

基于 VMD-Seq2seq 模型的扬声器短期寿命预测研究

李天宇 周静雷 李佳斌

(西安工程大学电子信息学院 西安 710600)

摘要:随着音频载体设备的发展,扬声器在向着体积小、功率大的趋势发展,长时间工作在大信号驱动时音圈发热严重,会出现音圈断路等热损坏问题,通过对扬声器电参量数据的预测,可以降低功放功率等方法保护音圈,延长使用寿命。针对功率试验中扬声器电参量数据的时序特性,提高预测准确率,提出一种基于变分模态分解(variational mode decomposition, VMD)和编解码器(sequence to sequence, Seq2seq)模型的扬声器电参量多步预测方法。该方法首先使用 VMD 将原始数据进行分解,降低数据的非平稳性,利用分解后的数据构建训练集并使用 Seq2seq 网络模型进行训练和多步预测。仿真结果表明,所提出的预测模型在单步预测情况下,模型评价指标均方根误差(RMSE)为 0.044、平均绝对百分比误差(MAPE)为 0.15%、决定系数(R^2)为 0.94,在五步预测的情况下,模型评价指标 RMSE 为 0.05、MAPE 为 0.17%、 R^2 为 0.92,均优于其余对比模型,表明所提出模型的精度更高。

关键词:变分模态分解;Seq2seq 模型;动圈式扬声器;多步预测

中图分类号: TN912 **文献标识码:** A **国家标准学科分类代码:** 510.1050

Prediction of speaker residual life based on VMD-Seq2seq model

Li Tianyu Zhou Jinglei Li Jiabin

(School of Electronic Information, Xi'an Polytechnic University, Xi'an 710600, China)

Abstract: With the development of audio carrier equipment, the loudspeaker in the trend of small volume, large power development, long time working in large signal drive when the voice coil heating serious, there will be a voice coil break and other thermal damage problems, through the prediction of the loudspeaker electrical parameters data, can reduce the power amplifier power and other methods to protect the voice coil, prolong the service life. Aiming at the time sequence characteristics of electrical parameter data of loudspeaker in power test, the prediction accuracy is improved. A multi-step prediction method for loudspeaker electrical parameters is proposed based on variational mode decomposition(VMD) and sequence to sequence(Seq2seq) model. First, VMD is used to decompose the original data to reduce the non-stationarity of the data. Then, the decomposed data is used to build a training set and the Seq2seq network model is used for training and multi-step prediction. The simulation results show that in the case of single step prediction, the model evaluation index RMSE is 0.044, MAPE is 0.15%, R^2 is 0.94, and in the case of five-step prediction, the model evaluation index RMSE is 0.05, MAPE is 0.17%, R^2 is 0.92, all of which are better than other comparison models. It shows that the accuracy of the proposed model is higher.

Keywords: variational modal decomposition; Seq2seq model; dynamic coil loudspeaker; multistep prediction

0 引言

近年来智能手机和互联网电视等设备快速发展,这使得市场对专业扬声器需求增长。智能手机、音响中的扬声器单元受限于体积因素,在大信号驱动的状态下,其内部

音圈高温会造成零件出现程度不一的退化,进而产生音圈断路、开路 and 脱胶等热损坏问题,对扬声器电参量进行短时预测可以提前调整功放功率输出,有效的提高扬声器的使用寿命。

