部分线谱信号的信噪比,使声信号特征频率表征的 连续性、稳定性受到干扰。

这些干扰,加上实际应用中风噪声等环境噪声 的影响,使得直升机飞过测点的过程中目标连续识 别鲁棒性受到影响,往往不能连续正确识别。



图 1 直升机飞行经过测点过程的噪声短时谱图 Fig. 1 Noise spectrogram of helicopter passing by the detector

2 复合深度神经网络模型

深度学习技术具有强大的学习能力,能够描述 输入数据与输出目标之间的高度非线性关系,已 在多类应用中取得了突破性的进展^[9]。深度学习 模拟人脑的分层工作机制,构建层次化的深度神经 网络,对输入数据逐层进行特征提取,得到分层的 特征表示。深度神经网络通过监督或无监督学习 优化数据的特征表征,有效地简化了特征提取的设 计。本文所用于优化直升机声信号特征提取的卷 积神经网络(Convolutional neural network, CNN) 和长短时记忆神经网络(Long short-term memory, LSTM)是深度学习中的经典模型,已被广泛应用 语音识别^[10]、声学场景分析^[11]等众多研究和应用领域。

2.1 总体框架

本文采用一种并行结合CNN和LSTM的复 合深度神经网络模型,如图2所示,利用CNN和 LSTM并行地从声信号短时谱图中进一步提取局 部时频信息和时序相关信息构造新的信号特征进 行分类。



图 2 复合深度神经网络模型 Fig. 2 Structure of combined deep neural network

2.2 卷积神经网络

卷积神经网络是由多层卷积层和池化层交替 连接组成的深度神经网络,具有局部连接、权值共 享和池化操作三大特点^[12]。卷积层从底层到高层 逐步抽取输入数据的抽象特征。池化层将相似特征 融合,大大减少了模型参数,同时具有二次提取特征 表示的功能,使特征对噪声和变形具有鲁棒性,保证 特征的平移不变性。

每个卷积层都包含多个特征图,特征图是由多 个神经元构成的二维矩阵,每一个神经元通过可训 练的卷积核与上一层特征图的局部区域连接,卷积 核是一个二维权值矩阵。特征图和卷积核维度可视 为频率 F 和时间 T。对于卷积层 l,输出特征图 X^l 表示为^[13]

$$\boldsymbol{X}^{l} = A\left(\boldsymbol{X}^{l-1} * \boldsymbol{W}^{l} + \boldsymbol{b}^{l}\right), \qquad (1)$$

其中,运算符号"*"表示卷积操作; A为激活函数; W^l为卷积核; b^l为加性偏置向量。

池化层通常跟随在卷积层之后,依据一定的下 采样规则对特征图进行下采样。对于池化层1,输出 第38卷第1期

特征图 X¹ 表示为^[13]

$$\boldsymbol{X}^{l} = S(\boldsymbol{X}^{l-1}), \qquad (2)$$

其中,S为下采样规则,本文采用最大池化的下采样规则。

线谱在短时谱图的相邻时频单元中通常表现 为局部最大值。最大池化操作选取特征的局部最大 值,可得到在该局部的线谱特征。为了更好地追踪 线谱的变化,结合目标声信号频谱特点,对卷积神 经网络的卷积、池化进行改进,使其只沿输入特征 的频率轴方向进行,各卷积核、池化核在时间轴上 的维度等于对应输入特征在时间轴上的维度,记为 CNN-1D,而通常对输入特征所使用的二维操作记 为CNN-2D。局部连接机制使卷积神经网络可以按 照参数所设定的尺度分析、挖掘声信号短时谱的局 部时频信息,进而表达声信号时频两个维度的内在 联系。

卷积神经网络模型参数依据声信号特点设置。 卷积核尺度大于线谱频率之间的间隔,以分析相邻 线谱之间频带范围内的线谱特征。池化核尺度小于 线谱频率之间的间隔,以避免池化核在频率轴上滑 动时可能混淆相邻线谱特征。

