

基于 DNT 模型的试飞遥测噪声分析研究

刘天畅

(中国商飞上海飞机试飞工程有限公司, 上海 201323)

摘要:针对新型号试验试飞转场频繁、构型差异大且重大改装密集情况下试飞噪声定位困难、分析周期长、排故试飞架次多的问题,对试飞噪声快速识别方法进行了研究;构建了基于 DNT 的试飞噪声识别系统,通过对已分析噪声数据与分析结果建立映射关系,设计数据升维模块并采用神经网络进行拟合训练,形成对噪声数据敏感的网络模型;对 5 类噪声进行多次识别测试, DNT 网络模型识别平均精度达到 83.2%,查全率达到 95%;构建的网络模型优化评估策略可根据不同外场试飞任务输入相应网络模型参数,获得网络性能评估结果,实现了试飞噪声的快速识别与分类,为缩短试飞噪声分析周期、减少排故试飞架次提供了技术支撑。

关键词:数据升维;神经网络;噪声分析;试飞测试;模型评估

Analysis of Flight Test Telemetry Noise Based on DNT Model

LIU Tianchang

(COMAC Shanghai Aircraft Flight Test Co., Ltd., Shanghai 201323, China)

Abstract: To address the problems of difficult noise localization, long analysis cycles, and increased troubleshooting flight sorties in flight test scenarios with frequent aircraft transfers, significant configuration differences, and intensive major modifications, research on a method for rapidly identifying flight test noise is conducted. Build a flight test noise identification system based on DNT model, establish the relationship between the analyzed noise data and the analysis results, design a data dimension-enhancement module, and employ neural network fitting training to form a network model sensitive to noise data. After multiple identification tests on 5 types of noise, the results show that the DNT network model achieves an average recognition accuracy of 83.2% and a recall rate of 95%. The optimization evaluation strategy for the constructed network model can input the parameters for corresponding network models according to different field flight tests and obtain the evaluation results of network performance, which rapidly identifies and classifies flight test noise, thus providing technical support for shortening the noise analysis cycle during flight tests and reducing troubleshooting flight sorties.

Keywords: data dimension enhancement; neural network; noise analysis; flight test; model evaluation

0 引言

飞行器需要在执行不同试飞任务单过程中按照不同试验点调整构型来完成试飞试验。试飞噪声数据一方面应按照 CAAC 36 部和 FAA 发布的相关噪声适航文件为新型号飞机取得型号合格证的依据;另一方面作为重要的试验飞行状态指标,在飞机试飞试验监控过程中起到不可或缺的作用。试验过程中的飞行器是在试飞任务大纲约束下具有能控性、能观性的系统,而对其输入变量的响应分析则要求具有较高的及时性^[1],民机试飞中由于新系统、新结构、新设计的使用,使得对全机噪声的分析尤为重要^[2]。

常见的飞机噪声有:APU(辅助动力装置)噪声,

一般在停机坪上表现明显;发动机噪声,一般在滑行、起飞阶段表现明显;气动噪声,一般在飞行过程中表现明显^[3]。试飞试验中常见噪声包括构型噪声、局部异响、空腔缝隙异响、环控系统噪声等高低频、宽窄带特性噪声^[4]。其中构型噪声是根据不同试验点调整飞机构型对气流产生不同影响所表现的噪声,而湍流边界层噪声、发动机噪声、和环控系统噪声则是影响舱内噪声量值的最主要因素^[5]。从频域角度分析,湍流边界层噪声在频谱上表现为宽频激励特征;发动机噪声主要包含高频的喷流噪声以及低频的风扇噪声、核心机噪声;环控系统噪声则主要集中在中低频段^[6]。此外系统工作时也会产生响应噪声,如空调出风口啸叫、刹车过程中刹车片与机轮摩擦时产生的啸叫等。从飞行状态角度,飞机从初

收稿日期:2025-05-20; 修回日期:2025-07-17。

作者简介:刘天畅(1992-),男,硕士,工程师。

引用格式:刘天畅. 基于 DNT 模型的试飞遥测噪声分析研究[J]. 计算机测量与控制, 2025, 33(11): 292-298, 335.

