

安全与环境学报
Journal of Safety and Environment
ISSN 1009-6094, CN 11-4537/X

《安全与环境学报》网络首发论文

题目: CEEMD-GRU 组合道路噪声预测模型
作者: 冯增喜, 崔巍, 何鑫, 赵锦彤, 孙欣, 张茂强, 杨芸芸, 韦娜
DOI: 10.13637/j.issn.1009-6094.2022.0715
收稿日期: 2022-04-20
网络首发日期: 2022-06-29
引用格式: 冯增喜, 崔巍, 何鑫, 赵锦彤, 孙欣, 张茂强, 杨芸芸, 韦娜. CEEMD-GRU 组合道路噪声预测模型[J/OL]. 安全与环境学报.
<https://doi.org/10.13637/j.issn.1009-6094.2022.0715>



网络首发: 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

出版确认: 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。

CEEMD-GRU 组合道路噪声预测模型

冯增喜¹, 崔巍¹, 何鑫¹, 赵锦彤¹, 孙欣¹, 张茂强¹, 杨芸芸¹, 韦娜²

(1.西安建筑科技大学建筑设备科学与工程学院, 西安 710055 2.西安建筑科技大学艺术学院, 西安 710055)

摘要: 针对道路降噪问题, 为降低主动噪声控制方法中滤波算法收敛性能要求, 提出一种基于互补集合经验模态分解 (complementary ensemble empirical mode decomposition, CEEMD) 与门控循环单元 (gated recurrent unit, GRU) 组合的道路噪声预测模型 (CEEMD-GRU)。首先, 基于 CEEMD 算法将输入的噪声音频序列分解为多个本征模态函数分量和一个残差分量, 以深度挖掘数据隐含的波动信息; 然后, 利用 CEEMD 分解的输入噪声序列各分量和输出噪声序列构建 CEEMD-GRU 神经网络噪声预测模型; 最后, 基于西安市某路段采集的噪声数据对该模型的有效性进行验证。试验结果表明: 该模型 E_{MA} 为 0.0191, R_{MSE} 为 0.0308, R^2 为 0.5892, 预测声信号能够代替主动噪声控制中自适应控制器的实际初级声信号, 为主动噪声控制的控制过程提供了更充分的响应时间。

关键词: 环境工程学; 噪声与振动控制; 噪声预测; 主动噪声控制; 门控循环单元; 互补集合经验模态分解

中图分类号: X593

文献标志码: A

DOI: 10.13637/j.issn.1009-6094.2022.0715

0 引言

随着交通量和车流密度的增加, 交通噪声已成为影响城市环境的主要污染源^[1], 其中重型运输车辆所产生的道路噪声是影响居民声环境的主要因素。我国《公路声屏障降噪效果检测方法》规定在道路干线两侧, 夜间噪声不得超过 55dB(A), 白天不得超过 70dB(A)^[2]; 研究表明超过 30% 居民的生活会受到道路噪声影响^[3], 而长时间暴露在噪声环境下可能会引发一系列的健康问题^[4]。

道路噪声主要是在车辆行使过程中, 由于车辆自身机械部件的振动、车体与空气间以及轮胎与道路间的摩擦所产生。针对降噪问题, 目前主要有被动式噪声控制技术 (Passive Noise Control) 和主动式噪声控制技术 (Active Noise Control) 两种解决方法^[5-6]。前者是利用声学材料或结构来消耗声波能量以实现噪声的抵消; 后者是利用杨氏干涉理论, 通过发出与实际初级声信号幅值频率相同、相位相反的噪声消除信号, 从而抵消初始噪声信号实现噪声控制^[7]。

自适应滤波算法是主动噪声控制技术的核心^[8]。由于主动噪声控制过程中自适应滤波算法的计算过程以及各元件的执行过程, 系统需要一定的响应时间。为尽量减少响应时间, 控制系统通常选择较为简单的自适应滤波算法进行计算。例如, 1959 年 Windrow 和 Hoff 等首次提出基于最小均方 (LMS) 自适应算法, 该算法具有计算简单、易于使用等优势^[9-11], 但该算法存在收敛速度和稳态误差相矛盾的问题^[12-13], 即在收敛系数的选取过程中, 较大的收敛系数带来更快收敛速度的同时也会产生更大的权矢量噪声, 进而导致失调量随之增大。因此, 控制器中选择简单的自适应滤波算法是通过牺牲计算精度换取了收敛速度的提升。此外, 由于传统主动式噪声控制系统中往往存在次级声反馈现象, 使得参考传感器采集的初级声信号存在一定的误差, 这将会对系统的稳定性带来巨大的影响^[7]。针对此种问题, 现有研究主要是通过对自适应滤波算法进行改进, 从而在确保收敛速度满足要求的同时降低稳态误差或在保持原有精度的同时提高其收敛速度。即使如此, 仍需考虑降低次级声反馈问题所带来的影响, 如反馈中和法是通过建立采用自适应滤波算法模型的补偿滤波器输出来抵消声反馈信号, 或通过引入与 IIR 滤波器契合的智能算法这一思想来解决声反馈问题^[7]。Khan 等^[14]基于自然启发烟花算法更新自适应 Volterra 滤波器参数的 ANC 控制器可降低稳态误差。George 等^[15]提出了一种基于函数链接型神经网络 (FLANN) 的多通道非线性有源噪声控制系统, 该系统采用一种适用于非线性噪声过程的粒子群优化算法训练。Zhao 等^[16]提出一种扩展流水线型二阶 Volterra 滤波器以及相应的非线性滤波算法, 从而提高非线性噪声控制的计算效率。聂永红等^[17]于 2012 年首次提出基于 EMD 与响度的有源噪声控制系统, 其通过 EMD 各分量的响度大小进行残差滤波器的设计, 从而降低对响度贡献较小的噪声成分的运算压力, 以此提高降噪效果。Chen 等^[18]于 2019 年首次提出相关 EMD 与 Chebyshev 滤波器组合的控制思想, 其利用 EMD 分解方法将噪声信号分解为多个分量, 根据各分量相关系数对输入信号进行筛选以此降低自适应控制器的运算压力, 并与

收稿日期: 2022-04-20

基金项目: 国家重点研发计划项目 (2017YFC070410702)

