

车内噪声声品质的神经网络预测

申秀敏, 左曙光, 何吕昌, 张世炜, 李 林

(同济大学新能源汽车工程中心, 上海 201804)

摘要: 鉴于车内噪声声品质评价的复杂性和非线性特征, 分析了 BP 神经网络方法在车内噪声声品质预测中的应用, 阐述了其基本原理和模型并结合实例提出了完整的实施流程。该预测方法具有很强的学习能力, 各连接权重由网络通过学习自主生成, 因此预测结果更具客观性和准确性。同时将用此种方法与现有的预测方法得出的结果进行比较, 得出结论: 神经网络用于车内噪声主客观评价数据处理可以得到更好的预测效果, 从而在很大程度上提高评价者的决策水平, 对现代汽车噪声的评价、分析与控制都具有重要意义。

关键词: 车内噪声; 声品质; BP 神经网络; 预测模型

中图分类号: TB535

文献标识码: A

文章编号: 1000-3630(2009)-03-0264-05

DOI 编码: 10.3969/j.issn1000-3630.2009.03.015

BP neural network prediction of car interior sound quality

SHEN Xiu-min, ZUO Shu-guang, HE Lü-chang, ZHANG Shi-wei, LI Lin

(Clean Energy Automotive Engineering Center, Tongji University, Shanghai 201804)

Abstract: Based on the complexity and non-linear characteristics of car interior sound quality evaluation, the problem about the application of BP neural network in car interior sound quality prediction is discussed. Combining the basic principles and models with examples the complete implementation process is presented. The self-learning ability of this prediction method is so strong that each connection weight could generate itself via network learning with a more objective and accurate predicted result. Then BP neural network evaluation method is compared with the existing prediction methods, and the conclusion shows that in interior vehicle subjective and objective noise evaluation, the prediction effect of the former method is much better. To a large extent the method could be used to improve the decision-making accuracy, which is of great importance to the evaluation, analysis and control of automotive noise nowadays.

Keywords: fuel cell vehicle; sound quality; BP neural network; predict model

1 前 言

世界汽车工业的发展越来越追求优越的性能和卓越的质量, 汽车的 NVH 特性成为衡量车辆品质的重要指标。车内噪声是影响乘员的舒适性、听觉损害程度、语言清晰度以及对车外各种音响讯号识别能力的重要因素, 车内声音的品质成为人们评价和选购汽车的重要因素之一。

汽车声品质的概念起源于 20 世纪 80 年代中期, 是汽车 NVH 研究的重要部分。从事汽车噪声控制的工程师们发现, 传统的 A 计权声压级不足以描述汽车噪声的全部特征^[1]。而声品质^[2]反映了作为评价主体的人对特定环境下噪声的主观感觉, 可以较为准确地用测量和计算获得的心理声学客观参数

数来量化描述^[3], 这些参数综合考虑了人体心理反应机制和噪声感知特性, 能够反映不同噪声信号造成的主观感受差异。以心理声学客观参数为基础, 建立可以客观衡量的声品质评价模型, 对于现代汽车噪声的评价、分析与控制都具有重要意义。

长期以来, 研究者都在努力探索建立精确的以客观参量描述人的主观感觉的声品质评价模型。到目前为止, 几乎所有的声品质评价模型都是基于线性回归基础上的, 即通过对客观评价参量的多元线性组合得到声品质的主观评价模型。由于人的主观评价的随机性很强, 与各客观参量之间存在一定的非线性, 所以现有的声品质线性回归模型不能映射主客观评价之间的复杂非线性关系, 评价结果也达不到理想的程度。人工神经网络是应用效果较好的一种预测方法, 而且广泛应用其汽车行业, 文献[4]的作者应用神经网络对汽车发动机噪声进行预测取得了满意的预测结果。神经网络是由大量简单的神经元相互连接而成的自适应非线性动态系统, 具有很多其他方法难以比拟的优点: 具有极强的自

收稿日期: 2009-01-04; 修回日期: 2009-03-14

基金项目: 国家 863 计划电动汽车重大专项(2005AA501000)和上海市曙光计划项目(05SG22)及汉高公司资助。

作者简介: 申秀敏(1982-), 女, 山东聊城人, 博士研究生, 研究方向为汽车振动与噪声控制方面。

通讯作者: 申秀敏, E-mail: sxm2004_2000@163.com

学、联想、存储功能以及良好的容错能力; 可以充分逼近任意复杂的非线性关系; 能够同时处理定量、定性知识; 可学习和自适应不知道或不确定的系统; 具有高速寻找优化解的能力等^[5]。

