

# 基于小波变换和神经网络的车内噪声信号重构

杨东坡, 王孝兰, 郭 辉, 刘宁宁, 王岩松

(上海工程技术大学 机械与汽车工程学院, 上海 201620)

**摘要:** 为获取较高精度车内噪声主动控制 (Active Noise Control, ANC) 参考信号, 提出了一种基于小波变换和 BP 神经网络的车内噪声信号重构方法; 以在某轿车采集到的噪声信号为基础, 用声学传递路径分析 (TPA) 方法确定影响车内噪声的关键点信号; 鉴于噪声源信号对车内信号非线性关系的复杂性, 建立 BP 神经网络的噪声重构模型, 并利用小波分解来降低噪声信号的非平稳性; 为对比重构效果, 建立 BP 神经网络噪声重构模型; 结果表明, 文章提出算法的重构值与实测值之间的平均绝对误差比 BP 神经网络小, 并且基于小波变换和 BP 网络重构模型的平均绝对误差均小于 0.01; 该方法能够对车内噪声信号进行准确、有效的重构。

**关键词:** 车内噪声; 小波变换; BP 神经网络; 重构

## Interior Noise Signal Reconstruction Method Based on Wavelet Transform and BP Neural Network

Yang Dongpo, Wang Xiaolan, Guo Hui, Liu Ningning, Wang Yansong

(School of Mechanical and Automotive Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

**Abstract:** To obtain high-precision active noise control (ANC) reference signal, a reconstruction method of interior noise signals that based on wavelet transform and BP neural network was proposed. Based on the noise signal sources collected in a vehicle, the key point signals affecting the interior noise were determined using the acoustic transfer path analysis (TPA) method. In view of the complexity nonlinear relationship between the noise source signals and interior signals, a BP neural network reconstruction model was established. And then wavelet decomposition method was used to reduce the non-stationarity of signals. Comparing the reconstruction effect, a BP neural network was established at the same time. The results show that the average absolute error between the proposed method reconstruction values and the measured values is smaller than that of the BP neural network. And the average absolute error of BP network reconstruction model based on wavelet transform is less than 0.01. This method can be used to reconstruct the noise signals on passenger ear-sides accurately and effectively.

**Keywords:** interior noise; wavelet transform; BP neural network; reconstruction

### 0 引言

为了实现高速工况下车内乘员耳侧噪声的主动控制 (ANC), 首先要为控制系统提供初级参考信号。对于初级参考信号的拾取, 传统方法是在乘员耳侧附近安装传声器以获取初级参考信号, 此方法不可避免的引入了次级声源二次污染<sup>[1]</sup>, 不利于系统的快速收敛, 因此研究车内乘员耳侧噪声的重构方法, 获取 ANC 的参考信号具有一定的意义。

汽车高速行驶 (大于等于 80 km/h) 时, 影响车内乘员耳侧噪声的源信号众多。这些噪声信号呈现非线性、非平稳性的特点<sup>[2]</sup>, 这就使得在数学上很难得出一个准确的关于噪声源信号影响变化的关系表达式。为解决这一问题, 人工神经网络 (Artificial Neural Networks, ANN) 提供了

一个可行性解决方案。目前, ANN 被广泛运用, 其中大部分采用 BP 神经网络<sup>[3-4]</sup>。虽然 BP 神经网络具有很好的非线性拟合能力, 单独使用神经网络可以很好地处理信号的非线性, 但非平稳性带来的误差不可避免。

目前, 针对此类信号, 研究者们已经进行了大量的研究, 并取得了一定的成果。集成算法建模可以提高多传感器数据融合模型的泛化性, 有效性和可靠性。如何集成建模, 已经提出了许多方法来解决这个问题<sup>[5]</sup>。基于神经网络模型, 为了获取高精度的结果, 集成算法建模表现出了很好的优势, 其中, 程静<sup>[6]</sup>使用多元回归分析和 BP 神经网络相结合的方法, 来预测风力发电机组气动噪声, 实验表明, 对输入的多变量进行筛选可以有效的提高结果精度。

为了解决噪声信号非平稳性, 提高噪声重构的 BP 神经网络模型的重构精度, 信号处理与 BP 神经网络相结合的集成算法被应用。目前, 传统的处理信号时间/频率变换方法有快速傅里叶变换 (FFT), 短时傅里叶变换, 小波分析和经验小波变换<sup>[7-10]</sup>等, 这些传统的信号处理方法不适用于噪声信号重构技术, 由于此类信号属于机械振动和声学信号, 具有强非线性, 非平稳和非高斯性<sup>[11]</sup>。目前, 小波分解<sup>[12]</sup>