第一作者: 冯增喜 (1979-), 男, 陕西韩城, 博士, 副教授, 工学博士, 从事智慧城市、建筑智能化研究。

固定电话: +86-29-82203404, E-mail: fengzengxi2000@163.com

通讯作者: 韦娜 (1980-), 女, 陕西西安, 博士, 副教授, 工学博士, 从事建筑环境与建筑节能、人居环境研究。

固定电话: +86-29-82205431, E-mail: wn923@163.com

Chebyshev 滤波器进行组合, 从而实现收敛速度的提升。

为弥补滤波算法中稳态误差及收敛速度间的矛盾问题, 同时有效的避免出现次级声反馈现象, 本文提出一种新的解决思路, 即建立基于 CEEMD-GRU 的组合预测模型在噪声控制执行前为自适应控制器提供更加充足的准备, 通过该模型对道路噪声进行预测, 并将实时噪声替换为模型预测结果作为主动噪声控制系统的实际初级声信号, 一方面使得移动的噪声源在抵达噪声控制点时系统能够产生准确噪声消除信号, 从而为系统内自适应滤波算法的计算及执行过程提供更加充分的响应时间, 避免了主动噪声控制系统中自适应滤波算法在选择时存在收敛速度和稳态误差相矛盾的问题, 另一方面, 参考传感器也可与次级声源保持较大的距离, 能够有效的避免次级声反馈现象。试验表明, 本文所提方法具有良好的噪声预测效果, 能够为后续主动式噪声控制提供准确的输入。

1 基于 CEEMD-GRU 的道路噪声预测模型

在车辆行驶过程中引发噪声的因素极多, 在预测过程中, 若将所有因素都考虑在内, 会增加预测难度, 此外同一车辆所发出的噪声具有非平稳性以及非线性的特性, 易导致预测过程中误差的产生。CEEMD 分解方法能够充分提取非线性噪声序列的特征, 挖掘其隐含信息, 使用原始数据经 CEEMD 分解后的虚拟分量替代实际影响因素作为模型输入变量也可以在数据分析的过程中避免由于人为选定影响因素而对分析结果产生影响; 同时, 由于噪声片段采样率的大小直接影响了噪声序列数据的完整性, 为保证样本数据的准确性, 需在数据提取过程中尽可能提高采样率, 导致噪声序列数据维度较高, 选择 GRU 神经网络能够避免高维度序列数据在模型训练过程中出现梯度消失的情况, 从而使预测效果更加准确。

1.1 互补集合经验模态分解 (CEEMD)

经验模态分解 (empirical mode decomposition, EMD) 是 1998 年 Huang 等^[19]首次提出的一种处理信号的方法, 其理论上可将任何类型的信号分解为多个本征模态函数分量(F_{im})和一个残差分量(r), 并且针对非线性数据的处理具有非常明显的优势。但 EMD 在分解信号过程中易出现模态混叠现象, EEMD 在 EMD 的基础上添加白噪声使信号在不同的时间尺度具有连续性, 从而可以有效的抑制模态混叠现象^[20], 但由于 EEMD 分解过程中引入的白噪声存在的残余会对原始数据产生不良影响^[21], Yeh 等提出互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD), CEEMD 将引入的白噪声改为高斯正负白噪声, 从而可避免模态混叠现象的发生, 也不会对原始数据产生影响^[22-24]。CEEMD 算法分解步骤如下:

- 1) 对原始信号加入正、负成对的高斯白噪声, 得到新的信号

$$\begin{bmatrix} M_1 \\ M_2 \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} S \\ N \end{bmatrix} \quad (1)$$

式中: S 为原始数据; N 为白噪声; M_1 、 M_2 分别为添加正、负白噪声的原始信号。

- 2) 通过下式对 M_1 、 M_2 进行分解。

$$\begin{cases} H(t) = \sum_{j=1}^n c_j(t) + r(t) \\ c_j(t) = \frac{1}{\lambda} \sum_{i=1}^k c_{ij}(t) \end{cases} \quad (2)$$

式中: c_{ij} 为第 i 次加入白噪声分解后的得到的第 j 个本征模态函数分量; $c_j(t)$ 为 C_1 、 C_2 在第 j 个 F_{im} 分量的平均值; r 为残差分量; λ 为加入白噪声的次数。分解后得到 2 组 F_{im} 分量表示为 C_1 、 C_2 , 然后对每组分量对应的同一阶分量求平均值, 得到最终的分解结果 H 。

其中每一个 F_{im} 分量需满足以下要求:

- 1) 在整个数据集中, 极值数量和零交叉数量必须相等或最多相差 1;
- 2) 在任何一点上, 由局部最大值定义的包络线的平均值和由局部最小值定义的包络线的平均值都是 0。

1.2 GRU 神经网络

循环神经网络 (Recurrent Neural Network, RNN) 在处理短时序列方面优势明显, 但处理分析维度过高的时序序列时易出现梯度消失情况。对此, Sepp 等^[25]提出了长短期记忆 (long short-term memory, LSTM) 神经网络, 通过设置输入门、遗忘门和输出门单元实现时序的记忆可控, 有效的解决了梯度消失问题。但 LSTM 神经网络结构复杂, 训练时间过长^[26], 因此, Cho 等^[27]提出门控循环单元 (gated recurrent unit, GRU) 神经网络。GRU 将 LSTM 的 3 个门控单元结构简化为重置门和更新门 2 个门控单元结构, 不存在单独的存储单元, 极大的简化了模型, 提高了收敛速度, 在保留了 LSTM 神经网络优点的同时提高了样本训练效率。GRU 模块结构如图 1 所示。

GRU 模块门控更新公式为:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (3)$$

$$\tilde{h}_t = \tanh(W_h[r_t * h_{t-1}, x_t]) \quad (4)$$

$$z_t = \sigma(W_z[h_{t-1}, x_t]) \quad (5)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (6)$$

$$y = \sigma(W_o \cdot h_t) \quad (7)$$

式中： r_t 和 z_t 分别为重置门和更新门； \tilde{h}_t 、 h_t 、 y 分别为当前记忆状态、单元输出系统状态、预测值的计算规则； σ 、 \tanh 分别为Sigmoid激活函数和双曲正切函数， W_r 、 W_z 、 W_h 、 W_o 为对应权重矩阵。