2 车内噪声声品质分析

车内噪声声品质的好坏程度需要经过评价将其量化, 评价方法主要有主观评价和客观评价。主观评价是以人为主体, 以听审团评价的方式进行; 客观评价方法, 即用客观物理量作为评价的依据, 使用仪器进行自动评价。文献[6]以等级评分方法对采自各种不同类型国产轿车的 32 个稳态车内声音样本进行了主观评价试验, 同时以响度、尖锐度、粗糙度、抖动度和 A 声级作为客观评价参量对样本声音进行了计算。主客观评价结果如表 1 所示。

为建立精确的车内噪声声品质评价模型, 首先对主客观评价结果进行相关分析, 以确定究竟哪些客观参量对车内声品质指标具有显著的影响; 然后建立由相关性较大的客观参量描述的车内噪声声品质评价模型。

为获得相关分析的精确结果, 并对比诸如心理声学参数与 A 计权声压级和主观评价结果的相关性, 以软件 SPSS 计算出声品质主观评价结果与客观参量之间的相关系数, 结果见表 2。可以看到四种心理声学参数中的响度、尖锐度和粗糙度与声品质主观评价结果之间的相关系数较高, 绝对值基本在 0.8 以上, 而抖动度的相关系数很小; A 计权声压级与声品质评价结果相关性也较大。因此本文主要采用多层前向 BP 神经网络进行车内噪声主客观评价结果的映射曲线拟合, 实现对车内噪声声品质的预测。

表 1 车内噪声样本的主客观评价结果
Table 1 Subjective and objective evaluation results of vehicle interior noise

样本序号	主观评价结果	响度	尖锐度	粗糙度	抖动度	A 声级
1	2.79	24.029	0.7578	0.5762	0.1892	60.8
2	3.22	19.486	0.7934	0.5647	0.1972	55.6
3	3.59	30.155	0.8703	0.4857	0.2078	63
4	4.07	250855	0.7819	0.4625	0.2183	63.8
5	4.54	27.401	0.9862	0.6318	0.2674	57.7
6	4.63	18.301	0.9659	0.6931	0.3007	59.4
7	4.97	25.972	0.8984	0.6097	0.2894	61.6
8	5.55	17.415	0.9546	0.4719	0.3414	57.8
9	5.7	20.58	0.9803	0.8335	0.3667	56.4
10	5.99	22.302	0.9863	0.5467	0.3736	55.8
11	6.36	30.367	0.9345	1.2046	0.3934	73.3
12	6.55	32.134	0.8867	1.1753	0.4308	60.6
13	7.02	29.896	0.9785	1.282	0.4563	58.7
14	7.37	35.605	0.9578	1.478	0.5567	78.2
15	7.5	33.232	0.9809	0.9728	0.5707	66.4
16	7.72	38.229	1.0778	1.6523	0.4955	66.6
17	8.01	36.423	1.0676	1.5045	0.5212	75.1
18	8.24	39.672	0.9651	0.8231	0.4896	75.3
19	8.36	44.503	0.9906	1.256	0.5033	71.1
20	8.61	42.764	1.1082	1.4974	0.4735	65.4
21	8.81	41.885	0.9537	1.7023	0.5364	63.9
22	9.32	41.223	0.9641	1.0811	0.4744	72.7
23	9.97	36.506	1.0763	0.8019	0.5309	65.1
24	10.25	45.067	1.1875	1.867	0.3896	71.1
25	10.86	38.869	1.1034	1.7631	0.4186	66.5
26	11.38	51.893	1.2357	2.1764	0.2038	71.7
27	11.83	43.079	1.2045	1.6637	0.2767	74.7
28	12.14	44.357	1.097	2.1024	0.3871	72.2
29	12.082	52.859	1.0706	1.2736	0.3483	75.9
30	13.09	53.069	1.0326	1.4339	0.1822	75.4
31	13.27	54.29	1.0781	1.5348	0.2344	76.5
32	14.91	49.4	1.3116	2.0941	0.2391	73.4