收稿日期: 2018-09-27; 修回日期: 2018-10-16。

基金项目: 国家自然科学基金项目 (51675324, 51175320)。

作者简介: 杨东坡 (1991-), 男, 河南商丘人, 硕士研究生, 主要从事汽车 NVH 方向的研究。

通讯作者: 王孝兰 (1985-), 女, 山东临沂人, 博士, 讲师, 主要从事智能驾驶和信号处理方向的研究。

被用于处理这类信号。

本文为实现车内乘员耳侧噪声时域信号高精度重构, 提出了基于小波变换的 BP 神经网络重构算法。首先将预处理后的神经网络输入信号经小波分解为高频分量和低频分量。再结合 BP 神经网络进行乘员耳侧噪声信号重构, 并通过实车数据和算法对比验证算法的有效性, 准确性。

## 1 基本理论与算法

### 1.1 小波变换分析

对于小波变换的离散函数  $U_f(a, b)$ , 将尺度因子  $a$  和偏移因子  $b$  设置为  $a = a_0^j, b = a_0^j k b_0 (j, k \in Z, a_0 > 1, b_0 > 0)$ , 小波函数在二元缩放因子缩放下每一级的函数表达式 (假设  $a_0 = 2, b_0 = 1$  时):

$$\psi_{j,k}(t) = 2^{+j} \psi(2^j t - k) \quad (1)$$

式中,  $2^{+j}$  为归一化常数。小波基在能量归一化的  $L^2(R)$  范数内进行归一化处理, 因此, 离散小波变换及其重构形式可以表示为:

$$U_f(a, b) = \langle f(t), \psi_{j,k}(t) \rangle = 2^{+j} \int_{-\infty}^{+\infty} f(t) \psi(2^j t - k) dt \quad (2)$$

$$f(t) = \sum_j \sum_k U_f(2^{-j}, 2^{-j} k) \psi(2^j t - k) \quad (3)$$

小波变换与短时傅里叶变换有极大的差别, 小波变换的窗口是两个矩形  $[b - a \quad Dy, b + a \quad Dy] \times [(\pm \omega_0 - Dy) / a, (\pm \omega_0 + Dy) / a] (\pm \omega_0 + Dy) / a$ , 这个窗口的中心位置是  $(b, \pm \omega_0 / a)$  式中的  $a$  是决定窗口位置和窗口形状的重要参数, 时间长度是可以改变的。也就意味着小波变换中时间长度可以改变, 低频时, 时间低、频率高; 高频时, 时间高、频率低, 这正符合了非平稳信号中信号的变化特点。

### 1.2 BP 神经网络原理

现有理论已经证明, 一个具有偏差的 Sigmoid 函数加上一个线性输出层能够逼近任意有理函数<sup>[13]</sup>。因此可以得到 BP 神经网络结构的基本设计规律。BP 神经网络是一种多层前馈神经网络, 本文采用的图 1 所示拓扑结构。一般该网络包含输入层、隐含层和输出层, 网络权值和阈值调整采用输出层误差反向传播, 使输出不断逼近期望值。




图 1 典型 BP 网络拓扑图

如图 1, 其中  $n, m$  和  $l$  分别定义为输入层, 隐层和输出层神经元数目。为了重构高速工况汽车乘员耳侧噪声信

号, 影响车内噪声的关键点信号作为输入数据, 乘员耳侧噪声信号作为输出数据。隐层神经元数目,  $m$ , 首先被设置根据一个经验公式, 然后基于本文解决的问题进行具体分析, 将在第四部分进行设置, 公式如下:

$$m = \sqrt{(n+l)} + \alpha \quad (4)$$

其中:  $\alpha$  取值  $0 \sim 10$ 。

BP 神经网络算法重复两个阶段: 前向传播和后向传播。在正向传播阶段, 输入信号通过输入层向前传播, 并逐层处理直至输出层。然后将输出与期望值进行比较, 期望值与输出结果之间的差异称为误差。在后向传播阶段, 使用误差形成损失函数, 并且通过优化方法更新神经网络的权重, 以最小化损失函数, 实现快速收敛, 并避免落入局部最小值点。