始状态到平飞的过程中,飞机速度不断增大,噪声频谱曲线也随之变得平滑,噪声能量主要集中在 8 000 Hz 以下的低频部分,其中发动机噪声频率集中在 300 至 500 Hz 的窄带区域内,气动噪声是宽频噪声,在飞机平飞阶段,FFT 曲线较为平滑,噪声频谱分布在 2 000 至 4 000 Hz 的中高频带宽内。在直升机中,噪声源包括主旋翼和尾旋翼、推进系统、传动系统等^[7]。其中主旋翼的噪声对直升机的整体噪声水平影响尤为明显^[8]。由于主旋翼叶片与空气的相互作用,在运行过程中会产生相当程度的空气动力学噪声,占直升机噪声的大部分,转子空气动力噪声根据频域特性可分为音调噪声和宽带噪声^[9]。音调噪声包括厚度噪声、负载噪声、叶片一涡旋相互作用(BVI)噪声和高速脉冲(HSI)噪声,主要由叶片通过频率(BPF)及其高次谐波的离散音调组成。宽带噪声又称涡流噪声,主要是由于旋翼叶片在扰动尾流涡旋中运行而产生的随机升力脉动引起的,特别是叶尖涡流引起的动态叶片载荷引起的高频噪声^[10]。

目前噪声分析需要在试飞结束后,由工程师进行数据拷贝、数据介质移交、数据解析处理及分发,随后对数据进行分析处理,比对历史数据,进行分析排故^[11],定位问题,分析成因,随后再根据问题影响级别,评估情况,重新制定排故或结合排故试飞计划,结合试验大纲进行排故试飞科目^[12]。而在排故试飞过程中,往往由于不同的环境条件,比如温度、气压、发动机工况等综合因素,使得排故过程中变量难以与之前架次完全一致,问题复现周期长,措施验证耗时久。噪声测量的研究主要集中在噪声的声源定位^[13-15]和强干扰下的噪声分析^[16]。在过去几十年中开发了许多技术,包括 DEMON(噪声包络调制检测)^[17]、频谱峰度分析^[17-18]、循环稳态分析等^[19-20]。

本研究提出 DNT 神经网络模型,即 End To End-Preset Models(端到端的权值预置网络),通过对模拟试飞数据中的异常噪声数据进行标注,建立训练数据集,采用神经网络分析异常噪声数据的特征,拟合异常噪声故障原因,搭建噪声分析系统,最后对模型的精度和查全率进行评估。

1 模型与方法

针对目前试飞试验中噪声识别周期长、及时性较低等现状,基于现有数据和机器学习研究方法^[21-22],提出 DNT 神经网络。DNT 是权值预置的端到端神经网络模型,探索使用机器学习算法在噪声试飞数据分析上的应用可行性,在多元时间序列聚类与分析上提高了噪声分析的及时性、准确性和高效性^[23]。

为了提高声学目标的识别性能,提出一种新型的深度学习框架来提取特征并识别试验机噪声,框架采用卷

积神经网络对试验机声学特性的表示进行优化,实现其类型识别。神经网络提取的优化特征旨在克服经典人工特征中试验机噪声缺乏保留内在特征的问题,与传统的声学试验机噪声识别方法相比,神经网络可以有效提高识别准确率,并且预处理方法可有效提高直升机信号受到干扰时的识别率。

卷积神经网络是深度学习中的经典模型,使网络能够学习输入特征和输出目标之间的高度非线性关系。已成功应用于众多声学领域的研究和应用,如语音识别、语音分离等。

如图 1 所示试飞噪声数据,输入信号为 $x(t)$,常用的方式包括频谱分析、时域分析、统计能量分析、声强分析、模态分析、小波分析、有限元分析等。




图 1 输入噪声信号时域图

飞行器噪声分析技术体系涵盖 7 种核心方法,各具独特优势与适用场景。频谱分析作为基础技术,通过傅里叶变换将复杂噪声信号分解为多个简谐分量,能够精确识别噪声的主要频率成分,为噪声源定位与控制策略制定提供理论依据。该方法在稳态噪声分析中表现优异,特别适用于发动机叶片通过频率、齿轮啮合频率等周期性噪声的识别与分析。时域分析直接考察噪声信号随时间的变化规律,能够捕捉噪声的瞬态特性,如突发性、周期性等动态行为。结合自适应鲁棒矩阵卡尔曼滤波等先进算法,该方法在处理弹性机翼振动分析和飞行噪声数据对齐方面具有显著优势,特别适用于非稳态飞行条件下的噪声监测与评估。统计能量分析(SEA)基于能量传递理论,专门针对中高频范围内的复杂结构声学系统。该方法将系统视为多个弱耦合子系统,通过统计方法预测振动能量在不同部件间的分布与传播路径。SEA 既可用作理论分析工具,也可用于实验验证,在航空工业中特别适用于评估结构噪声和空气动力学噪声在飞机不同部件间的传播与衰减特性。声强测量法通过量化单位面积上的声能流密度来评估噪声源强度。基于 RANS 求解器和 Cantrell-Hart 方程的数值计算方法,