2.3 长短时记忆神经网络

长短时记忆神经网络是一种擅长处理序列数 据的深度神经网络^[14],能够从序列中学习到数据特 征和建模数据之间的长短时依赖性。其循环连接的 结构使得长短时记忆神经网络可对历史信息进行 记忆并应用于当前输出的计算中。区别于其他神经 网络,其同一隐藏层之间的节点是有连接的且节点 间参数共享,并且隐藏层的输入不仅包括当前时间 步上一隐藏层的输出还包括上一时间步同一隐藏 层的输出。同时,在隐藏层中引入由记忆单元、输入 门、输出门和遗忘门组成的存储块,存储块中的三 个门挖制信息在不同记忆单元之间的流动。本文采 用文献[15]所提出的LSTM存储块结构,如图3所 示,计算关系如下。

$$\begin{pmatrix} \boldsymbol{i}_{t}^{l} \\ \boldsymbol{f}_{t}^{l} \\ \boldsymbol{o}_{t}^{l} \\ \boldsymbol{z}_{t}^{l} \end{pmatrix} = \begin{pmatrix} \operatorname{sigm} \\ \operatorname{sigm} \\ \operatorname{sigm} \\ \operatorname{tanh} \end{pmatrix} \boldsymbol{W}^{l} \begin{pmatrix} \boldsymbol{h}_{t}^{l-1} \\ \boldsymbol{h}_{t-1}^{l} \end{pmatrix} + \boldsymbol{b}^{l}, \quad (3)$$

$$\boldsymbol{c}_{t}^{l} = \boldsymbol{f}_{t}^{l} \circ \boldsymbol{c}_{t-1}^{l} + \boldsymbol{i}_{t}^{l} \circ \boldsymbol{z}_{t}^{l}, \qquad (4)$$

$$\boldsymbol{h}_t^l = \boldsymbol{o}_t^l \circ \tanh(\boldsymbol{c}_t^l), \tag{5}$$

其中, h_t^l 表示隐藏层在时间步的输出;i、f、o、c分 别表示输入门、遗忘门、输出门和记忆单元;W、b分 别表示网络通过训练得到的权值矩阵和偏置;sigm、 tanh分别表示非线性Sigmoid、Tanh激活函数; \circ 表 示矩阵点乘。

输入门*i*^l_t、遗忘门*f*^l_t依赖*h*^{l-1}_t和*h*^l_{t-1}。这种依 赖性使得记忆单元*c*的更新和输入序列前后信息相 关,能够对记忆单元中的信息进行选择性的记忆和 遗忘,从而更有效地建模数据的长时依赖性。同时, 输出门*o*^l_t控制记忆单元输出与当前时间步相关的 信息。



图 3 LSTM 存储块结构 Fig. 3 Structure of LSTM cell

直升机飞行是一个连续过程,因此其声信号特 征具有时间上的连续性,这一特性有助于提升声目 标识别效果。特别是在直升机声信号特征变化时, 历史信息有助于目标探测系统快速适应改变,及时 捕捉目标声信号特征。因此可考虑利用长短时记忆 神经网络学习声信号特征的长短时依赖性,改善连 续识别过程中识别的正确率和鲁棒性。

3 直升机识别实验

3.1 实验数据

本文使用的数据是来自不同地点的多次外场 实验中采集的四种型号(分别以A、B、C、D表示)的 直升机声信号。根据直升机声信号特点,信号采样 率为3kHz,兼顾特征提取与计算量控制。实验数据 包含多种典型飞行状态,如不同高度的直线飞行和 沿不同半径的盘旋飞行以及少量的不同距离和高 将实验数据根据实验环境分为训练集和测试 集,训练集数据大多采集自训练场、靶场等场所,测 试集数据来自更接近实际使用条件的野外环境。以 直升机从声学探测距离之外飞向测点,经过测点后 继续飞出探测距离为止作为一个完整的飞行事件, 表1列出了训练集和测试集中各类飞行事件的分布 情况。训练集中各类目标的声信号时长约1h,大体 均衡;测试集中各类目标的声信号时长则各不相同。

通过交叉校验方法使用训练集数据训练神经 网络,测试集用于检验其识别性能和泛化能力。训 练集和测试集中的各类数据都是在多个时间、多个 地点,利用同一型号不同架次直升机分批次采集得 到的。