如图 2 所示, 对于有  $n$  个输入信号的神经元  $j$ , 此神经元的输出结果可以表示为:




图 2 一个神经元

$$O_j = f\left(\sum_{i=1}^n \omega_{ij} \cdot x_i - \theta_j\right) \quad (5)$$

其中:  $\omega_{ij}$  和  $\theta_j$  分别表示神经元  $j$  的权重和阈值,  $f$  为激励函数, 本文中使用的双曲正切 S 形函数, 值域范围为  $[-1, 1]$ , 表达式如下:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

$$\text{其中: } X = \sum_{i=1}^n \omega_{ij} \cdot x_i - \theta_j$$

由于选用的上述函数作为激励函数, 结合噪声信号自身特点, 输入数据和期望输出数据必须进行归一化处理, 这里采用线性转换算法将数据归一化到  $[-1, 1]$ , 公式如下:

$$x_1 = \frac{2 \cdot (x - x_{\min})}{x_{\max} + x_{\min}} - 1 \quad (7)$$

其中:  $x_{\min}, x_{\max}$  分别代表训练数据  $x$  的最小值、最大值。

当前得到的输出是下一层神经元的输入, 因此将输入信息传送到输出层。期望值与输出值之间的差异称为输出单元误差。

对于第  $i$  个样本, 定义它的误差函数为  $E_i$ , 公式如:

$$E_i = (y_{d,k} - y_k)^2 \quad (8)$$

其中:  $y_{d,k}$  和  $y_k$  分别代表输出层神经元的期望输出值和真实输出值。对于  $N$  个数据样本总误差  $E$  可以得到:

$$E = \frac{1}{N} \sum_{i=1}^N E_i \quad (9)$$

误差信号通过 BP 神经网络逐层递归计算得到，我们的目标是通过调节权重来减小误差值。下面，介绍调整 BP 神经网络权重的过程。首先定义输出层神经元第  $r$  次迭代的误差信号为  $e(r)$ ，表示为：

$$e(r) = y_d(r) - y(r) \quad (10)$$

$y_d(r)$  和  $y(r)$  分别表示期望输出值和真实输出值。这里的误差用于下次迭代调节权重，表达式：

$$\omega_{jk}(r+1) = \omega_{jk}(r) - \Delta\omega_{jk}(r) \quad (11)$$

$\omega_{jk}(r+1)$  和  $\omega_{jk}(r)$  分别表示在  $r+1$  次和  $r$  次迭代的神经元  $j$  和神经元  $k$  之间的连接权值， $\Delta\omega_{jk}(r)$  表示下一次迭代中权重的调整部分。

### 1.3 基于小波变换和 BP 神经网络的重构算法

汽车高速行驶时，车内噪声信号声压变化具有随机性，采集的信号呈现非稳态非线性的特点，从而导致 BP 神经网络对一些数据点的学习和训练存在混淆现象。基于现有的大多数方法在进行信号重构，对于相对平稳的数据序列的重构精度往往很高，但是具有明显非平稳性的数据序列由于自身变化规律很难掌握，所以在进行重构时，重构精度一般比较低。因此，为了满足信号的重构精度，需要对信号进行平稳化处理。因为小波分解方法可将非平稳数据序列分解成相对平稳的数据序列。因此本文基于小波变换和 BP 神经网络相结合的方法，对车内乘员耳侧噪声时域信号重构。

在本文中，应用小波分解，将各原始噪声时域信号经其分解，得到高频和低频分量。利用各个信号的分解分量建立重构模型，以 2 个分量数据作为输入数据，乘员耳侧信号的 2 个分量数据作为期望输出值，对 BP 神经网络模型进行训练，通过调整隐藏层神经元的神经元数和训练次数，使网络误差满足工作要求，确定输入层、隐藏层和输出层的权系数以及各个节点的阈值，建立乘员耳侧的噪声信号相应频段的重构模型，将信号各频段的重构结果进行小波逆变换，进而获得乘员耳侧噪声重构信号。

## 2 试验验证

### 2.1 试验数据获取

通过查阅相关文献[14-15]，初步确定车内噪声主要贡献量在以下位置：轮胎噪声、左右 A 柱低端、左右 A 柱顶端、左右后视镜、进、排气口。利用实验室已有的某款轿车试验采集数据，选取以上位置测点及驾驶员耳侧的噪声时域信号，测试工况：匀速工况 80 km/h。作为提出算法试验验证初始数据。测试仪器西门子公司的 LMS 数据采集器，采样频率为 51200 Hz，测试路面符合标准。

