

DOI:10.19651/j.cnki.emt.2518914

基于助听器自适应增益的预测研究^{*}方宏宇¹ 张宇翔² 宫琴²

(1.无锡清耳话声科技有限公司 无锡 214000;2.清华大学生物医学工程学院 北京 100084)

摘要:传统助听器在语音放大过程中采用的增益补偿公式主要适用于安静环境,无法满足听损患者在不同环境下实际增益的需求,这导致患者对助听器增益补偿不满意、佩戴体验感不佳,为解决这一问题,本文提出了一种针对实际生活环境自动调整最适增益的GS-LGA-XGBoost算法,算法通过极端梯度提升(XGBoost)、网格搜索(GS)和改进的遗传算法(LGA)来预测助听器各频率点增益,利用实际医院采集的患者满意的1200只耳朵的助听器增益数据作为数据集,构建小声、中声、大声三个增益预测模型。本文提出的算法在轻声、中声和大声增益测试集上的测试效果更接近患者满意的增益值。与三种不同的机器学习方法(支持向量回归(SVR)、随机森林(RF)和深度学习(DNN))相比较,本文提出的算法在预测助听器增益方面均优于其他机器学习方法。本文提出的GS-LGA-XGBoost算法不但实现助听器增益在不同环境下的动态调整,而且预测精度高,更符合听障患者对助听器满意增益的需求。

关键词:助听器;增益;极端梯度提升;人工旅鼠算法

中图分类号:R318.04;R764.5;TN91 **文献标识码:**A **国家标准学科分类代码:**510.4

Research on adaptive gain prediction for hearing aids

Fang Hongyu¹ Zhang Yuxiang² Gong Qin²

(1. Wuxi Qing'er Huasheng Technology Co., Ltd., Wuxi 214000, China;

2. School of Biomedical Engineering, Tsinghua University, Beijing 100084, China)

Abstract: Traditional hearing aids employ gain compensation formulas during speech amplification that are primarily designed for quiet environments, failing to meet the actual gain needs of hearing-impaired patients in diverse real-world settings. This results in patient dissatisfaction with the gain compensation and a suboptimal user experience. To address this issue, this paper proposes a GS-LGA-XGBoost algorithm that automatically adjusts the optimal gain for real-life environments. The algorithm predicts the gain at each frequency point of the hearing aid using Extreme Gradient Boosting (XGBoost), Grid Search (GS), and an improved Genetic Algorithm (LGA). A dataset comprising gain data from 1200 ears of patients satisfied with their hearing aids, collected from actual hospitals, was used to construct three gain prediction models for soft, medium, and loud sounds. The proposed algorithm demonstrates test results on the soft, medium, and loud gain test sets that align more closely with the gain values preferred by patients. Compared to three other machine learning methods—Support Vector Regression (SVR), Random Forest (RF), and Deep Neural Network (DNN)—the proposed algorithm outperforms all of them in predicting hearing aid gain. The GS-LGA-XGBoost algorithm not only enables dynamic adjustment of hearing aid gain across different environments but also achieves high prediction accuracy, better meeting the satisfactory gain requirements of hearing-impaired patients.

Keywords: hearing aid; gain; extreme gradient boosting; artificial lemming algorithm

0 引言

听觉受损是全球范围内普遍存在的健康问题,目前世界上约有15亿人存在听力受损问题^[1-2],据统计,我国听力受损的人群比例已达到1/6,随着人口老龄化趋势的加剧,

老年群体听力障碍问题愈发严重^[3-4],听障患者人数不断攀升,对助听器的辅助需求也越来越大。助听器的本质是一种信号放大,由验配师或者医生基于听障患者的听力测试结果,在专业软件上,选择合适的增益补偿公式(验配公式)。这些公式可以计算出外界不同响度声音信号在不同

收稿日期:2025-05-26

* 基金项目:“十四五”国家重点研发计划(2023YFC2416200)项目资助

频率处需要补偿的增益值,以补偿听障患者的听力功能缺陷,进而改善其对声音的感知和理解能力^[5]。目前,临床上主要使用的增益计算公式主要包括成人验配公式和儿童验配公式这两大类:成人验配公式主要使用图表 6 公式 (figure 6, Fig6)、NAL-NL1 公式 (nal-non linear-version 1) 和 NAL-NL2 公式 (nal-non linear-version 2) 等^[6-7],儿童验配公式主要是 DSL-V5 (desired sensation level-version 5) 公式^[7-8]。

NAL-NL1 作为一种非线性验配处方公式^[7-8],它将外界语音的响度作为增益计算依据,设计基于 Moore 响度模型与语音清晰度指数,在避免过度放大语音的同时,最大化言语可懂度^[8]。DSL-V5 公式基于儿童听觉系统发育的特点,将真耳耦合腔差值等参数考虑到助听器的增益计算中,使得儿童听损患者能够在语音的全频段范围内实现最佳言语感知^[8]。Fig6 公式是目前唯一公开的助听器增益计算公式,该公式考虑到外界语音大小对增益补偿的影响,针对语音的小声、中声、大声处,分别施加不同增益值。

在助听器增益计算中,NAL 与 DSL-V5 作为主流验配公式被广泛应用, Fig6 公式也在公开增益算法中占据重要地位。但是,研究表明,上述所有的公式仍存在一定局限性:首先,某些频段计算出的增益存在过度放大问题,达不到听损患者最适增益的需求;其次,计算出的助听器增益都是安静环境下的,适应外界环境的增益需要依赖医生再进行手动增益调整。因此,迫切需要开发一种适合外界通用环境且能短时间内精准预测助听器增益的方法。

近年来机器学习在预测方面应用广泛^[9-11],其中,极端梯度提升 (extreme gradient boosting, XGBoost) 算法具有较强的预测精度,在计算效率及泛化能力方面均表现出显著优势^[12-13],但在助听器增益预测研究中,机器学习应用受限的主要瓶颈在于缺乏患者满意的增益数据,致使相关研究较少。为了解决上述提到的问题,本文利用实际采集的患者在不同外界环境下满意的助听器增益数据,提出了基于 XGBoost 预测助听器增益的方法。2024 年 Huang 等^[14]将其用于海洋领域,用于波浪预测。相较于传统方法,该结果精度更高,然而,该方法使用网格搜索 (grid search, GS) 优化 XGBoost 参数,未考虑到 GS 只适合确定浮点参数类型;刘馨雅等^[15]在 2024 年将 XGBoost 用于故障诊断领域,但是,该方法同样未考虑参数特性,对于不同类型的参数采用同一套优化策略,因此,考虑到参数类型对优化策略的影响,本文提出利用网格搜索方法和改进的遗传算法对 XGBoost 算法的超参数进行调优,构建基于网格搜索法和改进的遗传算法优化的极端梯度提升算法 (GS-LGA-XGBoost),用于助听器在不同环境下的自适应增益值的预测。