目前针对扬声器单元寿命分析有基于物理模型的预测方法。物理模型的方法主要有有限元法和加速模型法,但是有限元法十分依赖模型、参数设置和材料属性的准确性,加速模型法只考虑了温度因素的影响,但是实际使用中还存在电参数、湿度等特性的影响^[1]。近年来基于数据驱动的预测方法被广泛的应用于各领域的预测研究中,其中以自回归平均模型(autoregressive integrated moving average, ARIMA)^[2]、卡尔曼滤波(Kalman filtering)^[3]、支持向量回归(support vector regression, SVR)^[4-5]和长短时记忆网络(long short term memory, LSTM)^[6-8]为代表,实现了通过采集的各种监测数据进行后续预测。Yu等^[9]提出了一种基于多维传感器数据的剩余寿命预测模型,融合了卷积神经网络(convolutional neural network, CNN)提取空间特征、LSTM网络提取时间特征的优点,并成功应用到航空发动机数据集中。Wang等^[10]结合CNN与双向长短时记忆网络(bi-directional long short-term memory, BiLSTM),建立了基于风速、舵角等多维度数据融合输入的船舶横摇运动预测模型。邢红涛等^[11]提出了一种基于CNN-LSTM的混合神经网络预测模型,通过CNN网络构建特征向量,再由LSTM网络进行预测,精度优于单一LSTM模型。但是以上方法在处理高度非线性数据和多变量数据输入时,不能有效的处理时间序列数据间的长时间依赖关系。李振鹏等^[12]使用编解码器(sequence to sequence, Seq2seq)模型对输电母排触电温度进行预测,相对于其他传统的模型具有较高的精度。Xiang等^[13]将Seq2seq模型应用于降雨量-径流量关系的回归问题中,得到了较好的精度。上述算法在一定程度上取得了效果,但是其内核均使用LSTM网络,LSTM网络能够很好的提取数据的时序特征,但是难以处理其空间特征。

扬声器单元工作时,由于噪声等外部因素的影响,其电参量数据具有明显的波动性且变化趋势较为固定,从实际需求出发,扬声器电参数更关注其整体变化趋势,直接使用预测模型进行多步预测存在精度较低的问题。近年来信号分解方法多被用于各种预测模型中,作为预测模型的数据前处理,对原模型的预测精度有较好的提升^[14-16]。向玲等^[17]考虑了变分模态分解(variational mode decomposition, VMD)后的残余分量也包含有风速变化趋势的特征,利用信号分解方法对风速数据进行了二次分解。殷礼胜等^[18]将VMD运用到了交通流预测的数据预处理当中,降低了数据的非平稳性,有效提升了建模的精度。

为了解决传统预测模型存在的对非线性数据和多步预测误差较大的问题,本文提出一种基于VMD和Seq2seq模型的扬声器短期寿命预测模型。通过VMD分解各电参量数据,得到富含扬声器电参量变化趋势并且噪声较小的分量,叠加后建立Seq2seq模型进行多步预测。

1 预测方法

本文提出的模型主要由两部分构成,VMD和Seq2seq

编解码器模型,Seq2seq编码器模型包含了CNN层和BiLSTM层,Seq2seq解码器层包含了BiLSTM层和全连接层。

1.1 VMD

VMD是一种时频分析方法,能够将复杂的多分量信号一次性分解成多个单分量调幅调频信号,能有效处理非线性、非平稳信号,可以实现固有模态分量(intrinsic mode function, IMF)的有效分离,进而有效的提取时序信号的变化趋势信息。VMD算法主要包括了变分问题的构造和求解,函数构造如下:

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\} \\ \text{s. t.} & \sum_k u_k = f(t) \end{aligned} \quad (1)$$

式中: k 是需要分解的模态个数; u_k, ω_k 是输入信号分解后第 k 个模态函数和相应的中心频率; $\delta(t)$ 是狄拉克函数; $f(t)$ 表示被采样的观测信号。

1.2 Seq2seq 模型

Seq2seq编解码器模型主要用于解决循环神经网络(recurrent neural network, RNN)存在的输入输出序列长度的问题。其主要包含编码器(encoder)和解码器(decoder)两部分,基本模型均采用单层RNN结构。编码器用于编码序列的信息,将RNN层每个神经元的输入数据 X_t 编码为隐藏状态 h_t ,传入下一个神经元中,所有时刻的隐藏状态组成的向量 C (式(2))在最后一个神经元进行输出,代表编码器得到的有用信息。解码器共有3个输入,分别为向量 C ,上一个神经元输出的隐藏状态 h_{t-1} 和输出 y_{t-1} ,变换为当前神经元的隐藏状态 h_t (式(3)),最后通过全连接层输出 y_t 。

$$C = q(X_1, X_2, \dots, X_t) \quad (2)$$

$$h_t = g(y_{t-1}, h_{t-1}, C) \quad (3)$$

式中: X_t 为输入序列; C 为编码器输出向量; h_{t-1}, y_{t-1} 分别为解码器上一个神经元输出的隐藏状态和输出值; h_t 为解码器输出; q, g 分别为编码器编码函数和解码器解码函数。