利用声学传递函数 (TPA) 贡献量分析<sup>[16]</sup>方法选择最具有相关性的关键测点信号来重构车内噪声，声压贡献量分析结果如图 3。通过分析可知源信号具有很强的对称性，进排气口的贡献量明显低于其他位置，因此最终确定左 A 柱低端、左侧 A 柱顶端、左前轮、左后视镜以及乘员耳侧噪声信号作为噪声信号重构的关键点位置。

考虑到人耳听觉范围在 20Hz 以上，进行滤波处理，乘员耳侧信号的频谱，如图 4 所示。从图中可以看出车辆处




图 3 各关键点在高速下的贡献量分析




图 4 车内乘员耳侧噪声信号频谱

于高速匀速工况时，车内乘员耳侧噪声能量主要集中在中低频 600 Hz 以下，其中，在匀速工况下 (30~60) Hz 左右频率段对耳侧噪声贡献最大，占主导地位，在 (200~500) Hz 频率段有明显的小波峰，因此，对各原噪声信号进行重新采样，只对 512 Hz 以下进行有效分析，采样频率为 1024 Hz，进行滤波处理。

### 2.2 重构模型精度对比

基于上述预处理后的试验数据，本节对小波变换和 BP 神经网络的车内噪声信号重构模型的有效性进行验证；为更好地表示本文提出算法重构性能，建立了 BP 神经网络噪声信号重构模型进行对比分析。

#### 2.2.1 BP 神经网络的构建

以各个噪声源信号数据作为输入数据，乘员耳侧信号的数据作为期望输出值，对 BP 神经网络模型进行训练，通过调整隐藏层神经元的神经元数和训练次数，使网络误差满足工作要求。建立乘员耳侧的噪声信号相应频段的重构模型。这里采用包含一个输入层，一个隐层，一个输出层的三层神经网络，输入层神经元个数，通过 2.1 分析，本文确定为  $n=4$ ；输出层重构乘员耳侧信号，本文确定为  $l=1$  个。学习效率定为 0.001，误差精度为 0.001，最大训练次数为 1000 次。

隐藏层神经元的确定是模型构建的关键，常用的方法是试错法。隐含层不同神经元个数对训练学习误差的影响见图 5。结果表明，随着神经元个数的增加模型学习误差减小，但神经元个数增加提高网络结构复杂度，导致网络的训练时间增加，同时一些无用的信息也会被记录。因此本

文提出算法模型, 低频选 160 个神经元, 高频选 210 个神经元, 对比噪声重构 BP 网络模型选 175 个。




图 5 隐层神经元的数目对重构结果的影响

### 2.2.2 重构结果分析

基于上述预处理后的试验数据, 本节对 BP 神经网络和小波变换和 BP 神经网络模型对车内乘员耳侧噪声时域信号进行重构, 结果如图 6 和图 7 所示。




图 6 本文提出算法重构结果




图 7 BP 网络重构结果

从图 6 (a) 和 7 (a) 中重构信号和实测信号的时域曲线对比可以看出, 不同的重构模型的乘员耳侧噪声重构信号与实测信号在幅值和相位上有相同变化趋势和较好的对应关系。结合图 6 (b) 和 7 (b) 中不同工况下的 500 Hz 以下的重构信号和实测信号的频谱对比分析可知, 在整个频带范围内, 其幅值和相位上有相同变化趋势, 其中在噪声的主要能量 30~60 Hz 范围内, 其幅值和相位上具有很好的对应关系, 在频带 60~400 Hz 范围内, 依然保持着较好的对应关系, 但超过 400 Hz, 本文提出算法模型频域结果较好, 因此可以表明本文所提出重构算法在时域和频域上均具有较高的信号重构性能。