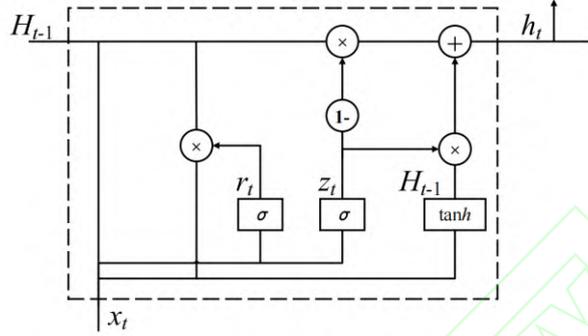


图 1 GRU 模块结构图

Fig.1 GRU module structure diagram

1.3 基于 CEEMD-GRU 的预测模型

为了对噪声序列进行更加精准的预测，从而为主动噪声控制提供准确的输入声信号，本文提出基于 CEEMD-GRU 的道路噪声预测算法。首先，该模型能够利用 CEEMD 分解方法处理非线性信号的优势，将数据分解为不同特征尺度的多个子分量，从而将各分量间的影响降低，减小预测过程的难度并降低误差；其次，利用 GRU 神经网络的记忆能力使得模型在训练过程中，能够充分学习噪声序列数据信息，从而使得预测噪声数据能够代替真实噪声数据作为主动式噪声控制的输入信号。模型构建流程如图 2 所示，具体步骤如下，

步骤 1：获取两测量点多组噪声音频；

步骤 2：对噪声音频进行采样，得到噪声样本数据；

步骤 3：为便于后续模型训练，将样本数据进行归一化处理得到测点一噪声序列 X ，以及测点二噪声序列 Y ；

步骤 4：通过 CEEMD 分解方法将噪声序列 X 进行平稳化处理，以深度挖掘数据隐含的波动信息，得到多个子分量 $F_{im1}, F_{im2}, \dots, F_{imn}$ ，以及残差分量 r ；

步骤 5：将多个子分量重组为 GRU 神经网络输入数据 $[F_{im1}, F_{im2}, \dots, F_{imn}, r]^T$ ，与测点二噪声序列 Y 共同划分为训练集与测试集，划分比例为训练集：测试集=49：1；

步骤 6：以 $[F_{im1}, F_{im2}, \dots, F_{imn}, r]^T$ 作为 GRU 神经网络输入，以 Y 作为 GRU 神经网络输出，进行多输入单输出的 GRU 神经网络训练，利用 GRU 神经网络的记忆能力充分训练噪声序列；

步骤 7：满足模型训练收敛条件后得到基于 CEEMD-GRU 道路噪声预测模型。

所构建 CEEMD-GRU 预测模型网络结构如图 3 所示，该模型主要包括 CEEMD 算法以及 GRU 神经网络，GRU 神经网络包含输入层、GRU 层、dropout 层、全连接层、输出层。其中 CEEMD 算法的作用是测点一样本数据 X 经 CEEMD 分解后得到 n 个本征模态分量以及一个残差分量。GRU 神经网络中，输入层数据集 $[F_{im1}, F_{im2}, \dots, F_{imn}, r]^T$ 由利用 CEEMD 算法分解的 n 个本征模态分量和残差分量所组成；GRU 层的神经元个数根据数据规模确定，若需要多个 GRU 层可依次叠加；dropout 层的主要作用是缓解模型训练过拟合现象，该层置于每个 GRU 层后，通常将 dropout 率设置为 0.5^[28]；输出层为测点二的预测值。