1) CNN

CNN是一种具有特殊结构的前馈型神经网络。其中卷积层是其核心部分,通过卷积核 w 与序列图像做点积运算,在激活函数的作用下产生非线性映射,从而达到提取特征的目的。CNN层可以提取时序数据中不同特征值之间的空间联系,进而弥补LSTM层无法捕获数据空间分量的缺点,同时它提取出的特征仍然具有时序性,卷积运算如下:

$$X_i = f(w \cdot x + b) \quad (4)$$

式中: X_i 为输入数据; f 表示激活函数; w 表示卷积核; b 为偏置量。

在卷积层之后添加最大池化层Max-pooling,减少网络中的参数和计算次数,并控制过度拟合。

2) BiLSTM

LSTM是RNN的变种,其在RNN的基础上引入了记忆控制门,解决了RNN网络存在的梯度爆炸或梯度消失问题,实现时序信息保留和长期记忆。但是LSTM为前向网络,只能在一个方向上处理时序数据,为了能够建立前向数据和后向数据之间的关联,使用BiLSTM代替LSTM,BiLSTM在LSTM的基础上添加了一个后向网络,网络结构如图1所示。

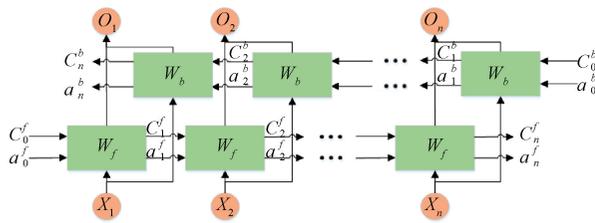


图1 BiLSTM网络结构

BiLSTM单元结构如图2所示,单个神经元结构与LSTM相同,输入输出为长期状态 \$c_t\$ 和隐藏状态 \$h_t\$, 包含了输入门、遗忘门和输出门,LSTM正是通过这些内部门之间的互相作用解决RNN网络的长期依赖问题。其中输入门的主要作用是控制哪些输入信息应该传入记忆细胞;遗忘门的主要作用是控制哪些信息应该删除和遗忘;输出门的主要作用是控制记忆细胞输出。

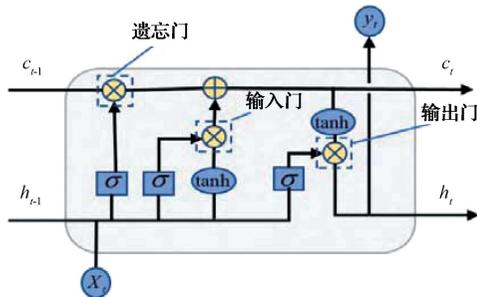


图2 BiLSTM单元结构

LSTM单元内的计算过程如式(5)。

$$\begin{cases} f_t = \sigma(W_f [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c [h_{t-1}, x_t] + b_c) \\ C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \\ O_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \\ h_t = O_t \cdot \tanh(C_t) \end{cases} \quad (5)$$

式中: \$f_t, i_t, C_t, O_t\$ 分别为 \$t\$ 时刻的遗忘门、输入门、单元状态、输出门的输出数据; \$\sigma\$ 为激活函数; \$\tanh\$ 为正切函数; \$h_{t-1}, C_{t-1}\$ 为上一个神经元输出的隐藏层和单元状态; \$b\$ 为各门的偏置量; \$W\$ 为各门的权重矩阵; \$\tilde{C}_t\$ 为记忆单元的输入状态; \$x_t, h_t\$ 分别为 \$t\$ 时刻的输入量和输出隐藏状态。

1.3 VMD-Seq2seq 预测模型建立

基于VMD分解和Seq2seq编解码器网络的扬声器电参量多步预测模型,构建流程如图3所示。

1)根据中心频率法确定VMD分解子序列的数量 \$K\$, 将扬声器多个电参量分解为 \$K\$ 个子序列,选取其中带有原序列退化趋势的子序列进行重新组合,并作为后续神经网络的训练集使用。

2)编码器层采用CNN-BiLSTM网络进行编码,利用CNN提取和放大重要退化趋势空间特征,使用BiLSTM网络同时接收正向和反向数据,可以更好的在时间维度上捕捉数据存在的双向依赖。