表1 飞行事件数 Tabel 1 Number of flight events

数据集	А	В	С	D
训练集	53	26	52	133
测试集	21	30	10	12
总计	74	56	62	145

本工作比较了3组不同类型的特征(表2):短时谱图、幅度谱和改进Mel频率倒谱系数(Modified MFCC, MMFCC)特征^[16]。其中MMFCC特征是在MFCC基础上针对车辆、飞行器等低频声目标远距离识别而改进的特征提取方法。

短时谱图:计算声信号每一秒的短时谱图作为 一个特征样本,帧间重叠50%。在计算短时谱时,做 512点快速傅里叶变换(重叠为50%)并取幅度值。 为了避免风噪声等干扰,去掉50 Hz以下的低频部 分,得到247×12的二维特征矩阵。

幅度谱:以256 ms为一帧,每帧数据使用 Welch 方法采用 256 点快速傅里叶变换计算归一化的平均 幅度谱,去掉 50 Hz 以下的低频部分,得到 124 维的 特征样本。计算频谱的能量、标准差、斜度和峭度等 统计量,将 124 维幅度谱和 4 个统计量组合为 128 维 特征向量。

MMFCC: 声信号降采样到1 kHz, 按照文 献 [16] 所述,以256 ms为一帧,提取25 维特征向量。

与传统MFCC相比,该特征主要依据目标声信号特 点改进了滤波器组的设计。

表2 特征样本数

 Table 2 Number of feature samples

数据集	特征类型	А	В	С	D
训练集	短时谱图	9761	10480	9809	10225
	幅度谱/MMFCC	38343	41037	38474	40540
测试集	短时谱图	2119	3063	2646	1832
	幅度谱/MMFCC	8370	12097	10378	7202

3.2 参数配置

复合深度神经网络的CNN模块由两层卷积 层和两层最大池化层组成。第一层卷积层卷积核 个数为64,第二层卷积层卷积核个数为128,使 用 ReLU 非线性激活函数。为进一步提升识别效 果,卷积层和池化层之间连接使用批归一化 (Batch normalization, BN)^[17]。

依据直升机声信号基频及谐频频率分布特点 和快速傅里叶变换定义的频率分辨率设置卷积核 和池化核尺寸。在CNN-2D中,卷积核维度均为 3×3,步长均为1×1,池化核维度均为2×2,步长 均为2×2。在CNN-1D中,卷积核在频率轴上维度 均为3,步长均为1,池化核在频率轴上维度均为2, 步长均为2。

复合深度神经网络的LSTM模块由两层隐藏 层组成,隐藏层有12个存储块,存储块维度是512, 在隐藏层之间使用层归一化(Layer normalization, LN)^[18]。全连接层神经元个数为1024,由CNN-1D 组成的复合深度神经网络记为CNN-1D+LSTM, 输出层为4个神经元的Softmax层。

复合深度神经网络选用 Nesterov Momentum 优化算法^[19],动量因子为0.9。前10次迭代初始学 习率为0.01,之后每次迭代学习率递减10%,连续3 次迭代交叉校验的结果无进一步改善则停止迭代 训练。

3.3 识别结果分析

为了验证复合深度神经网络的有效性,本文将 其与CNN、LSTM两种深度神经网络和以支持向量 机(Support vector machine, SVM)为代表的浅层 神经网络,使用三种典型特征通过分类实验进行 识别性能比较。深度神经网络使用短时谱图特征; SVM分类器使用幅度谱特征及针对目标远距离探 测设计的MMFCC特征。其中,使用幅度谱特征的 SVM记为SVM1,使用幅度谱和MMFCC组合特征 的SVM记为SVM2。