能够处理跨音速条件下的非线性声传播问题。该方法计算效率高,易于快速实现,在噪声源定位和噪声控制措施效果评估方面具有突出优势,特别适用于进气道噪声和机体不规则结构产生的噪声分析。模态分析通过识别系统的固有频率、阻尼比和模态形状等参数,深入理解飞机结构对噪声的响应特性。结合线性化卡尔曼滤波和松弛迭代法,该方法能够处理湍流环境下的随机过程噪声和测量噪声,为高性能飞机控制系统设计提供精确的空气动力学预测,在飞行测试数据的系统识别和空气动力学模型更新中发挥重要作用。小波分析作为傅里叶分析的拓展,克服了传统频域分析难以反映局部信息特征的局限性。通过多尺度时频局部化分析,实现高频处时间细分、低频处频率细分的自适应处理,特别适用于非平稳、瞬变噪声信号的精细化分析。能量有限元分析作为新兴的中高频噪声控制理论,直接基于有限元模型预测结构激励与声场激励下的噪声响应。该方法具有建模简化、计算精确、适用范围广等显著优势,无需复杂的子系统建模过程,避免了模态密度判断和结构阻抗计算的繁琐步骤,显著降低了工程应用门槛,在中高频结构噪声预测与控制方面展现出强大的理论价值和工程实用性。

在飞行试验中,以上方式均需要在试飞完成后人工将数据录入系统,根据现有知识对大量试飞数据进行后期分析,过程耗时长,工作量大,对单个噪声问题需要进行全量因素分析,效率较低,实时性低,对于试飞试验中一些偶发性、难复现的问题响应时间较长。

1.1 分析模型设计

分析网络采用端到端网络模型设计思路。噪声分析属于音频分析领域,传统的音频识别系统由多个模块构成,包括声学模型、发音源集、语言模型等等,其中声学模型和语言模型等需要进行单独训练,各个模型往往都有与之匹配的目标函数,如声学模型的训练目标是最大化识别结果,而语言模型的训练目标是最小化困惑度。由于各个模型在训练时权重不互联,使得各自的损失函数和梯度下降方式难以互相取长补短,同时训练目标函数又与系统整体的性能指标存在一定的偏差,造成最后训练出的有多个模型构成的网络往往难以达到最优性能。端到端的网络采用黑箱思想,将传统音频分析的多个模块全部混合训练,不再关注单个模块训练结果的好坏,也不再人为关注模型的相互影响机理,而是将原始数据作为输入,将识别结果作为输出,不再从原始数据中单独提取特征,避免了由于数据维度过高产生的维度灾难,也避免了在缺少经验的情况下设计特征不合理的情况,模型非常简洁,但灵活性稍差,适用于特定问题。

模型设计引入残差连接神经网络和特征金字塔思

想,由数据输入层,激活层,卷积层,残差连接层,多尺度输出层构成。主干网不再单独构建池化层,而使用卷积层调整步长的方式进行降采样,生成不同尺度的特征,同时取消全连接层并大量使用残差进行跳层连接,增加了多尺度特征的传递路径。使用分析工具对网络结构进行可视化,如图 2,其中多次的卷积层、降采样层和残差连接层均已折叠。




图 2 DNT 网络结构

网络中损失函数 J_θ 由检测区域误差损失 J_{θ_1} 、置信度误差损失 J_{θ_2} 、类别误差损失共同构成 J_{θ_3} , 如式 (1) 所示:

$$J_\theta = J_{\theta_1} + J_{\theta_2} + J_{\theta_3} \quad (1)$$

检测区域的误差损失 J_{θ_1} , 指在每次对噪声数据识别后,在这一小段噪声信号中,需要在信号可视化中对识别到的噪声升维数据进行标识,为现场监控人员提供直观的噪声识别效果,如式 (2) 所示:

$$J_{\theta_1} = \lambda_1 \sum_{i=0} \sum_{j=0} k_1 [(x_i - x'_i)^2 + (y_i - y'_i)^2 + (w_i - w'_i)^2 + (h_i - h'_i)^2] \quad (2)$$