3)解码器层采用BiLSTM网络进行解码,使用BiLSTM网络对有效信息进行提取,对数据进行精确预测,并使用两个全连接层进行输出。

2 数据采集与数据处理

2.1 数据采集

使用扬声器可靠性寿命分析系统对动圈式扬声器进行恒定应力的加速寿命试验,采集扬声器电参数数据,可以同时记录8组扬声器单元从试验开始到出现音圈断路时的电阻抗、电压电流、有功功率、功率因数等参数变化,试验流程如图4所示。

所用扬声器额定功率为0.5W,额定阻抗为8 \$\Omega\$,对扬

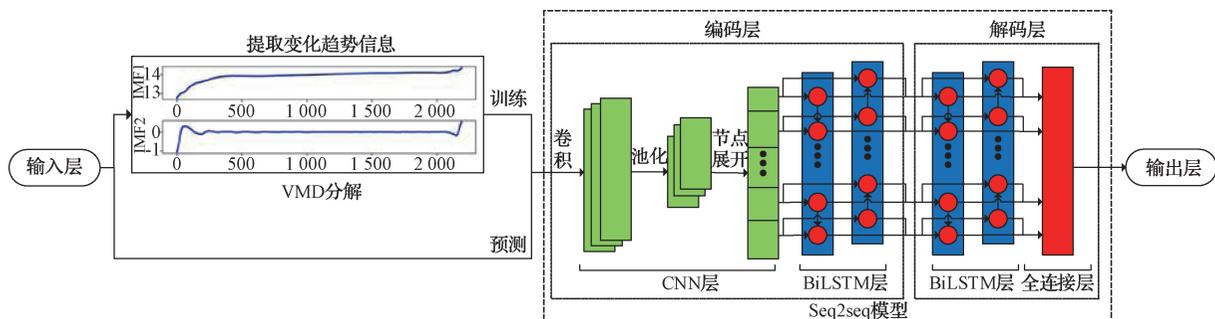


图3 预测模型

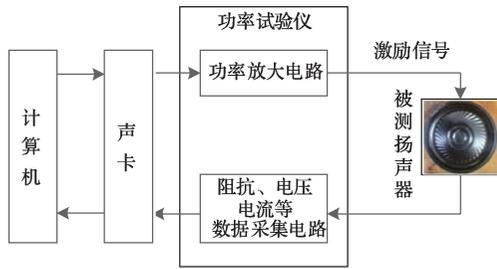


图4 数据采集试验

声器单元进行温升试验,根据稳态温度大小和扬声器非线性热模型,计算出扬声器热损坏上限功率为 3.14 W。试验时采用 4 W 功率的 EIA 测试信号,对 8 组扬声器单元进行加速寿命试验,采样间隔为 3 s,试验时长直至所有扬声器全部损坏。所有试验扬声器在 13 h 内全部损坏,大部分集中在 1~5 h 内,损坏表现均为高温引起的音圈脱胶和断路。扬声器单元各参数变化趋势如图 5 所示,可以看出在功率试验过程中扬声器电参数变化主要分为 3 个部分,变化期、平稳期和损坏期。

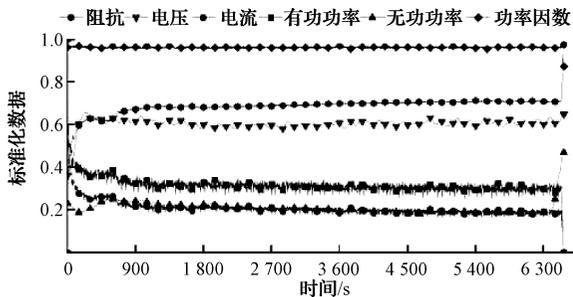


图5 电参数变化趋势

通过皮尔逊系数法进行相关性分析,选择相关系数较大的特征作为实验数据特征,相关性热力图如图 6 所示。由图 6 可知,选择电阻抗、电流、有功功率、无功功率和功率因数作为历史特征数据,同时考虑数据变化曲线和与其他数据的相关系数大小,选择电阻抗作为衡量扬声器剩余