表3是CNN、LSTM两种深度神经网络与以 SVM为代表的浅层神经网络的识别结果。深度神 经网络的总体识别结果均好于SVM的总体识别结 果,主要原因是目标声信号频域信息及其随时间 的变化规律是目标声信号特性的重要体现,深度神 经网络采用的二维短时谱图包含了连续数帧数据 的连续时频变化信息,利用其多层网络结构的信息 抽象表征能力,能够在学习中逐步优化目标声信号 特征表征提高目标识别性能。而SVM由于受限于 浅层神经网络的信息处理能力,只能采用幅度谱、 MMFCC等低维特征,这些特征局限于信号的短时 频域信息,不能扩展到连续数帧数据来获取声信号 的时频相关信息。此外, SVM 识别结果中各类目标 识别正确率之间的不均衡程度明显大于深度神经 网络的识别结果,在实际应用中这种不均衡将导致 识别系统对某类目标存在严重的性能短板。

表3 SVM和深度神经网络的识别结果

Table 3Recognition results of SVM,LSTM and CNN

	分类器	特征类型	А	В	С	D	总体
	SVM1	幅度谱	75.72%	86.94%	62.28%	93.77%	79.04%
	SVM2	幅度谱 + MMFCC	76.58%	90.48%	62.15%	97.24%	80.97%
	LSTM	短时谱图	73.71%	95.92%	68.10%	85.75%	81.50%
(CNN-2D	短时谱图	88.44%	97.98%	78.53%	89.68%	88.99%

表4比较了CNN-1D、CNN-2D和复合深度神 经网络的识别结果。CNN-1D较CNN-2D提高了声 目标识别的总体正确率,各类均有不同程度的提高。 这是因为当线谱发生频移时,沿时间轴的一维操作 筛选掉短时谱图中每个频带上的局部较小值,能更 好地选取每个频带上局部最大值,有效地追踪到线 谱的频率变化。CNN-1D+LSTM复合深度神经网 络的整体识别正确率最高。可见LSTM网络所侧重 的直升机信号随时间变化的特征信息,可辅助CNN 优化目标声信号频域信息的表征,从而进一步提高 识别性能。图4是以一个典型直升机声信号对比复 合深度神经网络和CNN-1D的连续识别结果,可见 复合深度神经网络能有效减少信号频谱的短时变 化引起的错误判决。

表4 三种深度神经网络的识别结果

Table 4 Recognition results of the threedeep neural networks

分类器	А	В	С	D	总体
CNN-2D	88.44%	97.98%	78.53%	89.68%	88.99%
CNN-1D	91.69%	98.17%	79.29%	89.79%	89.99%
CNN-1D +LSTM	91.84%	97.81%	80.23%	96.12%	91.37%



图 4 CNN-1D+LSTM 和 CNN-1D 的连续识别结 果对比

Fig. 4 Compare of continuous recognition results of CNN-1D+LSTM and CNN-1D

以直升机从远处直线飞入探测范围,经过测点 然后直线飞离探测范围为一个飞行事件,计算多个 飞行事件中各时刻的平均识别正确率,得到平均识 别正确率随时间的变化曲线。无论目标运动速度如 何,在直线飞行事件中目标与测点之间的距离与时间成正比。因此该曲线能够在统计意义上展示直升 机飞行过程中声信号的连续识别性能。

以47个完整的直升机直线飞行事件为样本,统 计CNN-1D+LSTM和SVM2的平均识别正确率随 时间变化曲线。将直升机经过测点,信号短时能量 最大的时刻作为时间轴原点,绘制曲线如图5所示。 总体上,直升机在测点附近时,由于信噪比较好,平 均识别正确率总体相对较高。随着目标与测点之间 距离增大,信噪比变差,平均识别正确率随之下降, 直到无法有效探测。



图 5 飞行事件的平均识别正确率随时间变化曲线 Fig. 5 Average accuracy rate in a target event changing over time

直升机经过测点上方时,目标特征线谱不但由 于多普勒效应产生频移,并且往往被宽带气动噪声 所淹没,导致目标最接近测点时反而容易产生误判。 如SVM2在测点上方附近平均识别正确率有较大 波动。这就是前文所述传统分类方法对目标信号连 续识别的鲁棒性较差的问题。如图5所示,本文所提 方法有效改善了完整飞行事件中目标识别正确率 和正确识别的连续性,其性能明显优于SVM方法。