表 2 车内声品质主观评价结果与客观评价参量间的相关性
Table 2 Correlation between subjective and objective evaluations of vehicle sound quality

		响度	尖锐度	粗糙度	抖动度	A 声级
主观评价结果 ($n=32$)	相关系数	0.895	0.832	0.805	0.074	0.723
	双尾检验	0.000	0.000	0.000	0.716	0.000

3 BP 神经网络基本原理与模型

BP 网络是指用反向传(Back-Propagation, BP)算法训练的具有单隐层的多层前馈式网络,目前比较成熟和应用最广泛的人工神经网络,是一种误差反向传播的多层前向反馈神经网络。理论上,一个三层 BP 网络可逼近任意非线性函数,其神经元的变换函数一般取(0, 1)内连续取值的 Sigmoid 函数^[7,8]。

3.1 BP 网络的结构模型

典型的 BP 网络一般采用三层结构,其拓扑结构如图 1 所示,包括输入层、隐含层和输出层,同层节点间无关联,异层节点之间前向全互连。输入层节点负责数据输入和预处理,首先确定初始指标体系,形成数据采集系统,然后对数据进行预处理,剔除非主要因素与随机因素,突出主要因素。隐含层实现数据计算,对研究对象进行描述、推断、模拟、评价和预测等综合分析。输出层通过对有关能反映研究对象的敏感性指标和数据的处理,将多个指标合并成一个综合性指标,用以判断研究对象的状况。




图 1 三层 BP 网络结构图
Fig.1 Three layer BP neural network

图 1 中, v 为输入层至隐含层连接权, w 为隐含层至输出层连接权。其中, 隐含层和输出层的节点具有加和与激活功能, BP 神经网络的信息处理机制正是由节点的加和与激活功能决定的。加和是指对一节点的所有输入与相应连接权重的乘积进行加和, 如图 2 隐含层的第 j 个节点的加和值为: $net_j = \sum_i x_i v_{ij}$ (net_j 为隐含层第 j 个节点的输入值, x_i 为输入层第 i 个节点的输入数据, v_{ij} 为输入层第 i

个节点向隐含层第 j 个节点分配的权重)。激活是指将加和得到的值经过一定的数学函数变换形成该节点的输出, 如图 2 隐含层第 j 个节点的输出值为:

$$o_j = f(net_j) = \frac{1}{1 + e^{-net_j}} \quad (f(\cdot) \text{ 为激活函数})。$$




图 2 网络模型结构
Fig.2 Network structure

3.2 BP 网络的学习算法与过程

BP 算法实质是将一输入输出问题变为一个非线性优化问题,即以网络连接权(v, w)为变量,误差函数 E 为目标的多元极小值问题。BP 网络的学习过程由正向传播和反向传播两部分组成。正向传播过程中,输入信息从输入层经隐含层处理并计算每个节点的实际输出传向输出层。如果在输出层得不到期望的输出,则转入反向传播,逐层递归地计算期望输出 y 与实际输出 o 的方差 ($E_k = \frac{1}{2} \sum_{j=1}^m (y_{kj} - o_{kj})^2$)

作为相应的误差测度,采用梯度下降法来调节连接权值与节点阈值,即 $w_{k+1} = w_k + \eta \cdot (\partial E / \partial w_k)$, 使误差不断减小。两个过程复交替,当网络总误差 ($E_{\text{总}} = \sum_k E_k$) 小于允许值 ϵ (精度控制参数),即网络适应了要求的映射时,网络的训练过程即告结束。

4 车内噪声声品质的 BP 神经网络预测模型

选择车内声品质主观评价量作为样本输出,客观评价参量作为样本输入。BP 网络对样本噪声“敏感”,若学习样本本身带有误差和干扰,系统输出会出现较大误差。因此,在考虑样本的多样性与均匀性的同时,应确保样本的准确性,去除异常的样本数据,防止降低网络的泛化能力^[9]。