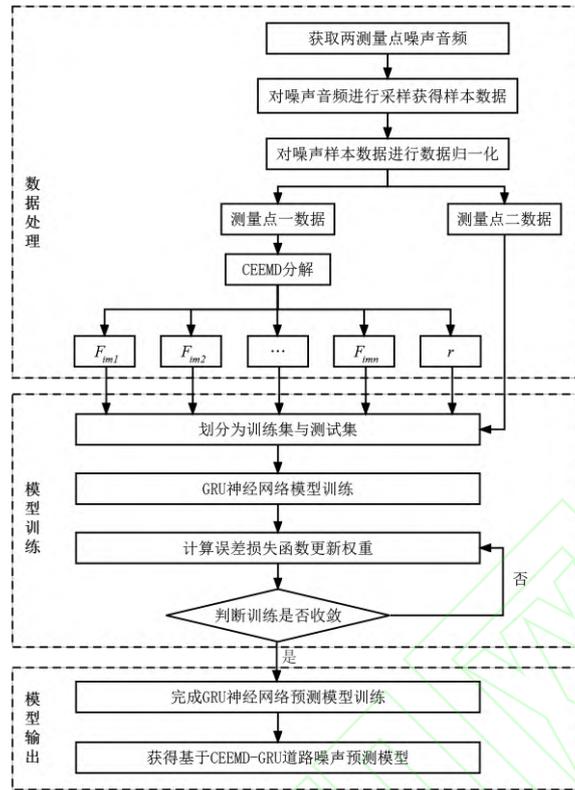


图 2 基于 CEEMD-GRU 的道路噪声预测模型构建流程

Fig.2 Construction of road noise prediction model based on CEEMD-GRU

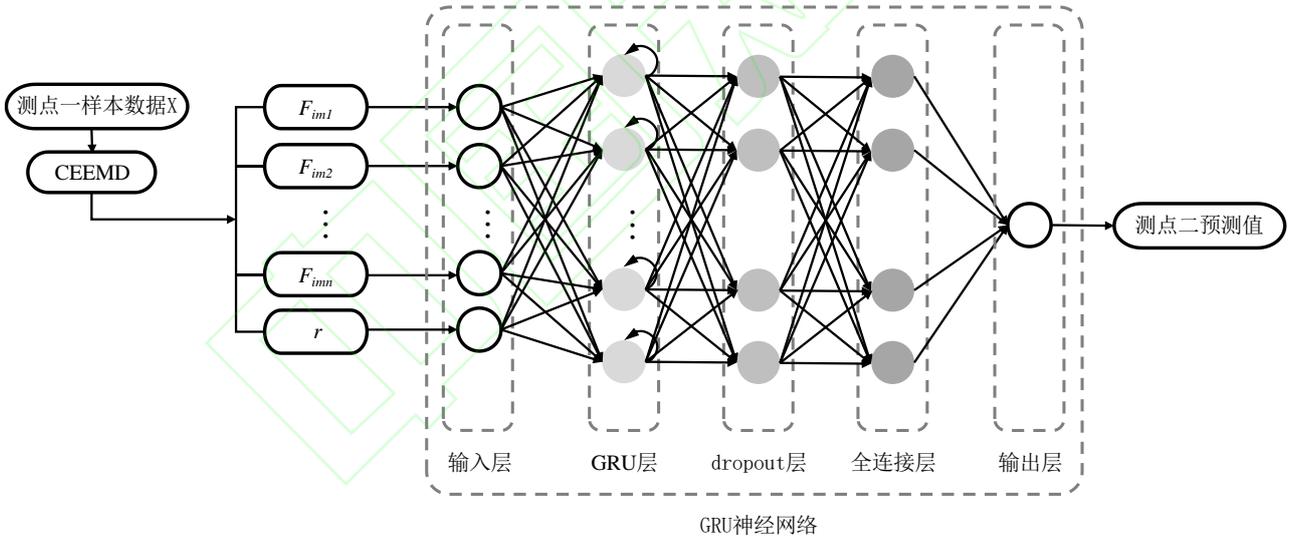


图 3 CEEMD-GRU 预测模型网络结构图

Fig.3 CEEMD-GRU neural network structure diagram

2 试验

2.1 数据来源

本研究主要针对车辆噪声严重影响沿街居民生活质量这一问题，选取西安市郊区某公路作为试验场地，对车辆噪声进行实地采集试验。试验车型为 3 台 MAXUS V80 型号货车，试验场景布置如图 4 所示，传统道路声屏障与路沿距离约为 0.5m，因此该试验两测点亦设置于距离公路路沿垂直距离 0.5m 处，两测点均设置带有区域侦测模块的 HIKVISION DS-2CD5A24FWD-IZS 摄像机并通过音频接口与 Beyerdynamic MM1 音频信号采集设备连接，同时为避免所采集数据中出现其他车辆噪声影响，根据该音频信号采集设备最远收音距离为 6m，将两测点间距离设置为 50m，并设置两测点音频信号采集路段为 AB 路段和 CD 路段，A、B 与 C、D 分别位于测点一和测点二两侧 15m 处，试验过程中 AD 路段内除试验车辆外

无其他噪声源。

以测点一为例，其数据采集过程为：试验开始前将摄像机区域侦测模块触发区域设置为 AB 路段，试验车辆驶入采集路段 AB 前启动定速巡航功能确保采集过程中车速恒定，当试验车辆到达 A 点，触发摄像机内置的区域侦测模块产生脉冲信号启动音频信号采集设备，当试验车辆到达 B 点，触发摄像机内置的区域侦测模块产生脉冲信号关闭音频信号采集设备，测点二采集过程同上，至此一组音频数据采集过程结束，控制试验车速由 30km/h 至 50km/h 逐次递增 1km/h 各进行 3 次采集。试验最终采集次数为 63 次，筛出受到其他因素干扰导致的异常数据，有效数据 50 组，每组数据包含测点一及测点二 WAV 格式音频各一段，随机抽取一组采集数据展示如图 5 所示。

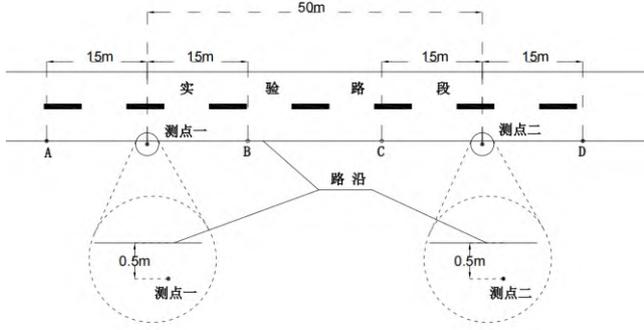


图 4 试验场景布置图

Fig.4 Experimental scene layout

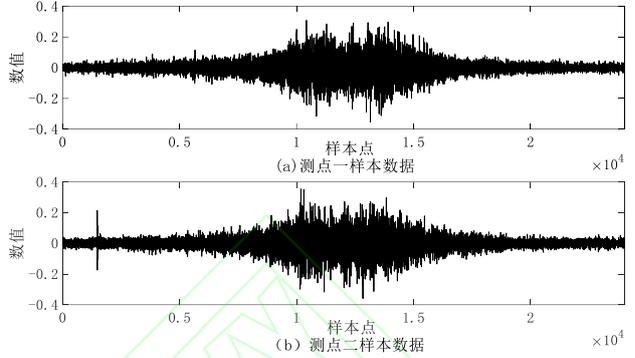


图 5 两测点道路噪声声波序列

Fig.5 Acoustic sequence of road noise at two measuring points

2.2 数据预处理

以 6000Hz 采样率对 50 组 WAV 音频文件进行数据采样，将噪声数据由模拟数据转化为离散数据，并对其进行归一化处理，为保证后续模型训练的连续性，将各组数据进行连接，获得测点一、测点二各 8×10^5 个样本点数据，由于摄影机设备区域侦测模块响应时间为 1×10^{-5} s，而以 6000Hz 进行采样后各样本点时间间隔为 1.67×10^{-4} s，故能够确保每组试验中两测点样本数据一一匹配。

2.3 评价指标

本文选择以下 3 个指标评估模型的准确性：

(1) 平均绝对误差 E_{MA} ，该评价指标能够准确反映预测模型的误差大小，即 E_{MA} 值越小则代表模型预测效果越好，表达式：

$$E_{MA} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (8)$$

(2) 均方根误差 E_{RMS} ，该评价指标能够反映预测值与实际值之间的差异程度，即 E_{RMS} 值越小则代表模型预测效果越好，表达式：

$$E_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (9)$$

(3) 拟合优度 R^2 ，该评价指标能够反映预测值与实际值曲线的拟合程度，即 R^2 越高则代表模型预测效果越好，表达式：

$$R^2 = 1 - \frac{\sum_i (\hat{y}_i - y_i)^2}{\sum_i (\bar{y} - y_i)^2} \quad (10)$$

(8) ~ (10) 式中： n 为数据总数； y_i 为实际数据值； \hat{y}_i 为预测数据值； \bar{y} 为实际数据均值。

2.4 CEEMD 分解过程

经数据预处理后可获得测点一及测点二两组数据量相同的时间序列，如 5 图所示，当车辆靠近时，噪声原始数据系列存在较大的波动性，且波动频率和振幅未呈现明显规律性变化，具有较高非平稳、非线性特征，难以有效的对该序列数据进行预测，故先采用 CEEMD 的方法对原始噪声数据进行处理，以充分提取原始数据特征。图 6 为测量点一处部分噪声原始数据经 CEEMD 分解后得出的 13 个 F_{im} 分量以及 1 个 r 残差分量，数据分解可将原始噪声数据转换为平稳性好且规律性高、低频分量，通过以虚拟分量代替可能影响噪声的外界因素作为 GRU 神经网络模型预测输入，将测点二噪声数据作为 GRU 神经网络预测输出构建模型，确保模型在训练过程中充分学习数据中的信息。