1 研究方法

1.1 GS-LGA-XGBoost 算法

本研究的目的是基于听力损失患者的听力信息,能够

快速预测其在外界环境中患者在不同频率处需要补偿的放大增益值,鉴于此,实验使用 XGBoost 作为助听器增益预测的核心模块。由于 XGBoost 模块中的超参数设置对其性能具有重要影响,若参数选择不当可能导致该模块不能与助听器实际增益数据进行拟合^[16]。考虑到简单性的问题,引用网络搜寻 GS 模块来确定核心模块的超参数,GS 的核心原理在于按照设定的步长对各个参数进行逐一调整^[14],该方法只适用于整型参数的确定,无法有效处理浮点型参数,因此,针对浮点型参数,为了节省预测助听器增益的时间,实验选用收敛速度较快的遗传算法 (genetic algorithm, GA) 模块来确定^[17],但 GA 模块也存在局限性,其模块中的种群数量会严重影响其最优参数的确定效果,为此本研究进一步引入 2025 年 1 月被首次提出的人工旅鼠算法 (artificial lemming algorithm, ALA) 模块来改进 GA 模块的种群数量设置^[18],改进后的 GA 模块称为 LGA 模块 (genetic algorithm optimized by artificial lemming algorithm, LGA)。基于上述情况,实验采用 GS 模块、LGA 模块、XGBoost 模块构建起增益预测模型 GS-LGA-XGBoost,实现对实际环境下患者满意的助听器增益值的预测。下面对各个模块的主要方法进行简单介绍。

1) XGBoost 模块

XGBoost 作为核心模块,是一种基于决策树的优化技术,其利用梯度提升法来优化损失函数,并通过引入正则化参数来防止过拟合。XGBoost 算法的核心思想是最小化以下目标函数:

$$Obj(\theta) = \sum_{i=1}^n l(\hat{y}_i, y_i) + \sum_{k=1}^K \Omega(f_k) \quad (1)$$

式中: $l(\hat{y}_i, y_i)$ 用表示损失误差, \hat{y}_i 是第 i 个样本的预测值, y_i 是第 i 个样本的实际值, Ω 为正则化函数,用来描述惩罚模型复杂度。 f_k 是第 k 棵树的模型,防止模型的过拟合是通过正则化项实现的。正则化项具体表达式如下:

$$\Omega(f) = \gamma T + 0.5\lambda \|\omega\|^2 \quad (2)$$

式中: T 表示树叶总数, γ 和 λ 表示惩罚系数, ω 为包含每个叶片得分的向量。

2) 网格搜索 GS 模块

网格搜索技术 GS 是一种遍历参数寻优方法,其核心在于组合每个可能的参数,并将这些组合参数逐一应用于模型训练过程。在模型训练过程中,拟合函数会全面评估所有参数组合的性能,最终输出经过参数优化的分类器,该分类器能够自动匹配机器学习模型的最优参数组合。本研究主要使用该模块确定核心模块的 2 个整型超参数。

3) 遗传算法 GA 模块

遗传算法 GA 是一种模拟生物进化过程的智能优化方法^[17]。它以随机生成的初始解集为起点,将每个解视为种群中的个体(染色体)。通过适应度函数评估个体优劣,高适应度将个体获得更高生存概率。算法会对高适应度的个

体进行选择、交叉和变异操作,产生更加符合目标函数新群体,经过多次迭代,种群逐渐收敛至最优解,最终在达到最优解或最大迭代次数时终止。本研究主要使用该模块确定核心模块的3个浮点型超参数。

4)人工旅鼠算法 ALA 模块

人工旅鼠算法 ALA 是一种新型元启发式算法,其核心思想源自对自然界旅鼠多种生存行为的模拟,包括其大规模迁徙、觅食活动、洞穴构建以及逃避捕食者等典型行为特征,通过建立数学模型来模拟这些生物行为,从而实现问题的求解。本研究使用该模块改进 GA 模块的种群数量设

置,改进后的 GA 模块称为 LGA 模块(LGA)。

1.2 GS-LGA-XGBoost 算法流程

实验采用网格搜索 GS 模块确定 XGBoost 核心模块中的两个整型超参数,在此基础上,利用人工旅鼠算法 ALA 模块改进的遗传算法 GA 模块的参数(种群数量),然后,使用已确定参数的遗传算法模块 LGA 继续确定 XGBoost 核心模块的3个浮点超参数,实现基于 GS-LGA-XGBoost 算法对实际环境下的患者满意的助听器增益的预测。

表1显示了本文所需要确定的 XGBoost 核心模块的超参数,以及对应各个参数的类型及范围。

表1 XGBoost 算法中超参数的含义

Table 1 The meanings of hyper-parameters in the XGBoost algorithm

超参数	类型	范围	含义
min_child_weight	integer	[0,20)	子节点所需的最小实例权重
max_depth	integer	[0,10)	每棵树的最大深度
subsample	floating-point	(0,1]	每棵树构建时随机采样的训练样本比例
gamma	floating-point	[0,7]	节点分裂所需的最小损失减少值
colsample_bytree	floating-point	(0,1)	每棵树构建时随机采样的特征比例

采用基于 GS-LGA-XGBoost 的机器学习方法进行助听器增益预测时,其具体流程图如图1所示,分别详述如下:

1) 构建基于 XGBoost 模块的助听器增益预测基础模型。在初始阶段,将 XGBoost 模块的5个关键超参数均设置为默认。

2) 采用网格搜索方法(GS)模块确定2个整型参数(min_child_weight、max_depth)的最优值。

3) 使用人工旅鼠算法(ALA)算法模块确定遗传算法(GA)的种群数量。

4) 利用第3)步确定的种群数量,使用遗传算法模块确定 XGBoost 核心模块的3个浮点参数(subsample、gamma、colsample_bytree)。