4.1 BP 网络的建立

(1) 网络层数的确定

Robert-Hecht-Nielson 证明了对于任何在闭区间的一个连续函数都可以用一个隐层的 BP 网络来逼近,因而一个三层的 BP 神经网络可以完成任意的

映射^[10], 因此本文 BP 网络采用三层结构。

(2) 输入层节点数的确定

基于对表 1 中车内噪声样本的主客观评价的相关性分析, 与车内噪声声品质主观评价量相关性较高的影响因素为: 响度、尖锐度、粗糙度和 A 计权声压级。因此车内噪声声品质评价模型结构的输入层的神经元个数为 $n=4$, 分别为上述对应的 4 个指标。

(3) 输出层节点数的确定

由于该模型只是预测车内声品质主观评价一个因变量, 因此输出层取节点数 $p=1$ 。

(4) 隐含层节点数的确定

隐含层节点数的选取尚无理论上的指导, 只有几个经验公式, 且只能确定单元数的范围。如 $q=n+p+a$, n 、 p 分别为输入层、输出层节点数, a 为常数(取 1~10)^[11]。隐含层节点数关系到整个 BP 网络的精确度和学习效率, 因此必须根据实际运行结果, 以样本总误差最小来确定节点数。考虑到单隐含层网络的非线性映射能力较弱, 对于相同的问题, 为了达到预定的映射关系, 隐含层节点要多一些, 以增加网络的可调参数, 所以隐含层节点数初设为 12。

因此本文所建立的 BP 神经网络的拓扑结构为 4-12-1, 网络模型的结构如图 2 所示。

4.2 BP 网络训练

选取表 1 中 1~20 号共 20 个数据作为训练样本, 同时, 选取 21~32 号的 12 个数据作为测试样本。使用软件 MatlabR2007 中的神经网络工具箱(Neural Network Toolbox) newff 函数创建 BP 训练网络; 选用 traingdm 作为训练函数, 该函数以梯度下降法进行学习, 并且学习速率是自适应的。

(1) 初始化

在训练网络之前, 必须对网络的权值和阈值进行初始化, 确定学习速率、目标精度控制参数等。取初始权值在 $[-1, 1]$ 之间的随机数, 学习速率设为 0.06, 网络训练后达到的目标精度控制参数设为 0.001, 将样本模式计算器和训练次数计算器都置为 1, 误差 E 置为 0。

(2) 网络训练

获得输入和输出变量后, 要对其进行线性归一化处理^[12]: $X'_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}$, $Y'_i = \frac{Y_i - Y_{\min}}{Y_{\max} - Y_{\min}}$, 将数据转化为 $[0, 1]$ 区间的值, 以满足网络对输入输出的要求, 避免神经元出现饱和。利用上述训练好的网络模型进行预测, 所得预测误差曲线如图 3 所示, 其中横坐标代表测试次数, 纵坐标代表预测误差。




图 3 训练误差曲线
Fig.3 Training error curve

从图 3 中可以看出, 所建立的 BP 神经网络预测模型显示出较好的预测精度, 而且收敛速度快(经过 344 次训练后, 网络误差达到要求)。

5 BP 模型与多元线性回归模型的比较

利用上述所建立的 BP 网络模型对表 1 中 21~32 号样本进行预测, 并计算出与实测值之间的相对误差并与文献[6]用多元线性回归模型预测得到的结果及相对误差比较, 如表 3 所示。

表 3 基于 BP 神经网络与多元线性回归模型预测结果对比
Table 3 Comparison between prediction results of BP neural network and multiple linear regression models

样本序号	实测值	BP 神经网络模型		多元线性回归模型	
		预测值	相对误差/%	预测值	相对误差/%
21	8.81	8.17	7.24	8.69	1.38
22	9.32	8.89	4.65	8.68	7.43
23	9.97	9.45	5.21	8.96	11.25
24	10.25	9.63	6.04	11.71	12.45
25	10.86	9.92	8.65	9.68	12.16
26	11.38	10.63	6.56	13.48	15.56
27	11.83	10.90	7.85	11.51	2.74
28	12.14	11.13	8.31	10.64	14.13
29	12.082	11.76	2.62	11.94	1.15
30	13.09	12.38	5.41	11.59	12.95
31	13.27	12.40	6.52	12.29	7.99
32	14.91	14.24	4.50	13.80	8.03