4 结论

本文提出了一种基于复合深度神经网络的直 升机声目标特征提取和分类识别框架,该框架使用 CNN和LSTM两个并行的深度神经网络模块提取 一段时间内声信号频谱特征和频谱随时间变化特 征,弥补了传统声目标识别方法对信号时间历程信 息利用不足的缺陷。同时结合声信号处理方法,改 进了卷积神经网络卷积层与池化层的计算方式,以 更好地适应声信号特征频率的变化。真实外场实验 数据测试结果表明,与传统方法相比,该方法明显提 升了对直升机完整飞行事件连续识别的鲁棒性,同 时提高了整体识别正确率。

参考文献

- Nielsen R O. Acoustic detection of low flying aircraft[C]. IEEE International Conference on Technologies for Homeland Security, 2009: 101–106.
- [2] Sinelnikov Y, Sutin A, Sedunov A, et al. Automated acoustic detection and classification of small aircraft[J]. The Journal of the Acoustical Society of America, 2013, 134(5): 4076.
- [3] 李世智. 基于基频检测和谐波识别的直升机探测技术 [J]. 水 雷战与舰船防护, 2017, 25(2): 5-9.
 Li Shizhi. Detection technology of helicopters based on

fundamental frequency detection and harmonious wave recognition[J]. Mine Warfare & Ship Self-Defence, 2017, 25(2): 5–9.

- [4] Elshafei M, Akhtar S, Ahmed M S. Parametric models for helicopter identification using ANN[J]. IEEE Transactions on Aerospace and Electronic Systems, 2000, 36(4): 1242–1252.
- [5] Chen Y, Xu X. The research of underwater target recognition method based on deep learning[C]. IEEE International Conference on Signal Processing, Communications and Computing, 2017: 1–5.
- [6] Cao X, Zhang X, Yu Y, et al. Deep learning-based recognition of underwater target[C]. IEEE International Conference on Digital Signal Processing, 2016: 89–93.
- [7] 张强, 王华明, 胡章伟. 直升机噪声信号的小波分析 [J]. 声学 学报, 2001, 26(5): 450-454.
 Zhang Qiang, Wang Huaming, Hu Zhangwei. Analysis for helicopter noise signal based on wavelet transform[J]. Acta Acustica, 2001, 26(5): 450-454.
- [8] Tong J, Xie W, Hu Y H, et al. Estimation of low-altitude moving target trajectory using single acoustic array[J]. The Journal of the Acoustical Society of America, 2016, 139(4): 1848–1858.
- [9] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436.
- [10] Yu D, Li J. Recent progresses in deep learning based acoustic models[J]. IEEE/CAA Journal of Automatica Sinica, 2017, 4(3): 396–409.
- [11] Zhang H, McLoughlin I, Song Y. Robust sound event recognition using convolutional neural networks[C]. IEEE International Conference on Acoustics, Speech and Signal Processing, 2015: 559–563.
- [12] Lecun Y, Bengio Y. Convolutional networks for images, speech, and time series[M]//The handbook of brain theory and neural networks. Cambridge: The MIT Press, 1998: 255–258.

- [13] Bouvrie J. Notes on convolutional neural networks[C]. Neural Nets, 2006.
- [14] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735–1780.
- [15] Gers F, Schmidhuber J, Cummins F. Learning to forget: continual prediction with LSTM[J]. Neural Computation, 2000, 12(10): 2451–2471.
- [16] Bao M, Guan L, Li X D, et al. Power spectrum sub-band analysis with weighting entropy maximum and its optimization algorithm for feature extraction in pattern classification[J]. Pattern Recognition & Artificial Intelligence,

2008, 21(1): 42-48.

- [17] Salimans T, Goodfellow I, Zaremba W, et al. Improved techniques for training gans[C]. Advances in Neural Information Processing Systems, 2016: 2234–2242.
- [18] Klambauer G, Unterthiner T, Mayr A, et al. Selfnormalizing neural networks[C]. Advances in Neural Information Processing Systems, 2017: 971–980.
- [19] Sutskever I, Martens J, Dahl G, et al. On the importance of initialization and momentum in deep learning[C]. International Conference on Machine Learning, 2013: 1139–1147.