5) 利用已经确定的5个超参数的值,构建基于 GS-LGA-XGBoost 算法的增益预测模型。

6) 如果 XGBoost 核心模块训练次数达到设定的最大值,则输出当前最优的 RMSE 结果。否则,重复步骤6)。

2 实验方法

本节详细阐述了实验准备与评估结果。研究将 GS-LGA-XGBoost 算法计算得到的助听器增益计算结果与主流助听器增益计算公式 NAL-NL1、NAL-NL2、DSL[i/o] (desired sensation level[input/output],DSL[i/o])的计算结果作对比,同时,作为消融实验,还将本文方法与 XGBoost 和 GS-XGBoost 的计算结果进行了对比,此外,本文方法还与三种不同的机器学习方法——支持向量回归(support vector regression, SVR)^[19]、随机森林(random

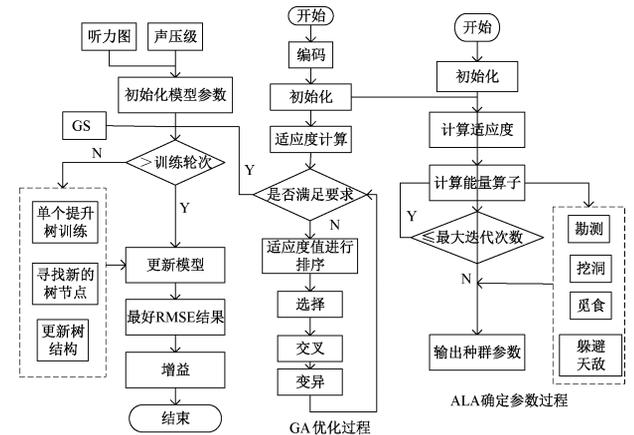


图1 算法流程结构图

Fig. 1 Algorithm process structure diagram

forest, RF)^[20]和深度学习^[21](deep neural network, DNN)作比较,实验中的所有算法均使用 Python 3.6 编程语言实现。

2.1 实验数据准备

本研究采集了实际生活环境下,来自成人患者的1200只耳朵的助听器验配数据,这些数据包括每位患者听力图信息以及外界输入为小声(声压级40 dB SPL)、中声(声压级65 dB SPL)、大声(声压级90 dB SPL)时,助听器对应各个频率处的该患者经过调整后,感到最为满意的增益值。由于助听器验配时公式计算的主要就是外界输入语音分别为小声、中声、大声时在各个频率点处增益值。以往的助听器增益计算公式表明,小声、中声、大声在各个频率处的增益值不仅与患者的听力图(即各个频点的听力阈值)有关,而且与外界语音的声压级有关。

基于此,本文构建了一个数据集,数据中一共有 1 200 只耳朵,每只耳朵都有患者在 6 个频率点处(0.25、0.5、1、2、4、8 kHz)的听力阈值,输入声压级、以及对应输入声压级(小声、中声、大声)下在 16 个频率处(0.125、0.25、0.5、0.625、0.75、1、1.1、1.25、1.5、1.75、2、3、4、5、6、8 kHz)的增益值,一共有 $1\,200 \times 16 = 18\,000$ 条样本。本实验以各个频点的听力阈值和外界语音的输入声压级作为模型的特征输入,各个声压级(小声、中声、大声)各频点处的增益作为模型的特征输出。

在实验中,对现有数据集进行了随机处理,通过洗牌和重组构建训练集,由于小声、中声、大声在各频率点处的相差较大,本文构建了 3 个模型,分别是小声、中声、大声增益预测模型,在助听器增益预测时,采用五折交叉验证,选取 90% 的样本用来训练,剩下 10% 的样本用来测试。

2.2 测量度量

实验利用均方根误差 RMSE 和平均绝对误差 MAE 作为预测精度的评价指标,公式如下:

$$RMSE = \sqrt{\frac{1}{2} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

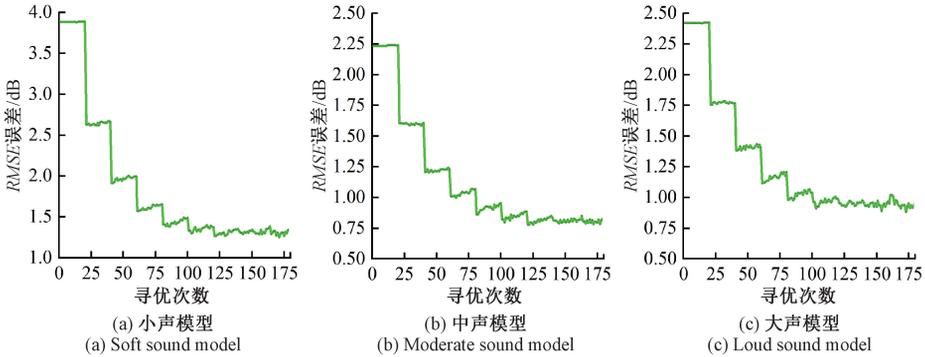


图 2 RMSE 和 GS 寻优次数的关系曲线

Fig. 2 The relationship curve between RMSE and the number of optimization times of GS

GS 确定 XGBoost 核心模块的 min_child_weight、max_depth 最优参数后,当均方误差 RMSE 达到最小值时,min_child_weight、max_depth 取值随寻优次数变化曲线如图 3 所示。由上一个结果可知小声增益在第 128 次、中声在第 167 次、大声在第 169 次时取得最优参数结果,故从图 3(a)、(b)可以看出每一次的寻优时 min_child_weight 和 max_depth 的取值,小声模型对应的 min_child_weight、max_depth 最优参数分别为 7、7;中声的为 6、9;大声的为 8、9。所选超参数的搜索范围以及最优值如表 2 所示。

确定 2 个整型参数值后,随后采用遗传算法(GA)对 subsample、gamma、olsample_bytree 这 3 个浮点型参数进行优化确定,由于 GA 的种群数量严重影响 GA 的优化效果,本实验采用旅鼠算法(ALA)模块来确定 GA 模块的种群数量,图 4 是 ALA 确定 GA 种群数量的适应度变化