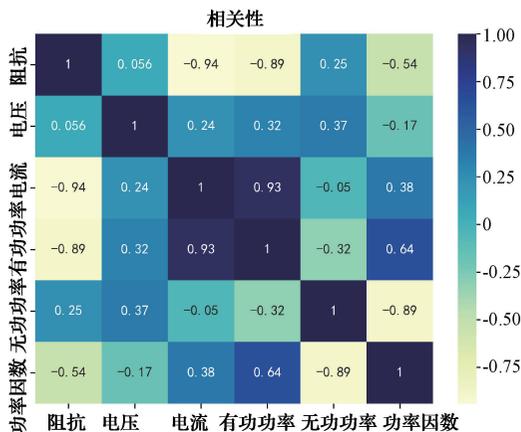


图6 相关性热力图

寿命标准的预测输出数据。

2.2 数据处理

同时对 8 个扬声器单元进行功率试验,采集的试验数据中,将 6 个扬声器单元的数据集作为训练集使用,1 个数据集作为验证集,1 个数据集作为测试集。由于预测数据理论上是未知的,不能同训练集一起进行归一化,首先对训练集进行归一化,得到训练集数据的最大最小值,再使用其对验证集和测试集进行归一化,最后将时间序列数据转化为监督问题数据,构建滑动窗口,进行多变量单步和多步预测。单步预测采用前 10 个时刻预测下一个时刻数据点,多步预测采用前 10 个时刻预测后 3 个和 5 个时刻数据点。

3 预测试验结果与分析

3.1 性能评价指标

为分析模型的预测效果,选取均方根误差(root mean squared error, RMSE)和平均绝对百分比误差(mean absolute percentage error, MAPE)、决定系数(R^2)3 个指标进行评估。以上均为时间序列预测领域的通用评价指标,具有一定的普适性。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y'_i)^2} \quad (6)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - y'_i}{y_i} \right| \times 100\% \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - y'_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (8)$$

式中: N 表示数据数量; i 表示当前时刻; y_i 表示当前时刻真实数据大小; y'_i 表示当前时刻预测值大小; \bar{y} 表示真实值的平均数。

3.2 仿真结果与分析

首先使用 VMD 算法对 5 种电参量数据分别进行分解,根据中心频率法选定分解层数 K 的选值,令 K 分别为 1, 2, 3, ..., 10 进行分解,得到不同层数分解下的中心频率表格,对每一列中心频率取平均值,观察各层分解的最后一个中心频率平均值大小。阻抗曲线分解中心频率如表 1 所示,当 $K > 9$ 时,中心频率的变化幅度很小,所以选择分解层数为 9 层,其余电参数按同样的方法进行分解处理。

表 1 中心频率

K 值	中心频率/kHz				
6	0.284	0.386			
7	0.278	0.367	0.421		
8	0.194	0.280	0.368	0.423	
9	0.189	0.276	0.313	0.371	0.424
10	0.149	0.194	0.277	0.314	0.371 0.424

图7所示为原始阻抗时间序列经过VMD分解后得到的子序列,可以看出子序列1主要表现了数据在时间上的变化趋势及阻抗数据的长期变化趋势。

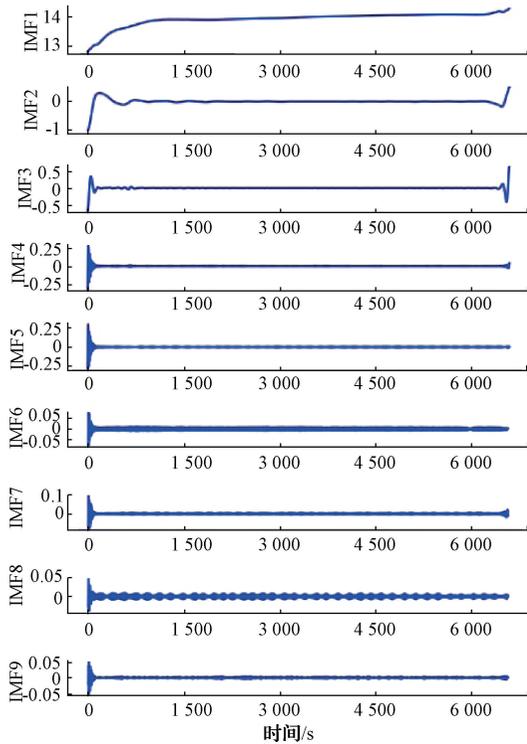


图7 VMD分解结果

为验证所提出模型的性能优劣,对5种预测模型的预测效果分别进行试验分析,同时为了增加模型的可信度,减少误差对模型结果的影响,对5种模型各进行10次试验,取均值进行比较,结果如表2和图8所示。