式中, λ_1 表示该项损失系数, k_1 对区域中是否存在待识别的噪声进行标记, x_i 与 y_i 标记了识别主体, w_i 与 h_i 对区间的范围进行了约束。

损失函数第二项 J_{θ_2} 是置信度误差损失。对于回归问题常用的损失函数包括 L1 Loss、L2 Loss、MSE、MAE、Huber Loss、SAME 等。为了将训练集上的数

据在整个数据区间进行拟合，使用回归问题的损失函数内部往往都会设计真实值与预测值差值的平方项来对数据区间的全部范围进行拟合。由于多分类往往可以降为多个二分类问题进行求解，区间仅在 (0, 1) 范围内进行拟合，其损失函数内部往往会具有幂函数特性的部分。常用的回归问题损失函数包括 Zero-One Loss、Logistic Loss、Hinge Loss、Exponential Loss、Huber Loss 等。研究选用 Logistics 作为分类的损失函数，如式 (3) 所示：

$$J_{\theta_2} = \lambda_2 \sum_{i=0} \sum_{j=0} k_{\theta_2} \sum_{c \in \text{classes}} p_i(c) \log(p'_i(c)) \quad (3)$$

λ_2 表示置信度误差损失系数， k_{θ_2} 表示区域内是否存在待检测的噪声， $p_i(c)$ 与 $p'_i(c)$ 分别表示存在噪声的数据区域内已经识别到的噪声真实值与预测值的置信度。

损失函数的第三项 J_{θ_3} 是对噪声类别识别带来的误差损失，如式 (4) 所示：

$$J_{\theta_3} = \lambda_3 \sum_{i=0} \sum_{j=0} k_{\theta_3} (c_i - c'_j)^2 + \lambda'_3 \sum_{i=0} \sum_{j=0} k'_{\theta_3} (c_i - c'_j)^2 \quad (4)$$

其中： λ_3 和 λ'_3 分别是类别损失权重， k_{θ_3} 和 k'_{θ_3} 分别表示识别区域中是否存在待测噪声的真假， c_i 和 c'_i 表示标记中的噪声类别与检测出的噪声类别。

1.2 特征映射信息数据升维

对原始噪声的一维数据 (1×N) 与初始化的升维矩阵 (N×M) 做矩阵乘法，构建二维数据，形成分析矩，升维矩阵为随机初始化的非零矩阵，使得原始噪声的一维数据中包含的噪声特征，特别是故障噪声信息可以无丢失的映射到分析矩上，对于二维的分析矩，采用数据平滑滤波的方式将离散的噪声信息点转化为连续的二维数据，使得其在高维信息空间可微，使得采用梯度下降法提取特征信息的方式可行。

采用 STFT (短时傅里叶变换) 方法在时域上对信号进行分段加窗对每段数据进行傅里叶变换，得到随时间变化的频谱信息，可实现对非平稳信号的分析。STFT 将原始信号按相邻或重叠的窗口进行分段，其中帧间距离决定了 STFT 在时间轴上的采样密度；为控制每段数据在边缘处对频谱分析的影响，需要乘以不同的窗口函数，如汉明窗、汉宁窗等，不同的窗口函数和长度会影响“时间分辨率”与“频率分辨率”的平衡；对每段加窗后的信号执行快速傅里叶变换得到对应的频谱，将所有帧的频谱按时间顺序排列即可得到信号随时间变化的频率分布。STFT 中， n 对应每个时窗中心所在位置， ω 为角频率， $w[m-n]$ 是窗口函数在第 n 帧的截取，如式 (5) 所示：

$$X(n, \omega) = \sum_{m=-\infty}^{\infty} x[m]w[m-n]e^{-j\omega m} \quad (5)$$

考虑到噪声与多个飞行参数有关，如起飞时的发动机噪声、不同仰角的气动噪声、不同构型的襟缝翼和扰流板产生的气动噪声，对于试飞科目的关键试验点，结合多个飞参数据可以在对试飞噪声的时域图、频域图分析时提高准确率。将时频分析的数据帧结合飞参，构建拓展矩阵，再通过神经网络方法对扩展矩阵进行分析可实现多维数据的组合分析，其构建过程如图 3 所示。




