

# 基于数据驱动的汽车部件温度预测模型研究

李淮<sup>1</sup>, 张晓东<sup>1</sup>, 张传鸿<sup>2</sup>, 陈心欣<sup>1</sup>, 赵雪茹<sup>1</sup>, 揭敢新<sup>1</sup>

(1.中国电器科学研究院股份有限公司, 广州 510663; 2.南京航空航天大学, 南京 210016)

**摘要:** **目的** 基于某汽车在中国吐鲁番地区自然暴露的部件温度变化试验数据, 预测该车在美国凤凰城地区气象环境下的汽车部件温度变化。**方法** 把汽车部件的温度作为输出变量, 提取影响汽车部件温度变化的关键特征(试验时间、大气温度、太阳辐照)作为输入变量, 同时运用公式对不同纬度地区部件受到的太阳辐照进行修正, 以消除地理位置的影响。利用 Python 等软件构建机器学习模型, 用吐鲁番试验数据训练模型, 然后预测该车部件在美国凤凰城地区的温度变化。**结果** 梯度提升机模型具有良好的泛化能力和预测精度, 其预测值与实际值的平均绝对误差均在 3.3°以内, 拟合优度  $R^2$  均大于 0.90。BP 神经网络和随机森林算法模型也具有较好的预测精度。**结论** 利用汽车在我国试验站点进行的自然暴露试验数据, 可以预测该汽车部件在国外相似地区气象条件下的温度变化。该研究对于依据汽车部件在我国的自然暴露试验结果预测其他国家相似地区自然环境下汽车部件的温度变化具有一定的指导意义。

**关键词:** 大数据分析; 神经网络; 机器学习; 汽车自然暴露试验

中图分类号: U467.1+3

文献标识码: A

文章编号: 1672-9242(2023)02-0102-08

DOI: 10.7643/issn.1672-9242.2023.02.014

## Temperature Prediction Model of Auto Parts Based on Data Driven

LI Huai<sup>1</sup>, ZHANG Xiao-dong<sup>1</sup>, ZHANG Chuan-hong<sup>2</sup>, CHEN Xin-xin<sup>1</sup>, ZHAO Xue-ru<sup>1</sup>, JIE Gan-xin<sup>1</sup>

(1. China National Electric Apparatus Research Institute Co., Ltd, Guangzhou 510663, China;

2. Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

**ABSTRACT:** The work aims to predict the temperature changes of the parts of a car in the Phoenix area of the United States based on the test data of the temperature changes of the parts of the car naturally exposed in Turpan, China. With the temperature of the auto parts was taken as the output variable, the key features that affect the temperature changes of the auto parts (test time, atmospheric temperature, solar radiation) were extracted as the input variables. At the same time, a formula was used to correct the solar radiation of parts in different latitudes to eliminate the effects of geographic location. Software such as python were used to build a machine learning model. The test data in Turpan were used to train the model, and then the temperature change of the auto parts in the Phoenix area of the United States was predicted. The prediction results showed that the gradient boosting algorithm model had good generalization ability and prediction accuracy. The average absolute error between the predicted value and the actual value was within 3.3 degrees, and the goodness of fit  $R^2$  was greater than 0.90. The BP neural network and random forest algorithm models also had good prediction accuracy. Using the natural exposure test data of a car at a test site in my country could predict the temperature changes of auto parts under the meteorological conditions in similar regions abroad. The

收稿日期: 2021-11-03; 修订日期: 2022-02-25

Received: 2021-11-03; Revised: 2022-02-25

作者简介: 李淮(1984—), 男, 工程师, 主要研究方向为汽车耐候性技术及机器学习算法。

**Biography:** LI Huai (1984+), Male, Engineer, Research focus: automobile weatherability technology and machine learning algorithm.

**引文格式:** 李淮, 张晓东, 张传鸿, 等. 基于数据驱动的汽车部件温度预测模型研究[J]. 装备环境工程, 2023, 20(2): 102-109.

LI Huai, ZHANG Xiao-dong, ZHANG Chuan-hong, et al. Temperature Prediction Model of Auto Parts Based on Data Driven[J]. Equipment Environmental Engineering, 2023, 20(2): 102-109.

research in this work has certain guiding significance for predicting the temperature changes of auto parts under the natural environment of similar regions in other countries based on the results of the natural exposure test of auto parts in China.