模型1(BiLSTM),采用常用于时间序列预测的双向长短时记忆网络进行预测,此模型可以建立前向数据和后向数据的联系。

模型2(CNN-BiLSTM),在模型1的基础上,加入CNN提取空间特征信息,从而构建CNN-BiLSTM模型进行预测。

模型3(Seq2seq-CNN-BiLSTM),在模型2的基础上加入Seq2seq模型,其中编码器使用模型2结构,解码器为BiLSTM-Dense层。

模型4(VMD-CNN-BiLSTM),在模型2的基础上,加入VMD分解所有电参量数据,得到的前两个带有时间退化趋势的子序列叠加作为训练集输入CNN-BiLSTM模型进行训练。

模型5(VMD-Seq2seq-CNN-BiLSTM),结合模型3和4,先使用VMD分解所有电参量数据,使用分解得到的前两个带有时间退化趋势的子序列叠加作为训练集,再使用模型3中的模型进行训练和预测。

结合表2和图8可知,模型5在不同步数预测时都能得到较高的预测精度。由表2可知,考虑了时间序列数据的时空特性后,模型2在模型1基础上加入了CNN,不同步数的整体预测准确度均高于模型1,但是在损坏期的单

表2 5种模型不同步数预测结果评价指标

测试集	评价指标	单步预测			三步预测			五步预测		
		RMSE	MAPE/%	R ²	RMSE	MAPE/%	R ²	RMSE	MAPE/%	R ²
后5%	模型1	0.25	1.3	0.94	0.52	2.5	0.75	0.87	4.0	0.19
	模型2	0.44	1.8	0.82	0.44	2.1	0.82	0.77	3.6	0.36
	模型3	0.24	1.2	0.95	0.40	1.9	0.84	0.70	3.2	0.47
	模型4	0.78	3.3	0.43	0.84	3.7	0.34	0.83	3.7	0.25
	模型5	0.21	0.8	0.96	0.39	1.7	0.85	0.56	2.2	0.67
整体	模型1	0.098	0.65	0.70	0.105	0.64	0.66	0.083	0.36	0.76
	模型2	0.089	0.56	0.76	0.072	0.40	0.84	0.080	0.35	0.78
	模型3	0.074	0.44	0.83	0.070	0.39	0.85	0.074	0.34	0.81
	模型4	0.062	0.17	0.88	0.068	0.21	0.86	0.066	0.20	0.85
	模型5	0.044	0.15	0.94	0.044	0.20	0.94	0.050	0.17	0.92

步预测准确度弱于模型1,三步和五步预测准确度高于模型1;模型3在模型2的基础上改为编解码器结构,在整个测试数据上的不同步数预测准确度均高于模型2;模型4考虑了对原时间序列进行VMD分解,提取有用的时间序列变化趋势,将模型2的训练集改为VMD子序列,结果显示,模型4对整体测试数据的单步及多步预测准确度都

远优于模型2,准确率提升较模型3更高,但是在损坏期的预测准确率低于模型2和模型3,说明利用VMD分解原始时间序列可以有效的提升模型整体预测的准确度。模型5结合了模型4和模型3,在测试数据整体预测指标RMSE、MPAE和R²上均优于前4个模型,测试数据整体预测单步及多步预测相比模型4, RMSE分别减少了