图 3 时序数据升维

在噪声时域图中，构建扩展矩阵与融合矩阵实现了时域图的图像信息与重要飞行参数的单值信息的融合，降低了多维数据网络分析的复杂度，同时提高了分析的准确率。

1.3 迁移学习

迁移学习是一种机器学习方法，就是把为任务 A 开发的模型作为初始点，重新使用在为任务 B 开发模型的过程中。权值预置是权值初始方式的一种，也是神经网络中重要的组成部分，为了防止层激活输出在深度神经网络的传递过程中爆炸或消失，神经网络的训练中需要对权值进行初始化。当传播过程中的梯度太小或者太大时，信息均无法有利地向后流动，造成网络难以收敛甚至发散。

迁移学习将已在特定任务或领域上学得的知识（如模型参数、特征表示等）迁移到新的相关任务或领域中，以减少对新任务训练数据的需求、缩短模型训练时间并提升新任务的性能。在深度学习领域尤其常见，常用于处理样本量不足或训练成本较高的场景。多数迁移学习方法借助“预训练—微调”或“特征提取”的理念，将原先在大型数据集上预训练好的模型或特征应用到新任务中。特征提取使用在源领域预训练好的网络，截取其前面若干层（如卷积层）提取特征，将其作为新任务的数据表示形式，然后只训练最后几层或新加的一层分类器完成目标任务。微调在特征提取的基础上，不仅修改最后几层，还对整个或部分网络进行微调，通过在目标数据集上进一步训练，可以适配新任务的特征分布。

由于在不同地点、气象、温度、速度等基地开展飞行测试任务中飞行噪声的基线水平不一致，每次重新训练会带来数据样本过小，训练周期过长等一系列问题，

采用迁移学习方式在保证准确率的前提下扩展了模型的适用面。采用最大平均差异方式衡量源域分布与目标域分布的差异,该方法通过计算源域与目标域的距离、散度对差异进行度量,如式(6)所示:

$$\text{MMD}^2(D_S, D_T) = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \phi(x_i^S) - \frac{1}{n_t} \sum_{j=1}^{n_t} \phi(x_j^T) \right\|_H^2 \quad (6)$$

其中: x_i^S 为源域样本, x_j^T 为目标域样本, n_s 、 n_t 分别为源域、目标域样本数, $\phi(\sim)$ 表示将样本映射到再生核希尔伯特空间中的映射, $\|\cdot\|_H^2$ 为该空间的二范数。同时在损失函数中增加一项 MMD 正则项,相当于鼓励源域与目标域特征分布更一致,减小域间差异,如式(7)所示。其中 λ 是平衡任务损失和分布对齐的系数:

$$\min_{\Theta} [\mathcal{L}_{\text{task}}(\Theta) + \lambda \cdot \text{MMD}^2(D_S, D_T)] \quad (7)$$

研究采用权值预置的方式构建网络,不再从零开始训练一个全新的模型,节省了硬件资源和训练时间,权值预置模块使用与音频处理类似的大型网络权值作为初始化权值构建基线,训练过程中对这些初始权值进行学习迭代,使得网络可以较为快速的收敛并取得较好的识别效果,同时采用权值预置模块,选择合适的预训练权值作为基线,对不同基地、不同构型的噪声背景下进行预置更新,提高模型鲁棒性。

2 结果与讨论

2.1 噪声升维数据标注可视化

采用 32 浮点位深度的单声道信号作为噪声模拟信号源,采样率 88 000 Hz,对获得的模拟噪声数据进行可视化,如图 4 所示。




图 4 噪声升维数据与标注

从图 4 中看出,在时域中存在多类噪声相互叠加干扰的情况,不同类别噪声的时域图相似度高,数据流速快,人工快速识别困难。使用矩阵分析工具对数据进行升维并标注。标注类别包括 DSC、DHY、ADY、AGS、DZY 共计 5 类,分别表示不同类型的已识别的噪声信号。