在式(3)、(4)中, y_i 表示实际增益值,表示预测的增益值, n 表示数据的总数。RMSE 和 MAE 越低,模型的预测效果越好。

2.3 实验步骤

首先,使用网格搜索(GS)模块来优化确定核心模块 XGBoost 的 min_child_weight、max_depth 这两个整型最优参数。借助训练集构建小声、中声、大声 3 个增益预测模型,分别用来预测小声、中声、大声各频点处的增益值,在此过程中,将其他 3 个浮点型参数设为默认值。如图 2 所示,图 2 展示了小、中、大声模型中,均方根误差 RMSE 随 GS 寻优次数变化的关系曲线,在总共 180 次寻优次数中,随着寻优次数的增加, RMSE 先稳定一段区间再逐渐减小,以此往复。在小声增益预测中,如图 2(a)所示,寻优到达 122 次后逐渐稳定,中声增益预测时,如图 2(b)所示,寻优到达 124 次后逐渐稳定,大声增益预测在寻优达到 105 次后逐渐稳定,如图 2(c)所示。最优超参数值是所有测试组合中 RMSE 最小的候选值。所以,在它们稳定后,选取 RMSE 最小的那一次寻优次数作为寻优结果,即小声增益在第 128 次、中声在第 167 次、大声在第 169 次寻优时,取得 RMSE 最小值为 1.35、0.85、0.96。

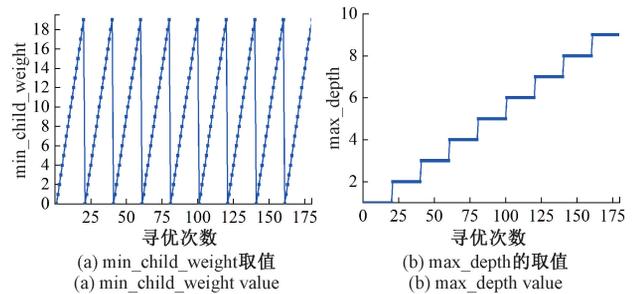


图 3 XGBoost 的超参数随 GS 寻优次数的取值曲线

Fig. 3 The value curve of the hyperparameters of XGBoost with the number of optimization times of GS

函数。迭代次数设置为 50 次,设置初始 GA 算法种群数量范围为 $[0, 20]$ 。当适应度值 RMSE 趋于稳定时,输出此时

表2 超参数调优的最优值

Table 2 The optimal values of hyper-parameter tuning

超参数	范围	最优值		
		小声	中声	大声
min_child_weight	[0,20)	7	6	8
max_depth	[0,10)	7	9	9

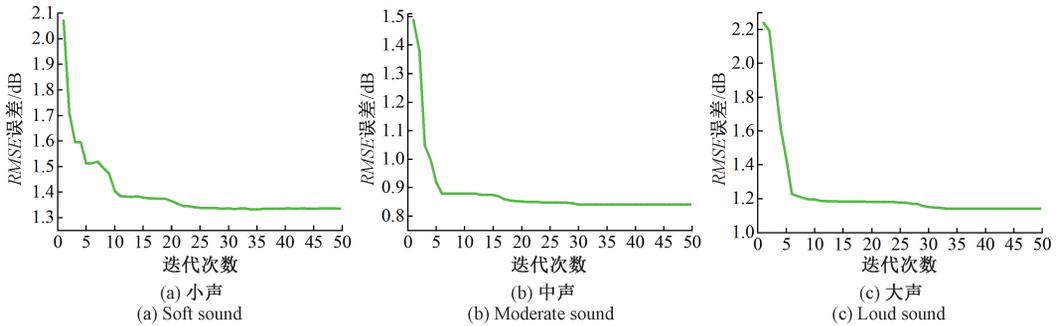


图4 ALA优化中的适应度变化曲线

Fig. 4 The curve of fitness change during ALA optimization

使用种群数量已确定的遗传算法GA继续优化3个浮点超参数。其遗传算法GA的适应度曲线如图5、6所示。图5、6展示种群数量参数未确定和参数已确定的遗传算法优化3个浮点型参数(subsample、gamma、olsample_bytree)的适应度变化曲线。图5、6的(a)、(b)、(c)分别表示小声、中声和大声增益预测模型。图5的种群数量参数已确定,由上一个实验结果已得出小声模型的种群数量为15,中声种群数量为10,大声种群数量为12。图6是GA的种群数量未确定,所以实验中任意设置的一个值:8。图5(a)的1~15表示小声模型生成的15个种群,同理,图5(b)、(c)和图6(a)、(b)、(c)也是如此。它们的迭代次数都设置为50次。下图的横坐标为迭代次数,纵坐标RMSE为个体适应度,随着迭代次数的增加,所有种群稳定时,就输出最优参数结果。在确定种群参数条件下,如图5(a)所

的结果,即GA的种群数量,在50次迭代过程中,如图4(a)所示,小声模型在22次迭代时趋向稳定;如图4(b)所示,中声模型在19次;如图4(c)所示,大声在第30次时趋向稳定,当适应度值总体稳定时,此时输出的小声模型的GA种群数量为15,中声种群数量10,大声种群数量为12。

示,小声模型的种群在37次迭代时达到稳定;如图5(b)所示,中声模型在31次时稳定;如图5(c)所示,大声模型在45次时稳定,输出subsample、gamma、olsample_bytree最优结果分别为:0.83、1、0.95;0.72、2.3、0.47;0.54、3.6、0.87。对比参数未确定的遗传算法适应度变化曲线,如图6(a)、(b)、(c)所示,无论是小声模型还是中声、大声模型,随着迭代次数的增加,种群趋于稳定时,均方根误差(RMSE)甚至高于初始通过网格搜索模块优化后的结果。这一现象表明,种群数量的设置不当可能对遗传算法GA确定XGBoost核心模块的参数产生负面影响。因此,采用旅鼠优化算法(ALA)来确定遗传算法(GA)的参数,简称为LGA,LGA能够更有效地促进浮点型参数的优化确定,从而提升模型性能。