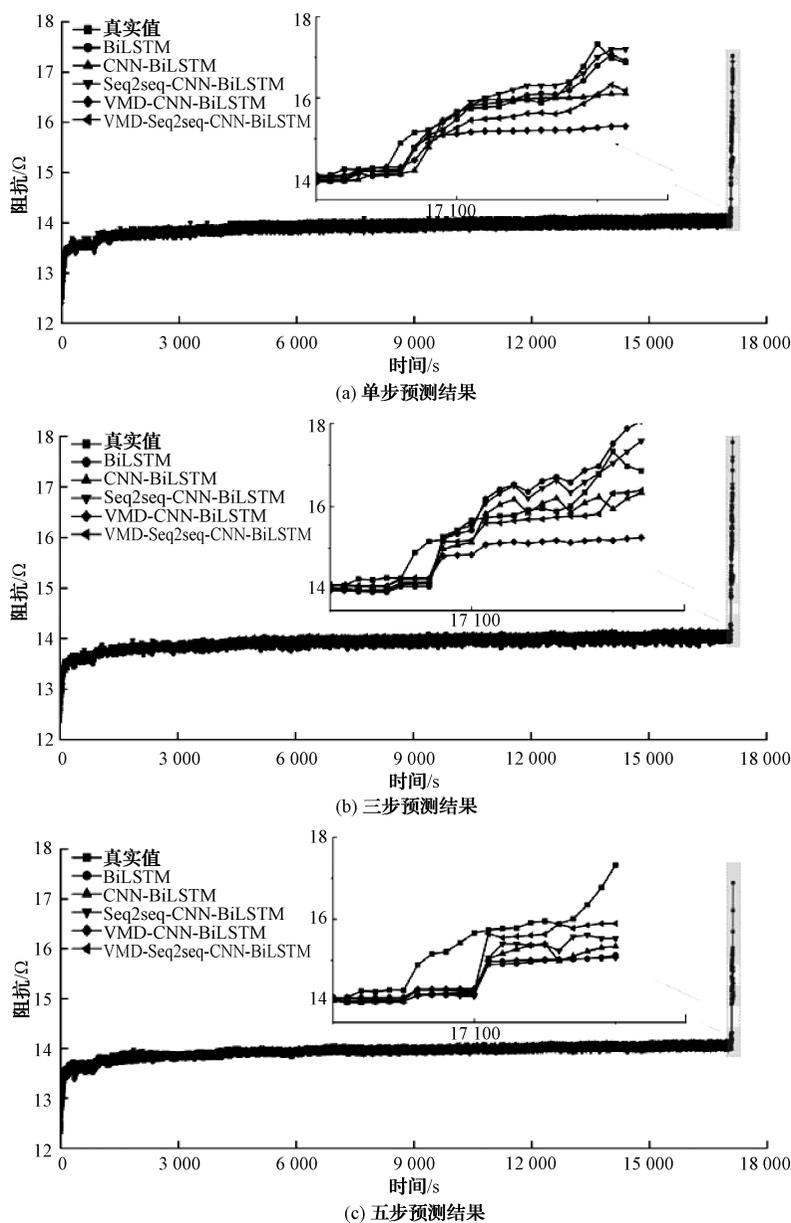


图8 5种模型不同步数预测结果比较

29%、35%、24%，MAPE 减少了 12%、4.7%、15%， R^2 增加了 6.8%、9.3%、8.2%，在损坏期上相比模型 3，RMSE 减少了 12.5%、2.5%、20%，MAPE 减少了 33.3%、10.5%、31.3%， R^2 增加了 1.1%、1.2%、43%，从评价指标和结果上来看，VMD-Seq2seq-CNN-BiLSTM 模型结合了模型 4 和 3 的优点，可以有效的追踪扬声器电参数的变化，预测结果更加准确。

为了验证模型的适应能力，使用同参数不同型号的动圈扬声器数据作为验证集再次进行预测试验，预测指标结果如表 3 所示。

验证结果表明，在不同型号的动圈扬声器上模型 5 的单步和五步预测结果依然优于其他 4 种模型结果，表明模型的适应能力较好。

表3 验证集评价指标比较

指标	单步预测			五步预测		
	RMSE	MAPE /%	R^2	RMSE	MAPE /%	R^2
模型 1	0.093	0.63	0.70	0.085	0.46	0.63
模型 2	0.070	0.42	0.83	0.068	0.38	0.76
模型 3	0.063	0.37	0.96	0.062	0.33	0.80
模型 4	0.069	0.34	0.83	0.054	0.16	0.85
模型 5	0.046	0.24	0.93	0.051	0.15	0.87