为了进一步表征重构模型精度, 本文选用平均绝对误差作为评价指标。如式 (12) 所示:

$$err = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (12)$$

其中:  $N$  表示采样点数,  $\hat{y}$  表示重构乘员耳侧信号,  $y$  表

示乘员耳侧原始信号。

为了更好地对结果作出说明, 对  $y, \hat{y}$  进行归一化处理。公式如 (13) 所示:

$$y_1 = \frac{2 \cdot (y - y_{\min})}{y_{\max} - y_{\min}} \quad (13)$$

其中:  $y_{\min}, y_{\max}$  分别代表向量  $y$  的最小值、最大值。  $y_1$  表示归一化的结果。

两种不同模型的重构信号与原始信号的误差曲线如图 8 所示。




图 8 两种模型误差分析

结果表明, 网络重构模型, 输入特征信号进行网络训练, 都可以实现对车内噪声信号的重构。然而, 基于小波变换的网络模型已经很大的提高重构结果准确性。两种模型的误差统计结果分别为: BP 网络噪声重构结果 (0.0180), 本文提出算法重构结果为 (0.0026), 精度提高了 85.6%, 这是因为小波分解可以很大程度上降低信号的非平稳度。同时重构信号与原始信号的误差均值小于 0.01<sup>[17]</sup>, 则认为完全重构出原始信号。这说明了依据本文提出算法模型对的车内乘员耳侧噪声重构信号可以得到准确的重构信号, 并且精度得到了很大的提高。

### 3 结论

汽车高速行驶 (大于等于 80 km/h) 时, 影响车内乘员耳侧噪声的源信号众多。同时噪声信号具有非平稳性, 非线性特点, 且风噪、轮胎噪声是车内噪声主要的影响因素, 因此, 本文提出了一种基于小波变换和 BP 神经网络算法的乘员耳侧噪声信号重构模型, 并且用实车试验数据对算法的有效性进行了验证, 结果表明:

1) 本文提出的基于小波变换和 BP 神经网络的车内噪声信号的重构方法。首先对影响车内噪声的源信号进行贡献量分析, 确定关键点; 然后基于噪声信号的非线性和非平稳性, 小波分解可以实现对原始噪声信号的分解, 得到高频和低频分量, 最后噪声信号分量作为 BP 神经网络的输入, 对网络进行训练。结果表明此方法可以降低模型的复杂度和信号的非平稳度, 从而提高了模型重构的精度。

2) 对比不同的噪声重构 BP 网络模型, 结果显示基于小波变换和 BP 网络噪声重构模型的平均绝对误差较小 (0.0026), 小于 0.01。表明该方法的重构精度得到了很大的提高。

3) 基于小波变换和 BP 神经网络的重构方法为主动控

制系统获取参考信号提供了一定的参考价值。

参考文献:

[1] Elliott S J, Cheer J, Bhan L, et al. A wave number approach to analysing the active control of plane waves with arrays of secondary sources [J]. J. Sound Vib., 2018, 419: 405 - 419.

[2] Huang Y, Jiang W K, Xin Y Z, et al. An experimental research of the characteristics of speeding-up interior noise of an intermediate coach [J]. Journal of Vibration Engineering, 2004: 1116 - 1118.

[3] 耿传飞, 卢文良, 俞醒. 基于 L-M 算法的神经网络在环境振动分析中消除本底振动的应用 [J]. 振动与冲击, 2016, 35 (13): 14 - 19.

[4] 苏丽俐, 王登峰, 王倩. 基于 GRNN 的车内噪声品质预测 [J]. 吉林大学学报 (工学版), 2011, 41 (S2): 82 - 86.

[5] Dietterieg T. Machine-learning research: four current directions [J]. AI Mag. 1998, 18: 97 - 136.

[6] 程静, 王维庆, 何山. 基于回归分析与 BP 神经网络的风机噪声预测 [J]. 噪声与振动控制, 2013, 33 (6): 49 - 52.

[7] Tang J, Yu W, Chai T Y, et al. Selective ensemble modeling load parameters of ball mill based on multi-scale frequency spectral features and sphere criterion [J]. Mech. Syst. Signal Process, 2016: 485 - 504.

[8] Feng Z, Liang M, Chu F. Recent advances in time-frequency analysis methods for machinery fault diagnosis: a review with application examples [J]. Mechanical Systems and Signal Processing, 2018, 96: 103 - 124.