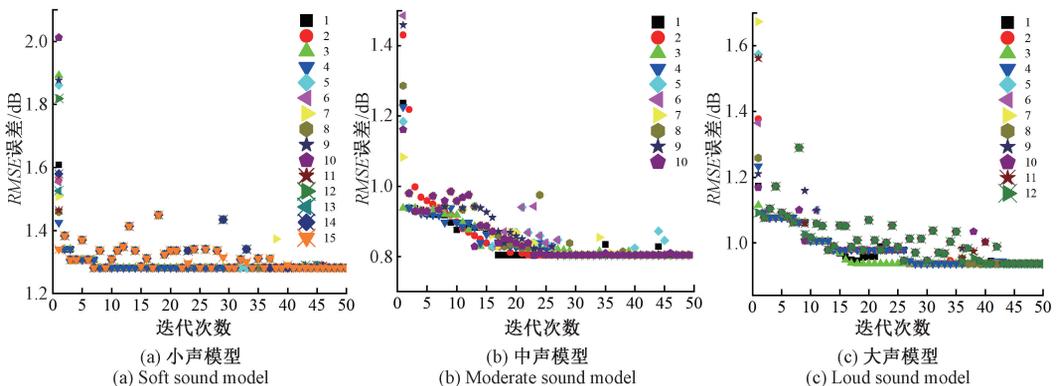


图5 参数确定后的遗传算法适应度变化曲线

Fig. 5 The fitness change curve of the genetic algorithm after the parameters are determined

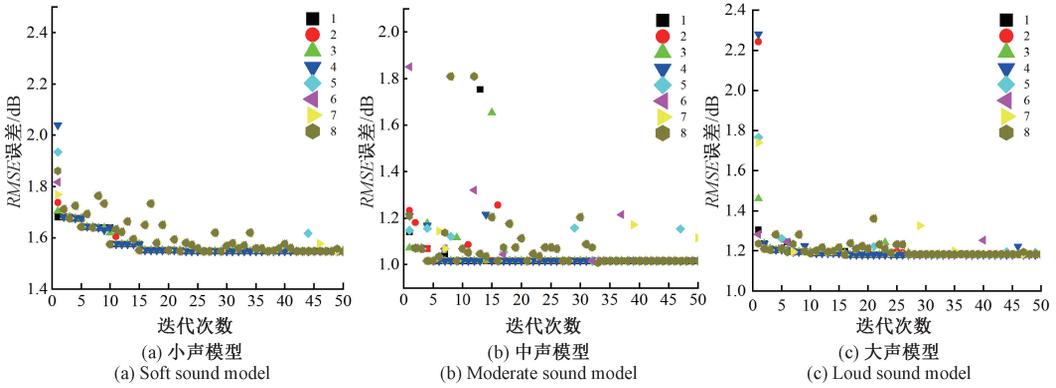


图 6 参数未确定的遗传算法适应度变化曲线

Fig. 6 The fitness change curve of the genetic algorithm when the parameters are undetermined

3 结 果

利用 GS-LGA-XGBoost 算法预测实际患者满意的增益数据,主要是预测 16 个频率点处的增益,所以在进行预测分析时,需要考虑各个频率点处的预测效果,如图 7 所示,图 7 绘制出所有测试样本在各个频率点下预测值和实际值的平均绝对误差 MAE 和其方差。在图 7 中,不同柱子代表不同增益预测模型,绿色是小声增益预测(柱状图里面包含点状图标)、黄色是中声增益预测(柱状图里面包含地质图曲线)、紫色是大声增益预测(柱状图里面包含线段),横坐标代表频率,纵坐标代表某个频率下所有测试样本预测值和实际值的平均绝对误差的均值,柱子上面的误差棒代表方差,表征误差的稳定程度。从图 7 可知,无论是小声增益预测还是中声、大声增益预测,各个频率点下的相对误差的均值都在 1 dB 以下,不过,在高频增益预测部分,误差的方差较大,误差结果不稳定,其原因考虑到在数据采集时,患者实际使用的助听器性能各有不同,部分助听器性能不佳,其高频段完全不施加增益,而性能更优的助听器,在高频段施加的增益可达到 10 dB 以上。因此,在不同助听器的型号下,即使是同一个患者,高频也会有较显著的差别。基于上述情况,使用 GS-LAG-XGBoost 进行助听器增益预测时,在高频部分预测误差会表现出不稳定性。总体来说,使用本文算法在低声、中声、大声各个频率处的增益预测误差都较小,某些频点处的平均误差绝对误差甚至在 0.5 dB 左右,整体预测性能优异。在实际助听器各频点处的增益预测中,只要预测值与实际患者满意的增益值尽量不超过 5 dB,最大不超过 10 dB,就认为预测计算出的助听器增益误差在合理范围内,所以本算法预测的增益结果具有较高的精度。各个频点处不同增益的预测的误差详细结果如表 3 所示。

本研究比较了本文 GS-LGA-XGBoost 算法增益预测结果与传统增益计算公式预测的结果,用以判断哪种算法更接近实际患者满意的助听器增益值。结果如表 4 所示。在表 4 中,本算法与实际患者满意的助听器增益间的

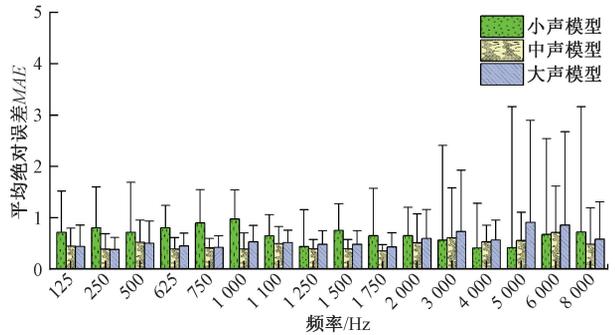


图 7 各个频点处不同增益的预测的误差

Fig. 7 The prediction errors of different gains at each frequency point

表 3 各个频点处不同增益的预测的误差

Table 3 The errors of predictions for different gains at each frequency point

频率	小声增益		中声增益		大声增益	
	误差均值 MAE	方差	误差均值 MAE	方差	误差均值 MAE	方差
125	0.71	0.83	0.44	0.35	0.44	0.41
250	0.80	0.84	0.38	0.31	0.38	0.23
500	0.71	0.97	0.51	0.43	0.51	0.43
625	0.81	0.43	0.39	0.22	0.44	0.25
750	0.89	0.64	0.41	0.18	0.41	0.22
1 000	0.97	0.56	0.39	0.31	0.52	0.32
1 100	0.64	0.41	0.49	0.33	0.51	0.24
1 250	0.43	0.72	0.39	0.17	0.48	0.26
1 500	0.75	0.52	0.39	0.18	0.48	0.25
1 750	0.64	0.92	0.35	0.12	0.43	0.27
2 000	0.64	0.55	0.51	0.56	0.59	0.56
3 000	0.56	1.84	0.60	0.97	0.73	1.19
4 000	0.41	0.87	0.52	0.32	0.56	0.38
5 000	0.42	2.74	0.55	0.55	0.91	1.98
6 000	0.67	1.86	0.71	0.90	0.85	1.82
8 000	0.72	2.44	0.48	0.70	0.58	0.73