◇ 声学新闻和动态 ◇

中国声学学会第九次全国会员代表大会在北京召开

中国声学学会第九次全国会员代表大会于2018年11 月10日在北京隆重召开。中国声学学会第八届理事会理事 长王小民等学会负责人、常务理事、理事和来自高等院校、科 研院所、企业的近四百位会员代表参加会议。杨士莪院士、 张淑仪院士、马远良院士、何琳院士出席本次会议。中国声 学学会第八届理事会副理事长兼秘书长张春华主持会议。

大会开始,张春华副理事长宣读了中国科协《关于中国 声学学会第九届理事会换届方案的批复》和《关于中国声学 学会召开第九次会员代表大会的批复》。

哈尔滨工程大学杨士莪院士为开幕式致辞。他介绍了 中国声学学会的发展历程,并号召广大声学科技工作者积极 加入中国声学学会这个全国性、学术性、公益性的社团组织, 通过参加形式丰富的学术交流活动,及时了解中国声学学科 的最新进展。同时,他也勉励中国声学学会不断提高自身实 力、扩大影响力和知名度,为会员提供更多服务,为国家发展 贡献才智和力量。

大会审议通过了第九次会员代表大会及九届一次理事 会主席团组成。学会第八届理事长王小民当选为主席团主 席。王小民理事长代表第八届理事会向大会做了工作报告, 报告全面总结了过去四年学会在学术交流、科学普及、期刊 编辑、学科发展、表彰举荐、服务创新型国家和社会建设、学 会党建等方面工作中取得的成绩,总结了相关经验并认真分 析了存在的问题和不足,同时对新一届理事会提出了建议。 大会审议通过了第八届理事会工作报告,与会代表认为报告 内容客观详实、深刻全面。

会议还审议通过了第八届理事会财务工作报告、《中国 声学学会章程(修订草案)》、中国声学学会个人会员及单位 会员会费标准、第九届理事会选举工作总监票人、监票人、计 票人名单以及第九届理事会、监事会选举办法。学会副理事 长张春华报告了第九届理事会理事候选人产生情况和监事 会监事候选人产生情况。

全体代表通过无记名投票方式选举产生了120名中国

声学学会第九届理事会理事和5名监事会监事。

随后召开了中国声学学会第九届第一次理事会,学会第 八届理事长王小民作为主席团主席主持了本次会议。会议 选举产生了40名常务理事和学会负责人。张春华研究员当 选为理事长,李琪教授、孙超教授、他得安教授、谢菠荪教授、 章东教授、李风华研究员当选为副理事长。

经新当选的理事长张春华提议,第九届理事会第一次会 议决定聘任张守著研究员为秘书长,刘晓峻教授、蒋德军高 工、郑海荣研究员为副秘书长。

第八届理事长王小民代表第八届理事会对全体会员给 予第八届理事会、常务理事会和学会负责人工作的大力支持 表示了衷心感谢,对学会第九届新当选的理事、常务理事和 学会负责人表示了由衷的祝贺,对学会未来的发展寄予了殷 切的希望。

第九届理事长张春华代表第九届理事会对各位会员代 表的信任和支持表示感谢,对王小民理事长和他领导的第八 届理事会做出的富有成效的工作给予了高度评价和崇高敬意。

2018年是承前启后的一年,中国声学学会第八届理事 会认真贯彻落实中央和上级领导部门对学会工作的指示精 神,认真执行学会工作"法人治理、民主办会"的原则,团结 带领广大会员,推动学会各项工作有序开展,将学会工作逐 步纳入到"规范、民主,创新发展"的轨道,圆满完成了四年 的工作。在此基础上,中国声学学会第九届理事会将进一步 扎实推进"三型"(开放型、枢纽型、平台型)学会组织建设, 牢固树立"四服务"意识,加强为科技工作者服务、为创新驱 动发展服务、为提高全民科学素质服务、为党和政府科学决 策服务,真正搭建起党和政府团结联系广大科技工作者的桥 梁,把中国声学学会建设成具有影响力和充满活力的现代学 术团体。

(中国声学学会 耿祎晗)