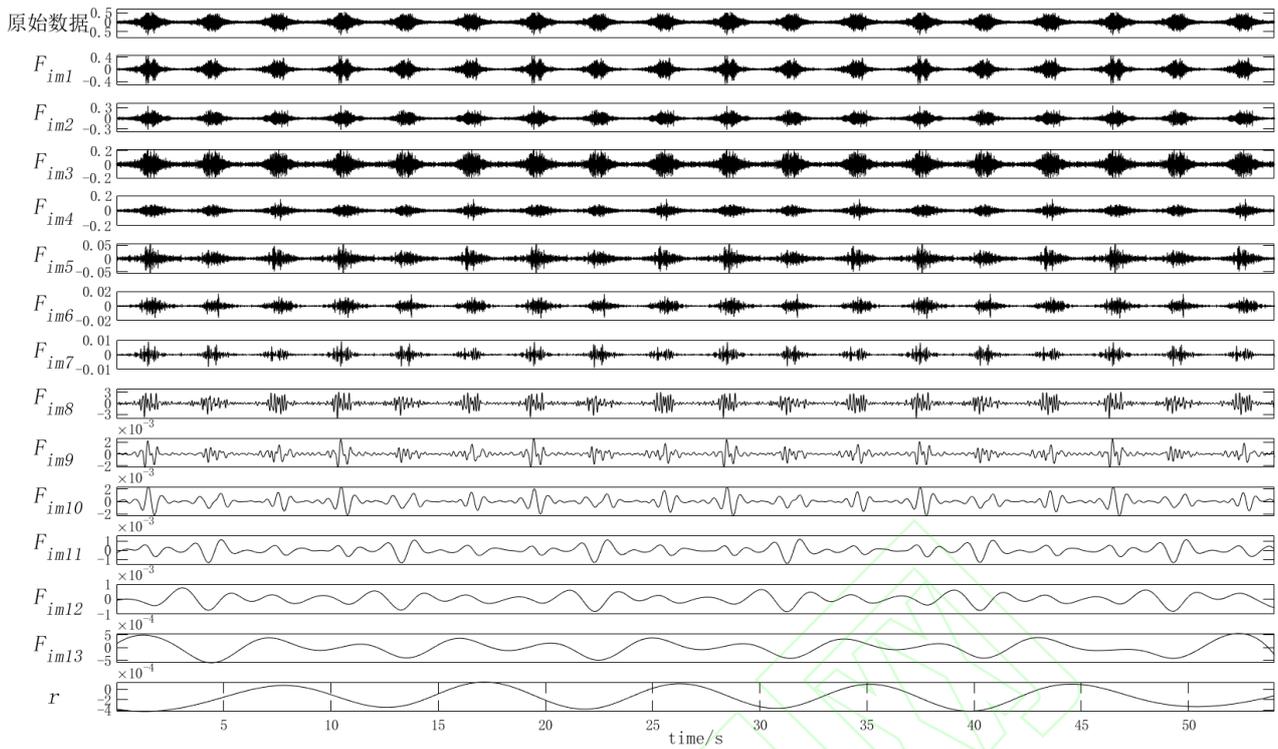


图 6 噪声序列数据 CEEMD 分解图

Fig.6 CEEMD decomposition diagram of noise sequence data

2.5 模型训练过程

为验证该模型性能，将本文所提预测模型与 BP 神经网络模型、GRU 神经网络模型、EMD-GRU 模型进行对比分析，各模型训练过程说明如下：

(1) 为充分训练模型的同时能够对模型训练效果进行观测，将测点一、测点二处音频文件经采样及归一化处理后所得噪声序列 X 、 Y 以及测点一经采样、归一化和 CEEMD 处理后的 $[F_{im1}, F_{im2}, \dots, F_{imn}, r]^T$ 均按照训练集：测试集=49：1 进行划分，经 K-fold 交叉验证方法对该划分比例进行检验后确定该划分比例合理；

(2) 本文所提模型经过多次试验调参，最终确定本文神经网络结构为 1 个输入层、3 个 GRU 层、1 个 dropout 层、1 个全连接层以及 1 个输出层；

(3) 根据 CEEMD 分解后数据维度设置本文所提模型，输入层神经元个数为 14，输出层神经元个数为 1。此外，设置 EMD-GRU 模型输入层神经元个数为 14，输出层神经元个数为 1，BP 神经网络模型及 GRU 神经网络模型输入层神经元个数为 1，输出层神经元个数为 1，并且通过网格搜索法确定各个模型训练次数及隐藏层神经元个数，如表 1 所示；

(4) 所有对比模型在训练过程中均采用 Adam 优化器，设置全局学习率为 0.9，最小学习率为 0.0005，距估计指数衰减速率 β_1 和 β_2 分别为 0.9 和 0.999^[29]。

表 1 本文模型与 BP、GRU、EMD-GRU 模型超参数取值

Table 1 Comparison of prediction and evaluation indexes between this model and GRU and EMD-GRU models

| 预测模型 | 超参数 | 搜索范围 | 超参数取值 |
|-----------|----------|-----------------------|-------|
| BP | 训练次数 | [50,100,150,200,300] | 50 |
| | 隐藏层神经元个数 | [10,20,40,70,100,150] | 20 |
| GRU | 训练次数 | [50,100,150,200,300] | 100 |
| | 隐藏层神经元个数 | [10,20,40,70,100,150] | 100 |
| EMD-GRU | 训练次数 | [50,100,150,200,300] | 150 |
| | 隐藏层神经元个数 | [10,20,40,70,100,150] | 70 |
| CEEMD-GRU | 训练次数 | [50,100,150,200,300] | 150 |
| | 隐藏层神经元个数 | [10,20,40,70,100,150] | 70 |

3 分析与讨论

为验证该模型性能，将所提预测模型与 BP 神经网络模型、GRU 神经网络模型、EMD-GRU 模型进行对比分析，图 7 为各模型于测试集共 16000 个样本数据的预测效果包络线图，该图仅能够观测各模型的预测效果的幅值变化趋势。由于测试集数据量较大，为能够更加精确观测预测效果以及误差情况，选取了采集过程中车辆初步进入测点设备有效范围[3950,4000]、车辆抵达测点处[7950,8000]以及车辆驶离音频采集设备有效范围[12950, 13000]三个区间噪声预测效果与样本数据进行局部放大展示，如图 8 所示，以上三个阶段可观测噪声幅值突变、噪声幅值达到最值、噪声幅值趋于平稳三种情况下该模型的预测效果。