平均绝对误差 MAE 基本都在 1 dB 以下,均方根 RMSE 误差最大也不超过 1.3。而目前主流助听器增益计算公式 (Fig6、NAL-NAL1、NAL-NAL2、DSL[i/o]) 计算的平均绝对误差最好也在 2 dB 左右,其最优 RMSE 值均在 2 dB 以上。因此,本算法 (GS-LGA-XGBoost) 的计算的助听器增益相较于传统计算公式,更符合实际患者满意的增益需求,与实际最适增益更接近,同时,实验对比了 XGBoost、GS-XGBoost 的预测误差,其中,原始 XGBoost 误差最大,本算法 (GS-LGA-XGBoost) 误差最小。

表 4 不同算法下预测增益与实际增益的误差对比

Table 4 A comparison of errors between predicted gains and actual gains under different algorithms

公式	MAE			RMSE		
	小声	中声	大声	小声	中声	大声
本文	0.89	0.45	0.57	1.26	0.79	0.92
Fig6	3.78	2.87	3.67	4.81	3.52	4.67
NAL-NAL1	3.62	3.54	3.53	4.56	4.22	4.51
NAL-NAL2	2.69	2.33	2.66	3.12	3.25	3.34
DSL[i/o]	4.98	4.89	4.67	5.61	5.56	5.93
XGBoost	1.55	1.51	1.16	2.64	2.23	1.81
GS-XGBoost	0.89	0.52	0.58	1.35	0.85	0.96

为了进一步验证效果,实验利用所有测试患者在不同频率处的平均绝对误差 MAE 进一步验证本算法的优势,在小声、中声、大声增益预测中,实验对比了本文算法 (GS-LGA-XGBoost) 和目前主流增益计算公式 (Fig6、NAL-NAL1、NAL-NAL2、DSL[i/o]),如图 8~10 所示。图 8、9、10 分别对应预测的是小声、中声和大声增益。它们展示了各个公式不同频率处计算的误差 (MAE) 对比,MAE 表示预测的增益与实际患者满意的增益值间的平均绝对误差。由图 9 可知,本文算法的预测助听器的增益效果最好。同理,中声增益预测结果如图 9 所示,本文算法的误差具有明显优势,图 10 的大声增益预测结果也是如此。

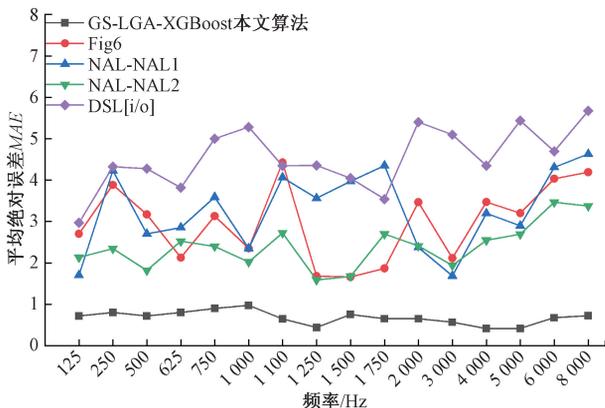


图 8 各个算法小声增益预测误差对比图

Fig. 8 Comparison diagram of prediction errors of soft sound gains for various algorithms

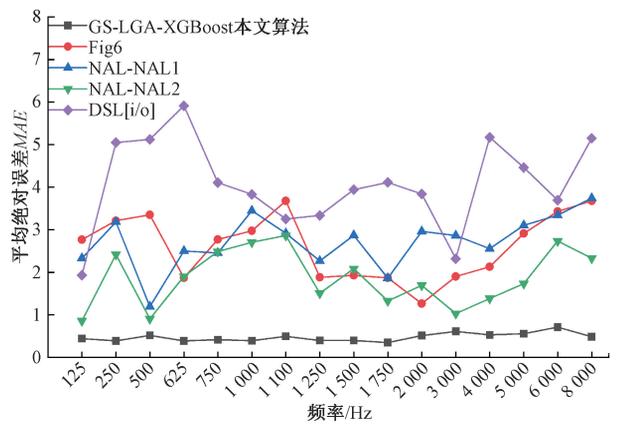


图 9 各个算法中声增益预测误差对比图

Fig. 9 Comparison diagram of prediction errors of moderate sound gains in various algorithms

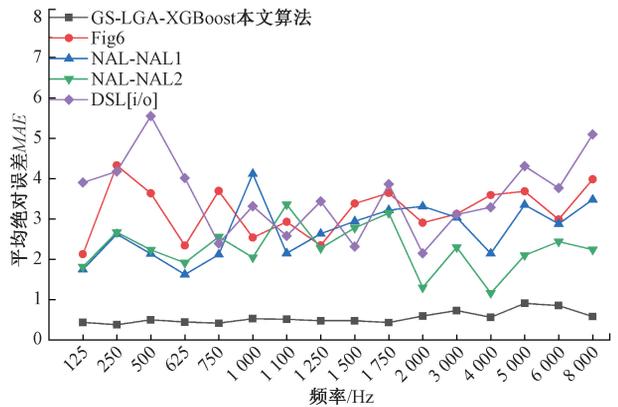


图 10 各个算法大声增益预测误差对比图

Fig. 10 Comparison diagram of prediction errors of loud sound gains for each algorithm