由表 3 的结果可见, 通过所建立的 BP 神经网络模型对表 1 中的 21~32 号样本进行预测之后得到的结果比较理想, 所有预测值的相对误差都在 10% 的范围之内, 而单独使用多元线性回归模型预测, 误差范围在 10% 之内的结果只有 42%, 且其预测结果的误差波动较大, 模型预测结果不理想。BP 模型的模拟精度高于多元线性回归模型。而且 BP 模型自身具有学习训练功能, 可以建立各种非线性映射, 使用方便, 并且精度可以人为控制。

6 结 论

基于 BP 神经网络的车内噪声声品质预测可以考虑较多影响因素,既可以是定量因素,也可以是定性或不确定因素,可以解决声品质预测中存在的非线性问题,同时预测结果与传统的多元线性回归模型相比精确度较高。另一方面,当客观评价参量发生变化,可以通过改变参数、重新训练网络,实现车内声品质预测的动态化。本文所建立的车内噪声声品质的 BP 神经网络预测模型不但可为车内噪声声品质的预测提供一定的指导意见,同时也证明了本文所建立的车内噪声声品质预测模型的可行性。

虽然人工神经网络能够解决声品质预测方面的不少问题,但仍存在许多问题,如所选取学习样本的数量和质量很大程度上影响着神经网络模型的学习性能、网络层数,隐含层神经元数的选取也影响整个网络的学习能力和学习效率以及如何解决样本误差带来的影响等,上述问题在实践中有待于进一步改进。

参 考 文 献

- [1] Blauert J. Aesthetic and cognitive aspects of noise engineering[C]. Proc. InterNoise'86, CambridgeMA, 1986, 1: 3-14.
- [2] SchneiderMatthias, Wilhelm Michael. Development of vehicle sound quality targets and methods[A]. //SAE International[C]. 971-976.
- [3] HeinrichsBoddenM. Sound quality evaluation of interior vehicle noise using an efficient psychoacoustic method[A]. //Proc of Euronoise 98[C]. 1998.
- [4] 段敏,王岩松,石晶. 基于神经网络的发动机噪声的预测[J]. 汽车工程, 2002; 24(6): 508-510.
DUAN Min, WANG Yansong, SHI Jing. Prediction of the noise in engine based on neural network[J]. Automotive Engineering, 2002, 24(6): 508-510.
- [5] WEN Xin. MATLAB neural network: simulation and application[M]. Beijing: Science Press, 2003(in Chinese).
- [6] 刘宗巍. 车内噪声声品质建模分析与自适应主动控制研究[D]. 吉林大学, 2007.
LIU Zongwei. Research on model analysis and adaptive active control for sound quality of vehicle interior noise[D]. Jilin University, 2007.
- [7] 飞思科技产品研发中心. 神经网络理论与 MATLAB 7 实现[M]. 北京: 电子工业出版社, 2005.
R&D center of Feisi IT products. Neural network Theory and MATLAB 7 realization[M]. Beijing: Electronics Industry Press, 2005.
- [8] 王灵敏,宋希庚,薛冬新. 基于神经网络的热气机功率预测[J]. 振动、测试与诊断. 2002; 22(2): 820-825.
WANG Lingmin, SONG Xigeng, XUE Dongxin. Performance prediction for stirling engine using neural network[J]. Journal of Vibration, Measurement & Diagnosis, 2002, 22(2): 820-825.
- [9] 吴微,陈维强,刘波. 用 BP 神经网络预测股票市场涨跌[J]. 大连理工大学学报, 2001, 41(1): 9-15.
WU Wei, CHEN Wei-qiang, LIU Bo. Prediction of ups and downs of stock market by BP neural networks[J]. Journal of Dalian University of Technology, 2001, 41(1): 9-15.
- [10] 曹民书,杜清玲. 基于 BP 神经网络的人力资源需求预测[J]. 山东理工大学学报(自然科学版), 2008, 22(5): 26-29.
CAO Shumin, DU Qingling. Human resources demand forecast based on back-propagation neural network[J]. Journal of shandong University of Technology(Natural Science Edition), 2008, 22(5): 26-29.
- [11] 程屿菲,聂规划. BP 网络在企业管理中的应用研究[J]. 武汉理工大学学报(信息与工程版), 2004, 26(4): 139-142.
CHENG Yufei, NIE Guihua. Study of the application of BP network to business administration[J]. Journal of Wuhan Automotive Polytechnic University, 2004, 26(4): 139-142.
- [12] Neural Network Toolbox. Math Work, 2007.