2.2 噪声识别结果

在公开数据集上完成训练后,使用该模型权重对新科目的噪声进行分析,模型实现了 95% 的查全率,同时最低的识别精度为 59%,意味着模型还具有更强的背景环境扰动下的识别能力。模型最高识别精度为 99%,表明模型拟合性能极强,平均识别精度为 83.2%,其识别后的标注信息如图 5 所示。




图 5 模型识别结果

2.3 性能提升与优化

2.3.1 批大小设置优化

批大小在训练速度、模型泛化能力、收敛稳定性等方面扮演重要角色。批大小设置小的优势在于梯度估计噪声大,类似模拟退火效应,有助于逃离局部极小值,同时每个 step 更新方向更具随机性,可能发现更优解;其劣势体现在单步更新方差大,收敛路径震荡,需降低学习率或增加迭代次数,硬件并行利用率低。采用大的批大小可以使得梯度估计更接近真实数据分布,更适合分布式训练,但容易陷入局部最优而非全局最优导致泛化能力下降,同时较大的学习率容易引发反向传播数值不稳定。不同的批大小设置中所对应的查全率、查准率、迭代数、单次训练时间如图 6 所示。

可以看出对于试飞噪声的样本情况,不同批大小带来的召回率、准确率、平均精确率并没有表现出明确的正相关,综合考虑训练时长和平均精确率,批大小设置在 20~36 之间可以提升整体模型性能。

2.3.2 网络激活优化

激活函数是神经网络中非线性变换的核心所在,激活函数在输入与输出之间引入非线性映射,使得神经网络能够学习并表示更复杂的函数关系。在没有激活函数的情况下,神经网络会退化成简单的线性模型,其表达能力受到严重限制。不同的激活函数所对应的查全率、查准率、迭代数、单次训练时间如表 1 所示。




图 6 不同批大小训练结果

从表 1 中可以看出选用 Mish 及其改型的激活函数可以获得更好的平均精确率。从学习效率和评估精度的角度分析，这些激活函数及其改型思想均是在原函数第一象限线性正相关，同时尽量抛弃第二象限及负区间的信息，导函数则是在第一象限快速趋向于 1，而在第二象限趋向于 0。但随着对负区间信息研究的深入，这些被抛弃的信息往往也在网络和梯度传递中起到一定作用，所以目前的改进方式是希望激活函数不全部丢弃负区间信息，即在第二象限靠近原点出设计些许波动，将部分负区间信息引入网络进行训练，由此也带来了计算量的增加。对于试飞噪声的样本情况，Mish 相较于 ReLU 等分段函数

表 1 不同激活函数的性能

激活函数	<i>P</i>	<i>R</i>	<i>mAP</i> 50	<i>mAP</i> 50—95	epochs	time_total(* 10h)
SiLU	0.937	0.969	0.976	0.877	600	0.535
Hardswish	0.931	0.959	0.978	0.855	556	0.472
Mish	0.95	0.965	0.982	0.89	757	0.635
Identity	0.407	0.188	0.188	0.0764	176	0.168
Sigmoid	0.83	0.526	0.724	0.488	649	0.558
ReLU	0.936	0.955	0.974	0.85	712	0.593
LeakyReLU	0.931	0.976	0.977	0.897	1608	1.371
ELU	0.928	0.966	0.974	0.833	696	0.589
Hardshrink	0.585	0.494	0.572	0.278	785	0.665
Hardsigmoid	0.729	0.323	0.453	0.258	652	0.551
Hardtanh	0.857	0.832	0.902	0.69	917	0.773
LeakyReLU-3	0.905	0.956	0.979	0.865	682	0.572
LogSigmoid	0.804	0.817	0.88	0.618	1027	1.21
PReLU	0.919	0.975	0.976	0.869	710	0.67
ReLU6	0.933	0.961	0.974	0.847	702	0.605
RReLU	0.937	0.937	0.973	0.836	695	0.603
SELU	0.868	0.942	0.964	0.755	713	0.61
CELU	0.928	0.966	0.974	0.833	696	0.609
GELU	0.938	0.934	0.98	0.85	533	0.448
Softplus	0.951	0.959	0.979	0.886	1274	1.249
Softshrink	0.428	0.339	0.323	0.144	626	0.689
Softsign	0.871	0.816	0.893	0.678	600	0.636
Tanh	0.859	0.92	0.944	0.757	1054	0.89
Tanhshrink	0.0148	0.039	0.000564	0.000153	108	0.1
Threshold	0.00126	0.006	0.00145	0.00109	286	0.239
Softmin	1.80×10^{-5}	0.003	1.46×10^{-5}	4.40×10^{-6}	130	0.14
Softmax	1.65×10^{-5}	0.003	2.04×10^{-5}	7.49×10^{-6}	186	0.193
MemoryEfficientMish	0.955	0.972	0.98	0.914	1117	1.33