为了更好的评估 GS-LGA-XGBoost 算法的预测的性能,本文绘制出交叉图,此外,还将 GS-LGA-XGBoost 的精度与 3 种不同的机器学习方法进行了比较:支持向量回归 (SVR)、随机森林 (RF) 和深度神经网络 (DNN)。SVR 是一个支持向量机的扩展^[19],它使用一个以支持向量形式存在的训练点的子集来创建一个回归模型。RF 是一种集成学习技术^[20],它集成了决策树的数量,以获得更精确和更稳定的预测,DNN 由多层神经元(节点)构成^[21],能够从数据中自动学习复杂的特征表示。如图 11~13 所示,图 11~13 分别表示小声、中声和大声增益预测的交叉图,这些交叉图显示了使用本文算法 (GS-LGA-XGBoost) 与其他机器学习方法在预测精度上的对比结果。交叉图的横坐标代表实际患者满意的增益值,纵坐标代表机器学习预测的增益值,当实际值和预测值越接近,均方根误差 RMSE 就越小,说明拟合效果越好,散点越近似 $y=x$ 的直线。在小声增益预测中。如图 11(a) 所示的本文算法 (GS-LGA-XGBoost) 对比如图 11(b) 所示的 SVR 小声模型、如图 11(c) 的 RF 小声模型以及如图 11(d) 所示的 DNN 小声

模型,其本算法更适合预测实际患者满意的助听器增益,其 $RMSE=1.27$ 。DNN 的效果最差 $RMSE=2.13$ 。在中声增益预测中,如图 12(a)所示的本文算法(GS-LGA-XGBoost)对比如图 12(b)所示的 SVR 中声模型、如图 12(c)的 RF 中声模型以及如图 12(d)所示的 DNN 中声模型,本文算法的优势更明显,均方根误差($RMSE$)接近 0.8。在大声增益预测中,如图 13(a)所示的本算法、13(b)所示的 SVR 大声模型、13(c)所示的 RF 大声模型、13(d)所示 DNN 大声模型,本文的预测结果($RMSE=0.92$)和 RF 方法($RMSE=1.01$)有点接近,但是还是本文算法具有优势。在小声、中声、大声增益预测中,都是 DNN 预测

的结果最差,其主要原因是 DNN 学习需要依靠大量数据,本文的增益数据量不足以提供 DNN 训练,所以 DNN 预测效果不佳。在 3 种增益的预测中,无论是使用哪种机器学习方法,都是小声增益预测的误差最大,主要原因是在实际增益数据中,小声增益的范围跨度最广,预测误差也因此比较大。而中声增益预测的效果最好,因为中声增益相较小声、大声,它的值处于中间位置,比较稳定。总的来说,本文算法(GS-LGA-XGBoost)预测的增益结果与实际结果非常吻合。这些统计误差表明,GS-LGA-XGBoost 在预测助听器增益方面优于其他模型,更适合实际助听器增益的预测。

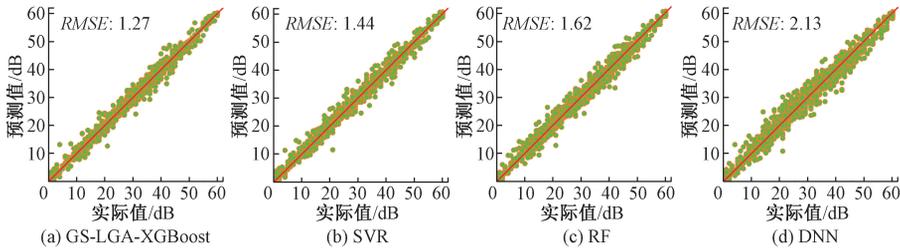


图 11 不同算法小声增益预测交叉图

Fig. 11 Cross diagram of soft sound gain predictions by different algorithms

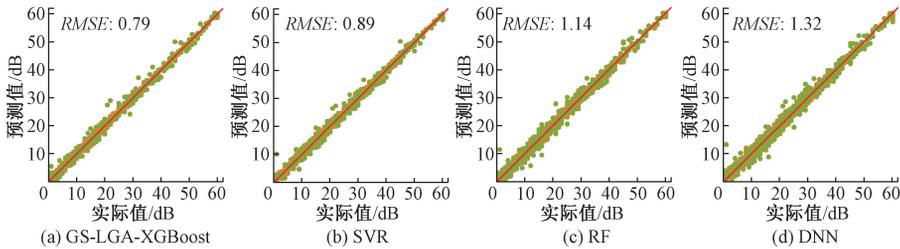


图 12 不同算法中声增益预测交叉图

Fig. 12 Cross diagram of moderate sound gain predictions by different algorithms

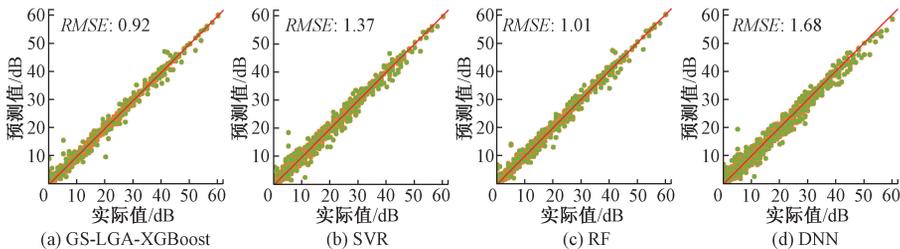


图 13 不同算法大声增益预测交叉图

Fig. 13 Cross diagram of loud sound gain predictions by different algorithms

4 结 论

本文构建了一套使用 GS-LGA-XGBoost 的机器学习算法,用于计算实际环境中患者满意的助听器增益,相较于传统的助听器验配公式,本文提出的算法预测的增益结果更接近患者在实际环境下满意的增益值,大大减少了助听器初次验配后需要的后续微调,能够节省医生时间,提高患者验配满意度。

在与其他机器学习方法的比较上,本文提出的算法相较于支持向量回归(SVR)、随机森林(RF)和深度学习(DNN)这些主流机器学习算法,面对较小的数据量能够获得较高的预测准确度与精度,在计算实际情况下患者满意的助听器增益的任务中,具有明显优势。

参考文献

- [1] CHADHA S, KAMENOV K, CIEZA A. The world report on hearing[J]. Bulletin of the World Health