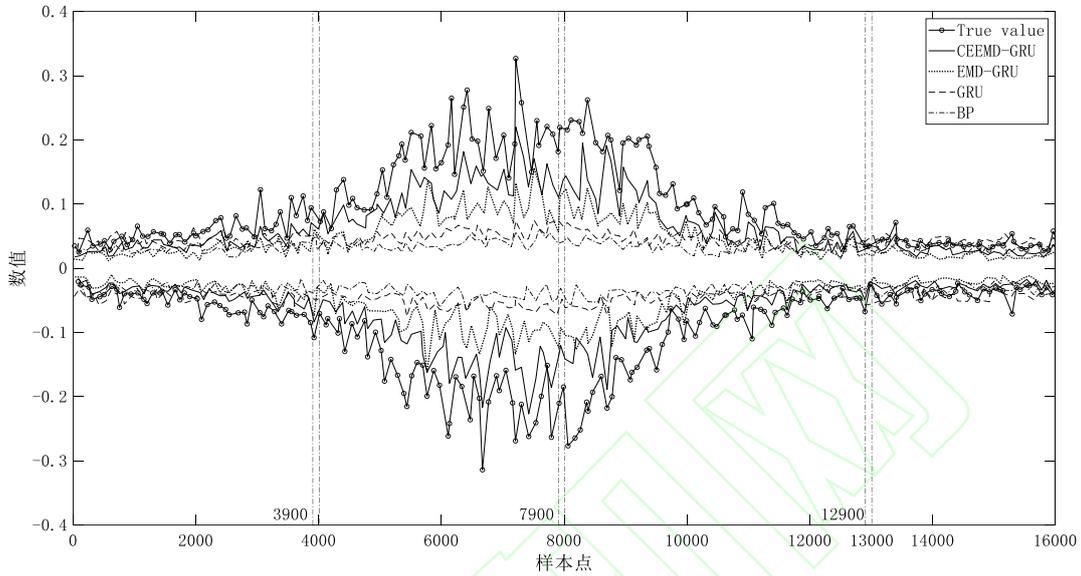


图 7 GRU 神经网络预测效果包络线图

Fig.7 Prediction effect diagram of GRU neural network

如图 7 所示在所有模型中，BP 模型整体预测效果最差，GRU 模型其次，在车辆驶过测量点过程中，噪声真实值振幅呈现由小到大再到小的变化，但 BP 及 GRU 模型始终在同一范围波动，完全无法跟踪噪声波动的变化趋势；而 EMD-GRU、CEEMD-GRU 能够在整个过程中呈现与真实值相似波动趋势，其中本文所提模型平均振幅与真实值平均振幅差距更小。

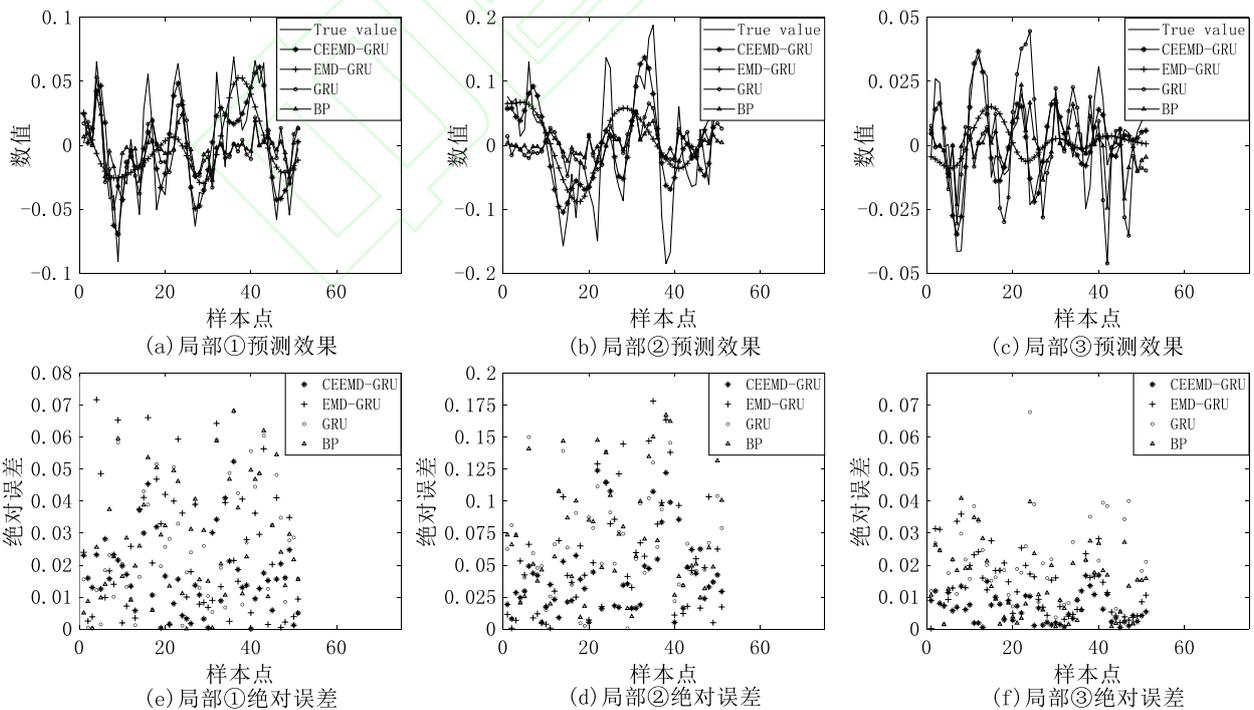


图 8 BP、GRU、EMD-GRU、CEEMD-GRU 预测效果局部对比图

Fig.8 Local comparison of prediction effects of BP, GRU, EMD-GRU and CEEMD-GRU

如图 8(a)、(b)、(c)三子图所示,加入模态分解后的 EMD-GRU 模型较 GRU 模型而言大部分数据均能够呈现与实际数据相似的波动变化,但在噪声数据振动频率较高时无法达到与噪声真实值同一水平的振动频率,无法完全跟随真实值变化趋势;与前三种预测模型相比较,本文所提模型能够实现更加充分跟踪数据整体波动变化趋势,呈现出最佳的预测效果。同时,如图 8 中(d)、(e)、(f)三子图所示,在噪声振幅由小变大、振幅较大、振幅较小三个时期,本文所提模型绝对误差低于其他三种模型,故本文所提模型预测的准确度较其他模型更高。

为定量评价多种模型预测性能,利用 2.3 所提三个评价指标对预测结果进行分析,如表 2 所示,本文所提模型绝对平均绝对误差 E_{MA} 较 BP 模型、GRU 模型、EMD-GRU 模型分别降低 61.2%、55.0%、42.9%;均方根误差 E_{RMS} 较 BP 模型、GRU 模型、EMD-GRU 模型分别降低 41.4%、34.9%、23.4%, R^2 较 BP 模型、GRU 模型、EMD-GRU 模型分别提升 89.1%、47.9%、18.4%。