4 结论

本文提出了一种基于 VMD 分解的 Seq2seq 网络模型用于扬声器可靠性试验时扬声器电参量短时寿命预测。

通过算例分析及模型对比,加入 CNN 和 BiLSTM 的 Seq2seq 网络模型可以有效的提取长序列数据中的空间和时间特征,在应对数据变化时,也能较好的跟踪数据的变化趋势。同时针对扬声器电参量的变化过程,利用变分模态分解可以有效提取出扬声器电参量的准确变化趋势。通过扬声器可靠性试验和预测算法实验验证了本文所提方法的有效性,在 Seq2seq 网络模型中加入变分模态分解后可以有效的提高模型的预测精度。

参考文献

- [1] WOLFGANG KLIPPE,王刚平,朱木兰. 扬声器热传递非线性模型[J]. 电声技术,2011,35(8):15-19.
- [2] 王瑞,冉锋,逯静. 基于游程判别法和 VMD 残差修正的风电功率预测[J]. 湖南大学学报(自然科学版),2022,49(8):128-137.
- [3] 周静雷,董春君. 热模型下扬声器音圈温度的卡尔曼滤波预测[J]. 西安工程大学学报,2019,33(6):631-636.
- [4] 郑晓亮,陈华亮,来文豪. 参数优化的 SVR 移动网络流量预测[J]. 计算机应用与软件,2022,39(9):278-284.
- [5] 左学谦,熊芝,聂磊,等. 基于 PSO-LSSVM 的离心泵状态预测方法[J]. 电子测量技术,2022,45(19):89-94.
- [6] 鲁南,欧阳权,黄浪卉,等. 基于注意力机制和多任务 LSTM 的锂电池容量预测方法[J]. 电气工程学报,2022,17(4):41-50.
- [7] 陈仁祥,王帅,杨黎霞,等. 弓网接触力长短时记忆网络预测的受电弓主动控制与仿真[J]. 仪器仪表学报,2021,42(5):192-198.
- [8] 王朝阳,李丽敏,温宗周,等. 基于时间序列和 CNN-LSTM 的滑坡位移动态预测[J]. 国外电子测量技术,2022,41(3):1-8.
- [9] YU S, WU Z, ZHU X, et al. A domain adaptive convolutional LSTM model for prognostic remaining useful life estimation under variant conditions [C]. 2019 Prognostics and System Health Management Conference (PHM-Paris). IEEE, 2019.
- [10] WANG Y, WANG H, ZHOU B, et al. Multi-dimensional prediction method based on Bi-LSTM for ship roll[J]. Ocean Engineering, 2021(242-Dec. 15).
- [11] 邢红涛,郭江龙,刘书安,等. 基于 CNN-LSTM 混合神经网络模型的 NO_x 排放预测[J]. 电子测量技术,2022,45(2):98-103.
- [12] 李振鹏,董明利,于明鑫,等. Encoder-Decoder LSTM 网络的输电母排触点温度预测方法[J]. 电子测量与仪器学报,2022,36(4):32-39.
- [13] XIANG Z, YAN J, DEMIR I. A rainfall-runoff model with LSTM-based sequence-to-sequence learning [J]. Water Resources Research, 2020, 56(1): e2019WR025326.
- [14] 赵阳阳,夏亮,江欣国. 基于经验模态分解与长短时记忆神经网络的短时地铁客流预测模型[J]. 交通运输工程学报,2020,20(4):194-204.
- [15] 李春祥,李洲. 基于多种信号分解的台风风速多步预测[J]. 振动. 测试与诊断,2019,39(5):1103-1110,1139.
- [16] 赵会茹,赵一航,郭森. 基于互补集合经验模态分解和长短期记忆神经网络的短期电力负荷预测[J]. 中国电力,2020,53(6):48-55.
- [17] 向玲,刘佳宁,苏浩,等. 基于 CEEMDAN 二次分解和 LSTM 的风速多步预测研究[J]. 太阳能学报,2022,43(8):334-339.
- [18] 殷礼胜,孙双晨,魏帅康,等. 基于自适应 VMD-Attention-BiLSTM 的交通流组合预测模型[J]. 电子测量与仪器学报,2021,35(7):130-139.

作者简介

李天宇(通信作者),硕士研究生,主要研究方向为声频测量、有限元仿真。

E-mail: 957994787@qq.com

周静雷,博士,副教授,主要研究方向为电声学、声频测量。

李佳斌,博士,副教授,主要研究方向为微电子光器件。