- Organization, 2021,99(4): 242-242A.
- [2] XIE J, HE L, GONG SH SH. Interpretation and thought on the WHO world report on hearing [J]. Chinese Journal of Otorhinolaryngology Head and Neck Surgery, 2021, 56(10): 1131-1135.
- [3] 韦干观, 韦福依, 谭颂华, 等. 老年听力损失患者配戴助听器满意度调查及其影响因素分析[J]. 中国听力语言康复科学杂志, 2024, 22(5): 484-487.
WEI G G, WEI F Y, TAN S H, et al. Satisfaction survey and influencing factors analysis of hearing aid use in elderly patients with hearing loss [J]. Chinese Scientific Journal of Hearing and Speech Rehabilitation, 2024, 22(5): 484-487.
- [4] 丁倩倩, 王亚茹, 张莹, 等. 老年性听力损失患者助听器配戴态度、效果与认知功能的相关性[J]. 中国听力语言康复科学杂志, 2025, 23(1): 43-46.
DING Q Q, WANG Y R, ZHANG Y, et al. Correlation between hearing aid use attitude, effectiveness, and cognitive function in elderly patients with presbycusis [J]. Chinese Scientific Journal of Hearing and Speech Rehabilitation, 2025, 23(1): 43-46.
- [5] FURUKI S, SANOH, KURIOKA T, et al. Investigation of hearing aid fitting according to the national acoustic laboratories' prescription for non-linear hearing aids and the desired sensation level methods in Japanese speakers: A crossover-controlled trial [J]. Auris Nasus Larynx, 2023, 50(5): 708-713.
- [6] 余双喜. 基于人工神经网络的助听器验配公式的研究与实现[D]. 天津: 天津大学, 2020.
YU SH X. Research and implementation of hearing aid fitting formula based on artificial neural network [D]. Tianjin: Tianjin University, 2020.
- [7] 王婕. 数字助听器验配公式和自验配算法研究与实现[D]. 南京: 东南大学, 2023.
WANG J. Research and implementation of digital hearing aid fitting formulas and self-fitting algorithms [D]. Nanjing: Southeast University, 2023.
- [8] CHING T Y C, QUAR T K, JOHONSON E E, et al. Comparing NAL-NL1 and DSL v5 in hearing aids fit to children with severe or profound hearing loss: Goodness of fit to-targets, impacts on predicted loudness and speech intelligibility [J]. Journal of the American Academy of Audiology, 2015, 26(3): 260-274.
- [9] HASSAN M, RONY M, KHAN M, et al. Machine learning-based rainfall prediction: Unveiling insights and forecasting for improved preparedness [J]. IEEE Access, 2023(11): 132196-132222.
- [10] SAYED E H, ALABRAH A, RAHOUMA K H, et al. Machine learning and deep learning for loan prediction in banking: Exploring ensemble methods and data balancing [J]. IEEE Access, 2024, 12: 193997-194019.
- [11] YULIANA H, ISKAND, HENDRAWAN. Comparative analysis of machine learning algorithms for 5G coverage prediction: Identification of dominant feature parameters and prediction accuracy [J]. IEEE Access, 2024(12): 18939-18956.
- [12] 王海峰, 行鸿彦, 陈梦, 等. 基于精细复合多尺度散布熵与 XGBoost 的海面小目标检测方法 [J]. 电子测量与仪器学报, 2023, 37(1): 12-20.
WANG H F, XING H Y, CHEN M, et al. A sea surface small target detection method based on fine composite multiscale dispersion entropy and XGBoost [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 12-20.
- [13] 肖寅东, 曾宇通, 刘科, 等. 基于 XGBoost 的模拟集成电路测试参数优化方法 [J]. 电子测量与仪器学报, 2023, 37(4): 61-68.
XIAO Y D, ZENG Y T, LIU K, et al. An optimization method for analog integrated circuit test parameters based on XGBoost [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(4): 61-68.
- [14] HUANG W, TANG R, QU G, et al. An XGBoost-based method for improved orbit prediction with an orbit-separate modeling strategy [J]. Journal of IEEE Transactions on Aerospace and Electronic Systems, 2024, 60(4): 4887-4895.
- [15] 刘馨雅, 马超, 黄民, 等. 变转速工况下基于角度重采样与 PCA-XGBoost 轴承故障诊断方法研究 [J]. 电子测量与仪器学报, 2024, 38(3): 45-54.
LIU X Y, MA CH, HUANG M, et al. Research on bearing fault diagnosis method based on angle resampling and PCA-XGBoost under variable speed conditions [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(3): 45-54.
- [16] CHEN T Q, GUESTRIN C. XGBoost: A scalable tree boosting system [C]. 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016, 785-794.
- [17] 王昊, 李晖, 宋端正, 等. 面向云-雾计算系统中的遗传算法任务调度研究 [J]. 电子测量与仪器学报, 2023, 37(8): 40-51.
WANG H, LI H, SONG D ZH, et al. Research on

- task scheduling of genetic algorithm for cloud-fog computing systems [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 40-51.
- [18] ANING X. Artificial lemming algorithm: A novel bionic meta-heuristic technique for solving real-world engineering optimization problems [J]. Artificial Intelligence Review, 2025, 58(3):84.
- [19] PRIYADARSHI M, DAS P, HUSSAIN A, et al. Prediction of specific methanogenic activity of anaerobic sludges from sewage treatment plants of Delhi, India based on SVR model[J]. Fuel, 2025, 385: 134119.
- [20] 石晴,张国山,刚蓓,等.基于随机森林的管道漏磁缺陷检测与量化[J].电子测量与仪器学报,2025,39(3): 199-207.
- SHI Q, ZHANG G SH, GANG B, et al. Magnetic flux leakage defect detection and quantification for pipelines based on random forest [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(3): 199-207.
- [21] LEE J, BYUN N, RYU S, et al. DNN-based estimation of flexural strength of horizontally curved bracing system [J]. Journal of Constructional Steel Research, 2025, 226: 109203.

作者简介

方宏宇, 硕士, 主要研究方向为助听器验配。

E-mail: 1833321737@qq.com

张宇翔, 博士研究生, 主要研究方向为真耳分析、助听器验配。

E-mail: yuxiang-22@mails. tsinghua. edu. cn

宫琴(通信作者), 博士生导师, 主要研究方向为听觉检测康复与认知工程等。

E-mail: gongqin2016@foxmail.com