表 2 本文模型与 BP、GRU、EMD-GRU 模型预测评价指标对比

Table 2 Comparison of prediction and evaluation indexes between this model and BP and GRU and EMD-GRU models

| 预测模型 | E_{MA} | E_{RMS} | R^2 |
|---------|----------|-----------|--------|
| BP | 0.0492 | 0.0526 | 0.3115 |
| GRU | 0.0425 | 0.0473 | 0.3982 |
| EMD-GRU | 0.0329 | 0.0402 | 0.4976 |
| 本文模型 | 0.0191 | 0.0308 | 0.5892 |

本研究的根本目的在于准确地预测噪声,为后续噪声控制的执行提供更为充足的前期准备,从而提高主动式噪声控制的效果,缓解日益严重的城市交通噪声污染问题,故噪声预测的准确度将直接影响到后续噪声控制的效果,由上述结果分析可知,所提预测模型通过 CEEMD 分解方法和 GRU 神经网络的结合,能够充分提取交通噪声序列的特征,进一步提高预测准确度,实现对道路噪声的预测,在噪声源经过测量点过程中的各个时期较其他模型均呈现更佳的预测效果。接下来为达到提升噪声控制效果这一最终目的,还需针对以下方面进行进一步研究:

- (1) 目前本研究只针对单车行驶所产生的交通噪声,尚未考虑多车辆所产生噪声的叠加情况,为进一步贴近实际情况,在未来的研究中将会把多车辆行驶过程中所产生噪声的叠加情况纳入考虑范围。
- (2) 下一步研究会将该道路噪声预测模型与主动式噪声控制技术结合为完整体系,并验证其噪声控制效果。

4 结论

(1) 本文利用预测模型对道路噪声进行预测,用预测声信号代替实际初级声信号作为主动式噪声控制技术中的输入,在避免次级声反馈问题发生的同时,为控制器提供更多的响应时间,降低了滤波算法对收敛速度的要求。针对主动式噪声控制技术中传统滤波算法存在的收敛速度与稳态误差相矛盾这一问题,提出了一种新的解决思路,能够为主动式噪声控制的执行提供更加充足的前期准备。

(2) 由于交通噪声时间数据序列具有显著的非线性、非平稳特征,使用单一的预测模型对其预测精度较低,本文通过将互补集合经验模态分解方法与门控循环神经网络相结合的方法构建预测模型,并对交通噪声数据进行预测。通过以上实例对模型精度进行验证,结果表明本文所提模型较 BP 神经网络模型、GRU 神经网络模型、EMD-GRU 组合预测模型均呈现更佳的预测效果。

参考文献

- [1] 丁真真,赵剑强,陈莹,等. 公路交通噪声源强预测模型研究进展[J]. 安全与环境学报, 2014, 14(4): 280-284.
DING Z Z, Zhao J Q, Chen Y. et al. Research advance review of the highway traffic noise Source and its intensity evaluation model[J]. Journal of Safety and Environment, 2014, 14(4): 280-284.
- [2] 中华人民共和国交通运输部行业标准公路声屏障降噪效果检测方法: JT/T 646.5-2017[S]. 中华人民共和国交通运输部; 2017.
Detection method of noise reduction effect of highway sound barrier: JT/T 646.5-2017[S]. Ministry of Transport of the People's Republic of China; 2017.
- [3] ALEXANDER A, EL-AASSAR A, MACDONALD J, et al. Technical approaches to developing a highway noise programmatic agreement[J]. Transportation Research Record, 2019, 2673(1): 102-109.
- [4] 宋立忠,李小珍,张良涛,等. 城市轨道交通桥梁-声屏障系统结构噪声特性与预测[J]. 交通运输工程学报, 2021, 21(3): 193-202.
SONG L Z, LI Z Z, ZHANG L T, et al. Characteristics and prediction of structure-borne noise from urban rail transit bridge-sound barrier system[J]. Journal of Traffic and Transportation Engineering, 2021, 21(3): 193-202.