(上接第 87 页)

示等功能用通用化处理代码固化在程序里, 将测试参数、通信协议、计算公式等作为配置参数项, 采用配置工具进行配置录入, 实现快速可配置设计。目前已经为近 5000 个复杂参数及十几个分系统的通信协议完成配置与运行。

该系统的控件设计模块通过标准化数据服务接口、通用持久化接口实现自定义控件设计的标准化与灵活扩展, 实现交互界面配置自动生成, 监控显示终端自动加载, 能够在使用现有功能的基础上进行自定义功能的开发, 在实际工程项目应用中, 根据总体的特殊需求, 利用标准服务接口, 完成定制了多种显示状态灯、监控文本窗口、功能按钮等控件, 不需作很多修改而方便地完成软件的更新和升级, 达到了快速开发的良好效果。历经多个工程项目, 该系统的设计方法和实现已得到了充分的验证。

4 结束语

基于复杂参数的组态化显示监控系统采用基于事件注册的复杂参数数据处理与显示方法, 实现飞行器复杂参数测试数据的实时监控, 提出标准化数据服务接口、通用持久化接口的组态化控件设计方法, 进行自定义控件设计标准化与灵活扩展, 实现交互界面配置自动生成、监控显示终端自动加载, 达到一套软件应用于多个型号的通用化目标, 实现飞行器复杂参数测试数据的实时监控, 已经在工程中得到很好的应用, 既节约人力物力, 又降低成本, 大

cessing, 2013, 38 (1): 165 - 205.

[9] An X, Jiang D, Liu C, et al. Wind farm power prediction based on wavelet decomposition and chaotic time series [J]. Expert Systems with Applications, 2011, 38 (9): 11280 - 11285.

[10] Gilles J. Empirical wavelet transform [J]. IEEE Transactions on Signal Processing, 2013, 61 (16): 3999 - 4010.

[11] Feng Z, Zuo M J. Vibration signal models for fault diagnosis of planetary gearboxes. Journal of Sound and Vibration, 2012, 331 (22): 4919 - 4939.

[12] Cusido J, Romeral L, Ortega J A. Garcia Espinosa. Fault detection in induction machines using power spectral density in wavelet decomposition [J]. IEEE Trans. Ind. Electron, 2008: 633 - 643.

[13] MacQueen J. Some methods for classification and analysis of multivariate observations [Z]. Proc Fifth Berkeley Symp Math Stat Probab. 1967, 14 (1): 281 - 297.

[14] 刘旺林. 全频段车内噪声预测分析与控制研究 [D]. 重庆: 重庆大学, 2016.

[15] Jia W, Zhang T, Dong G, et al. Correlation analysis of car exterior and interior noise tests under different yaw angles with beamforming [A]. International Forum on Mechanical, Control and Automation [C]. 2017.

[16] 余琪, 周铨. 传递路径分析用于车内噪声贡献量的研究 [J]. 汽车技术, 2010 (3): 16 - 19, 30.

[17] 林琳. 基于压缩感知的信号重构与分类算法研究 [D]. 西安: 西安电子科技大学, 2012.

大大提高了开发效率, 实现软件的复用。

参考文献:

[1] 宋征宇. 新一代航天运输系统测发控技术发展的方向 [J]. 航天控制, 2013, 31 (4): 3 - 9.

[2] 冀航. 基于组态技术的通用运载火箭遥测数据处理平台研究与实现 [D]. 南京: 南京理工大学, 2013: 2 - 3.

[3] 刘青普. 面向监控的测控站仿真系统的设计与实现 [J]. 仿真技术, 2007, 23: 241.

[4] 韩亮. 测发控软件组态开发平台的设计与应用 [J]. 计算机测量与控制, 2014, 23 (5): 1795.

[5] 葛东明, 黄显林. 面向控制的高超声速飞行器动力学特性分析 [J]. 航天控制, 2010, 28 (4): 3 - 9.

[6] 程进, 冯大伟, 段春泉. 飞航导弹变结构过载控制方案研究 [J]. 航天控制, 2008, 26 (2): 35 - 40.

[7] 宋征宇. 新一代航天运输系统测发控技术发展的方向 [J]. 航天控制, 2013, 31 (4): 3 - 4.

[8] 陈涛, 徐小力. 基于组态王的大型烟机检测诊断系统研究 [J]. 故障诊断, 2007, 23: 221.

[9] 曾贵明. 飞行器测发控技术 [M]. 计算机测量与控制, 2009 (9).

[10] 王思平. 测控软件通用仿真测试平台研究与实现 [D]. 北京: 北京工业大学, 2015.

[11] 送海涛. 组态软件技术及靶场测控软件系统的设计 [J]. 航天控制, 2008, 26 (1): 71.