**KEY WORDS:** big data analysis; neural network; machine learning; outdoor exposure test of vehicle

随着中国装备“走出去战略”的推进和中国产品全球化的实施, 中国汽车走出国门的步伐已经势不可挡。小汽车是非常便捷的通勤交通工具, 在其生命周期内, 会受到光(太阳辐射)、热(高温)、水(潮湿的空气、雨水等)、空气污染物等各种环境因素的影响<sup>[1]</sup>, 从而对汽车材料进行破坏, 使其发生老化、腐蚀等现象, 轻则影响汽车的感官品质及使用寿命, 重则会导致汽车功能失效, 甚至对车主的人身安全产生严重影响<sup>[2]</sup>。整车强化腐蚀试验以及自然暴露试验是验证汽车耐候性设计, 以及选用材料的耐候性性能是否达到设计要求的重要手段。整车强化腐蚀试验是根据 QCT 732—2005 或 GMW 8738—2005 要求进行的, 考察汽车金属部件的抗腐蚀能力<sup>[3-6]</sup>, 而整车自然暴露试验不仅可以考察金属部件及涂镀层的抗腐蚀能力, 同时也可检验非金属材料的抗老化性能<sup>[7-10]</sup>。整车自然暴露试验通常是按照 GB/T 40512—2021<sup>[11]</sup> 或 QC/T 728—2005<sup>[12]</sup> 的要求, 把汽车静置于干热试验场或是湿热试验场进行为期 1~2 a 的暴露试验, 最后以汽车部件的缺陷数量以及缺陷程度作为该车耐候性的评判指标<sup>[13]</sup>。

对于在国外进行自然暴露试验必然会增加企业成本及时间, 目前虽然数值仿真计算已经应用于汽车的整车温度场以及车身内部的流场计算<sup>[14-18]</sup>, 但是仿真计算需要准确预设出汽车部件的各项物理特性, 否则仿真结果的误差会很大, 在现实使用过程中具有一定的局限性。因此, 运用机器学习大数据分析手段来预测汽车自然暴露时的温度变化对于汽车企业具有重要的意义。目前在各个领域的数据挖掘实践中, 机器学习算法模型已经是广泛应用的手段之一, 如在光伏发电功率预测<sup>[19]</sup>、高分子材料性能预测<sup>[20-21]</sup>上均有大量应用。本文以某型汽车整车在吐鲁番的自然暴露试验数据, 预测在美国亚利桑那州凤凰城地区自然暴露过程中部件的温度变化。通过对多种机器学习模型的预测结果进行比对, 结果表明, BP 神经网络模型、随机森林和梯度提升机模型均具有良好的泛化能力和预测精度。本文研究对于依据我国地区自然暴露试验结果, 预估国外相似气候地区环境下汽车外部件的温度变化具有一定的指导意义。

## 1 整车自然暴露试验

根据 QC/T 728—2005 的要求, 将汽车整车置于工业产品环境适应性国家重点实验室吐鲁番干热自然暴露试验场以及美国亚利桑那州自然暴露试验场

内进行静置暴露试验, 连续实时监测汽车典型零部件的表面温度以及大气环境参数, 每 5 min 记录 1 次数据。

## 2 数据预处理

### 2.1 相关性分析及特征选取

选取空气温度、大气湿度、风速、太阳总辐照作为比较数列, 参考数列分别取车顶中部外表面温度、右外后视镜壳上表面温度、前保险杠中部(商标处)表面温度。分别计算 3 个测点温度与大气环境的斯皮尔曼(Spearman)相关性系数, 斯皮尔曼相关系数计算方法<sup>[22]</sup>为:

$$r = 1 - \frac{6 \sum d^2}{n(n^2 - 1)} \quad (1)$$

式中:  $d$  为汽车部件温度序列(参考数列)和特征序列(比较数列)的等级差数;  $n$  表示序列个数。当  $|r| < 0.3$  时, 表示 2 数列是弱相关; 当  $0.3 < |r| < 0.5$  时, 表示低度相关; 当  $0.5 < |r| < 0.8$  时, 表示中度相关; 当  $|r| > 0.8$  时, 表示高度相关。斯皮尔曼相关性结果如图 1 所示。

由图 1 可知, 汽车部件表面温度与大气温度和太阳总辐照的相关性最强, 与风速的相关性最弱, 而与大气相对湿度有一定的相关性。考虑到异地之间的相对湿度可能有很大差异, 如果把差异比较大的因子放入模型会导致模型的泛化性变差。因此, 选取大气温度、汽车部件受到的太阳总辐照作为关键特征, 不考虑相对湿度。