- [5] 张振华,郭春,郑鑫,等. 公路隧道内噪声控制技术[J]. 现代隧道技术, 2018, 55(S2): 1015-1019.
ZHANG Z H, GUO C, ZHENG X. et al. Research on noise control techniques in highway tunnels[J]. Modern Tunnelling Technology, 2018, 55(S2): 1015-1019.
- [6] 陈琪. 基于智能算法的车内路噪多通道主动控制技术研究[D]. 吉林: 吉林大学, 2020.
Chen Q. Research on multi-channel active control of road noise inside vehicles based on intelligent algorithm[D], Jilin: Jilin University, 2020.
- [7] 陈克安. 有源噪声控制[M]. 北京: 国防工业出版社, 2014. 1-3.
Chen K A. Active noise control[M]. Beijing: National Defense Industry Press, 2014. 1-3.
- [8] 叶朋,张东洋,李广剑,等. 基于改进 LMS 算法的引信自适应去噪声研究[J]. 火力与指挥控制, 2020, 45(10): 63-66.
YE P, ZHANG D Y, Li G J, et al. Adaptive noise cancellation in fuze based on the improved LMS algorithm[J]. Fire Control and Command Control, 2020, 45(10): 63-66.
- [9] 张中华,张瑞金. 一种新的变步长 LMS 自适应滤波算法及性能分析[J]. 系统工程与电子技术, 2009, 9(9): 2238-2241.
ZHANG Z H, ZHANG R J. New variable step size LMS adaptive filtering algorithm and its performance analysis[J]. Systems Engineering and Electronics, 2009, 9(9): 2238-2241.
- [10] 叶华,吴伯修. 变步长自适应滤波算法的研究[J]. 电子学报, 1990, 18(4): 63-69.
YE H, WU B X. The study on a variable step size adaptive filtering algorithm[J]. Acta Electronica Sinica, 1990. 18(4): 63-69.
- [11] 卢炳乾,冯存前,龙戈农. 一种基于正弦函数的归一化变步长 LMS 算法[J]. 无线电工程, 2014, 44(3): 2-23.
LU B Q, FENG C Q, LONG G N. A normalized variable step-size LMS algorithm based on sine function[J]. Radio Engineering, 2014, 44(3): 2-23.
- [12] 曾伟,吴国辉,代冀阳,等. LMS 自适应滤波算法的改进及性能分析[J]. 计算机仿真, 2011, 28(4): 111-114.
ZENG W, WU G H, DAI J Y, et al. LMS adaptive filtering algorithm improvement and performance analysis[J]. Computer Simulation, 2011, 28(4): 111-114.
- [13] SRISTI P, LU W S, ANTONIOU A. A new variable-step-size LMS algorithm and its application in subband adaptive filtering for echo cancellation[C]// The 2001 IEEE International Symposium on Circuits and Systems. IEEE, 2001. 721-724.
- [14] KHAN W U, YE Z F, ALTAFF F. A novel application of fireworks heuristic paradigms for reliable treatment of nonlinear active noise control[J]. Applied Acoustics, 2019, 146(3): 246-260.
- [15] GEORGE N, PANDA G. A particle-swarm-optimization based decentralized nonlinear active noise control system[J]. IEEE Transactions on Instrumentation and Measurement, 2012, 61(12): 3378-3386.
- [16] ZHAO H, ZENG X, ZHANG X, et al. Adaptive extended pipelined second-order volterra filter for nonlinear active noise controller[J]. IEEE Transactions on Audio Speech and Language Processing, 2012, 20(4): 1394-1399.
- [17] 聂永红,程军圣,张亢,等. 基于 EMD 与响度的有源噪声控制系统[J]. 仪器仪表学报, 2012, 33(4): 801-808.
NIE Y H, CHENG J S, ZHANG K, et al. Active noise control system based on EMD and loudness[J]. Chinese Journal of Scientific Instrument, 2012, 33(4): 801-808.
- [18] CHEN B, YU S Y, GUO R R. Nonlinear active noise control system based on correlated EMD and Chebyshev filter[J]. Mechanical Systems and Signal Processing, 2019, 130: 74-86.
- [19] HUANG N, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society A Mathematical Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [20] VROCHIDOU E, ALVANITOPOULOS P, ANDREADIS I, et al. Artificial accelerograms composition based on the CEEMD[J]. Transactions of the Institute of Measurement and Control, 2018, 40(1): 239-250.
- [21] 赵征,汪向硕. 基于 CEEMD 和改进时间序列模型的超短期风功率多步预测[J]. 太阳能学报, 2020, 41(7): 352-358.
ZHAO Z, WANG X S. Ultra-short-term multistep wind power prediction based on CEEMD and improved time series model[J]. Acta Energiae Solaris Sinica, 2020, 41(7): 352-358.
- [22] YE H J, SHIEH J S, HUANG N E. Complementary ensemble empirical mode decomposition: a novel noise enhanced data analysis method[J]. Advances in Adaptive Data Analysis, 2010, 2(2): 135-156.
- [23] 丁家乐,陈国初,原阔. 基于改进萤火虫算法的短期风功率预测[J]. 系统仿真学报, 2019, 31(11): 2509-2516.
DING J L, CHEN G C, YUAN K. Short-term wind power prediction based on improved firefly algorithm[J]. Journal of System Simulation, 2019, 31(11): 2509-2516.
- [24] 乐友喜,杨涛,曾贤德. CEEMD 与 KSVD 字典训练相结合的去噪方法[J]. 石油地球物理勘探, 2019, 54(4): 729-736.

- LE Y X, YANG T, ZENG X D. Seismic denoising with CEEMD and KSVD dictionary combined training[J], Oil Geophysical Prospecting, 2019, 54(4): 729-736.
- [25] HOCHREITER S, SCHMIDHUNBER J. Long short-term memory[J], Neural Computation, 1997, 9(8): 1735-80.
- [26] GRAVES A, MOHANMED A R, HINTON G. Speech recognition with deep recurrent neural networks[C]//2013 IEEE International Conference on Acoustics, Speech, and Signal Processing, May 26-31, 2013, Vancouver, BC, Canada, New York: IEEE Xplore, 2013:6645-6649.
- [27] CHO K, MERRLENBOER B V, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]. Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, October 25-29, 2014, Doha, Qatar: Association for Computational Linguistics, 2014: 1724-1.
- [28] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting[J]. The Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [29] 高翔, 李国玉, 撒奥洋, 等. 基于 Adam 算法优化 GRU 神经网络的短期负荷预测模型[J]. 电子设计工程, 2022, 30(9): 180-183+188.
- GAO X, LI G Y, HAN A Y, et al. Short-term load forecasting model based on Adam algorithm to optimize GRU neural network[J]. Electronic Design Engineering, 2022, 30(9): 180-183+188.

Road noise prediction model with CEEMD-GRU combination

FENG Zeng-xi¹, CUI Wei¹, HE Xin¹, ZHAO Jin-tong¹, SUN Xin¹, ZHANG Mao-qiang¹, YANG Yun-yun¹, WEI Na²

(1. School of Building Services Science and Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China; 2. Academy of Arts, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: A road noise prediction model (CEEMD-GRU) based on the combination of complementary ensemble empirical mode decomposition (CEEMD) and gated recurrent unit (GRU) was proposed to reduce the requirements on the convergence performance of the filtering algorithm in the traditional active noise control method and solve the secondary acoustic feedback in the control process, provide more adequate preparation for the subsequent active noise control. Firstly, the model decomposes the input noise signal sequence into multiple eigenmode function components and a residual component based on the CEEMD algorithm to deeply mine the fluctuation information implicit in the data. Secondly, the multiple input noise sequence eigenmode function components decomposed by the CEEMD algorithm and the output noise sequence were used to construct the CEEMD-GRU neural network noise prediction model. Finally, based on the noise data collected from a road section in Xi'an, the validity of the model is verified and analyzed, and the prediction effects of various models are compared. The experimental results show that the average absolute error E_{MA} of the prediction results of the model is 0.0191, which is respectively 61.2%, 55.0% and 42.9% lower than that of the BP neural network model, the GRU neural network model and the EMD-GRU combined prediction model; the root mean square error E_{RMS} is 0.0308, which is respectively 41.4%, 34.9%, and 23.4% lower than the BP neural network model; the R^2 of the prediction results of the model is 0.5892, which is respectively 89.1%, 47.9% and 18.4% higher than that of the BP neural network model, the GRU neural network model and the EMD-GRU combined prediction model. The GRU neural network model, and the EMD-GRU neural network model. Therefore, this model can show better prediction effect than BP neural network model, GRU neural network model and EMD-GRU combined prediction model, the predicted acoustic signal can replace the actual primary acoustic signal of the adaptive controller in active noise control, which is an active. The control execution process of the noise control provides a more sufficient response time and effectively avoids the secondary acoustic feedback phenomenon, which provides more sufficient response time for the control execution process of active noise control, and effectively avoids the phenomenon of secondary acoustic feedback.

Key words: environmental engineering; noise and vibration Control; noise prediction; active noise control; GRU; CEEMD

CLC number: X593

Document code: A