更平滑,有助于稳定反向传播并促进收敛,具有自正则化特性。采用 Swish 类似的非单调激活方式能在一定程度上抑制梯度爆炸或消失的现象,Mish 在输入较大的负值或正值时梯度信号依然能够有效传播,可以提升模型训练效率并获得更好的梯度流动。在噪声分析问题上,希望采用运算量较小的模型获得较好的结果从而满足时间响应要求,不对精度做出极高的要求,选用 Mish 及其改型函数作为激活函数,计算量小,也使得在后期的跨层传播中获得速度上的提高。

2.3.3 多进程优化

在噪声分析过程中,多进程优化可以提高数据读取效率,使用多个子进程可以并行处理数

据,减少训练过程中的数据读取瓶颈。过小的进程数会造成 CPU 资源闲置降低数据读取速度;过大的进程数会造成 CPU 轮训频繁,导致进程调度开销变大,进而降低总体效率,甚至出现内存不足等问题。不同的进程数设置中所对应的查全率、查准率、迭代数、单次训练时间如图 7 所示。

从图 7 中可以看出,进程数的设置需要综合考虑数据读取速度、硬件资源和并行开销,设置为 CPU 核心数减去 1~2 相对合适。同时在设置较大的进程数时,应考虑增加单个训练过程的复杂程度,即当需要训练的样本过于简单时,单次训练迭代时间过小时,大进程数反而不利于模型训练。

3 结束语

本研究基于 DNT 模型对试飞遥测噪声分析进行了深入探索,通过构建端到端的权值预置神经网络架构将噪声数据与分析结果建立映射关系,设计了数据升维模块并采用深度学习技术进行拟合训练,形成了对噪声数据高度敏感的网络模型。实验验证结果表明,DNT 网络在 5 类典型试飞噪声的识别测试中表现优异,平均识别精度达到 83.2%,查全率高达 95%,最高识别精度可达 99%。通过系统性的超参数优化,包括批大小设置、激活函数选择、多进程优化等关键技术环节的精细调优,进一步提升了模型的训练效率和识别性能。后续研究将进一步优化模型的实时性能,扩展多模态数据融合能力,并结合硬件加速技术实现更高效的现场部署应用。




图 7 不同进程数训练结果

参考文献:

- [1] WANG K C, ILIFF K W. Retrospective and recent examples of aircraft parameter identification at NASA dryden flight research center [J]. *Journal of Aircraft*, 2012, 41 (4): 752 - 764.
- [2] MORELLI E A, KLEIN V. Application of system identification to aircraft at NASA langley research center [J]. *Journal of Aircraft*, 2012, 42 (1): 12 - 25.
- [3] JATEGAONKAR R, FISCHENBERG D, GRUENHAGEN W VON. Aerodynamic modeling and system identification from flight data-recent applications at DLR [J]. *Journal of Aircraft*, 2004, 41 (4): 681 - 691.
- [4] HOBBS C, PAGE J. Acoustic repropagation technique and practical source characterization for simulation noise model databases [J]. *The Journal of the Acoustical Society of America*, 2010, 127 (3): 1834 - 1834.
- [5] ZHOU T, JIANG H, HUANG B. Quad-copter noise measurements under realistic flight conditions [J]. *Aerospace Science and Technology*, 2022, 124: 107542.
- [6] ALEXANDER W N, WHELCHER J, INTARATEP N, TRANI A. Predicting community noise of sUAS [J]. 25th AIAA/CEAS Aeroacoustics Conference, 2019.
- [7] GEORGE A R. Helicopter noise: state-of-the-Art [J]. *Journal of Aircraft*, 2012, 15 (11): 707 - 715.
- [8] LOWSON M V, OLLERHEAD J B. A theoretical study of helicopter rotor noise [J]. *Journal of Sound and Vibration*, 1969, 9 (2): 197 - 222.

(下转第 335 页)