除了将大气温度和部件受到的太阳辐照作为关键特征外, 另外再选取当地时间作为特征参数。把时间、日期、节气等作为机器学习模型的特征参数<sup>[23]</sup>, 在其他领域也有被广泛应用。由于吐鲁番数据记录用的是北京时间, 需要把该时间转换成地方时作为特征参数。将时间转成地方时, 主要是使得数据本身更具有规律性, 因为地方时中午 12 点时, 太阳在当地的经线上, 太阳高度角最大。

将时间、大气温度、部件受到的太阳总辐照作为模型的输入参数, 汽车部件(车顶中部外表面、右外后视镜壳上表面温度和前保险杠中部商标处)表面温度作为输出参数。输出参数为 1 个, 对于 3 个部件分别建立 3 个模型进行预测。本文将吐鲁番的数据集随机抽取 80% 作为训练集, 其余 20% 作为验证集, 而美国亚利桑那州数据集作为测试集数据。




图1 汽车部件温度变化与气象环境的斯皮尔曼相关系数  
 Fig.1 Spearman's correlation coefficient between temperature changes of auto parts and meteorological environment: a) outer surface of middle roof; b) upper surface of right outer rearview mirror housing; c) surface of the middle of the front bumper (at trademark)

汽车部件受到的等效太阳辐照值  $R$  的近似计算方法为:

$$R = A / \sin(H + \alpha_n) \times \sin(H + \alpha_{car}),$$

$$H = 90 - (\beta + \beta_s) \tag{2}$$

式中:  $A$  为太阳辐照计的测量值;  $\beta$  为进行试验地区的纬度;  $\beta_s$  为当日太阳直射点的地理纬度, 且当试验地区与当日太阳直射点位于同一半球时,  $\beta_s$  取值为负数, 当试验地区与当日太阳直射点位于不同半球时,  $\beta_s$  取值为正数; 由于吐鲁番和美国凤凰城地区的纬度均大于北回归线的纬度, 因此  $H$  为试验地区当地时正午时刻的太阳高度角, 本文利用 Python 的 Pysolar 库中的 Solar 模块计算吐鲁番和美国凤凰城 2 地每日正午时分(地方时)的高度角;  $\alpha_n$  为太阳辐照计的测量平面与水平面之间的夹角, 在测量地区位于北半球的情况下, 辐照计朝正南倾斜时  $\alpha_n$  取正值, 朝正北倾斜时  $\alpha_n$  取负值, 南半球的情况下取值相反;

$\alpha_{car}$  为部件表面监测点切面与南北(当地经线)方向之间的锐角夹角, 在试验地区位于北半球的情况下,  $\alpha_{car}$  在所述表面监测点切面的外侧(即表面监测点切面背向被测汽车部件的一侧)面向南方和北方时, 分别取正值和负值, 南半球的情况下, 取值相反。

## 2.2 数据归一化

数据归一化方法是机器学习模型在训练和预测前对数据常做的一种处理手段, 目的是消除各维度数据间数量级的差别, 从而避免因输入输出数据数量级差别较大而造成网络预测误差较大。数据归一化主要有 2 种形式, 分别为数据规范化和标准化<sup>[24-25]</sup>。

数据规范化是把所有数据转化成 0~1 的值, 其函数形式为:

$$x_t = (x_t - x_{min}) / (x_{max} - x_{min}) \tag{3}$$

式中:  $x_{min}$ 、 $x_{max}$  分别为数列中的最小、最大数值。

数据标准化是移动其分布, 使得数据的平均值为 0, 标准差为 1。其函数形式为:

$$x_t = (x_t - x_{mean}) / x_{var} \tag{4}$$

式中:  $x_{mean}$  为数列中的均值;  $x_{var}$  为数列的方差。

一般情况下, 使用数据规范化进行数据预处理即可。如果每种特征数据的取值范围差异很大, 普遍的做法是对每个特征做数据标准化处理<sup>[26]</sup>。时间的取值范围为 0~24 h, 大气温度取值范围大致为 -20~40 °C, 太阳辐照的取值范围为 0~1 400 W/(m<sup>2</sup>·s)。由于时间和大气温度的取值范围与太阳辐照的取值范围差异较为明显, 故本文采用标准化对数据进行归一化处理。

## 3 构建模型

本节对汽车部件表面温度变化构建预测模型, 并用训练集数据训练模型, 采用的机器学习模型分别为: BP 神经网络、梯度提升机和随机森林。其中, BP 神经网络和随机森林模型是利用 Python 软件的 Scikit-learn 库搭建, 梯度提升机是通过 Python 的 Xgboost 库搭建。使用训练集数据进行模型训练, 通过对比不同超参数<sup>[27]</sup>模型下验证集数据的性能优劣选取最优的模型, 然后用训练集和验证集数据在选定的模型上重新训练模型, 以得出最终的预测模型, 最后用测试集数据检验模型的预测性能。

### 3.1 BP 神经网络模型

BP 神经网络是信息从正向逐层向前进行传递, 而误差通过反向传播回来的一种网络结构。该神经网络使用梯度下降法调整各层神经元的权重和偏置, 从而达到网络误差缩小的目的<sup>[28-29]</sup>。根据 Kolmogorov 定理, 一个 3 层 BP 神经网络可以完成任意  $n$  维空间到  $m$  维空间的映射。本文神经网络模型是利用 Python 软件的 Scikit-learn 模块搭建的 3 层 BP 神经网络, 神

经网络的激活函数设置为 Sigmoid 函数, 学习算法为 “Adam” 算法, 最大迭代步数为 1 000 步, 学习率设置为 0.005。

隐含层神经元的个数对预测精度会产生较大影响, 若神经元个数过多, 会导致训练时间增加, 并且泛化能力降低; 若神经元个数过少, 网络的学习能力下降, 会导致训练误差增大。根据经验公式确定神经元个数的大致范围, 最佳隐含层节点数的选择参考式 (5)、(6) [25,30]。

$$L < \sqrt{m+n+a} \tag{5}$$

$$L = \sqrt{m+n+1+a} \tag{6}$$

式中:  $n$  为输入层节点数;  $m$  为输出层节点数;  $a$  为 0~10 的常数;  $L$  为隐含层节点数。

隐含层节点数选取 5~12 个, 分别对各项训练集数据进行神经网络训练, 然后查看验证集的性能情况, 性能以平均绝对误差 MAE 作为评判, 结果如图 2 所示。从图 2 可以看出, 对于 “车顶中部表面” “右外后视镜壳上表面” 和 “前保险杠中部 (商标处) 表面”, 当隐含层神经元个数分别为 10、10、11 时, 神经网络的预测性能最优。分别选取隐含层神经元




图 2 隐含层节点数量对模型预测性能的影响

Fig.2 Effects of the number of hidden layer nodes on the prediction performance of the model: a) outer surface of middle roof; b) upper surface of right outer rearview mirror housing; c) surface of the middle of the front bumper (at trademark)

个数为 10、10、11, 对上述部件构建 3 层 BP 神经网络, 网络结构如图 3 所示。将训练集和验证集数据带入重新训练模型, 将训练好的 3 个模型作为最终的预测模型。




图 3 实际构建的 BP 神经网络结构

Fig.3 BP neural network structure actually constructed

### 3.2 梯度提升算法模型

梯度提升算法是在函数空间中进行最优函数的搜索。对于模型的损失函数  $L[y, F(x)]$ , 需要求解出最优的函数  $F^*(x)$ 。以函数  $F(x)$  作为一个整体, 与梯度下降法的更新过程一致, 经过  $N$  次迭代后, 得到最优的函数  $F^*(x)$  为:

$$F^*(x) = \sum_{t=0}^T f_t(x),$$

$$f_t(x) = -\alpha_t * \left[ \frac{\delta L(y, F(x))}{\delta F(x)} \right]_{F(x)=F_{t-1}(x)} \tag{7}$$

式中:  $\alpha$  为步长。初始状态时,  $F_0(x) = f_0(x)$ 。

这里的梯度变量是一个函数, 更新函数通过当前函数的负梯度方向来修正模型, 使模型更优, 最后累加的模型为近似最优函数。本文的梯度提升机是通过 Python 的 Xgboost 库搭建的, 梯度提升树设置为 100 个 ( $n\_estimator=100$ ), 最大树深度为 30 ( $max\_depth=30$ ), 学习速率设为 0.03 ( $learning\_rate=0.03$ ), 其他参数为默认值。

### 3.3 随机森林模型

随机森林的弱分类器使用的是分类回归树 (CART), 该算法是一个二叉树, 即每一个非叶节点只能引申出 2 个分支。当数据集的因变量为连续性数值时, 该树算法就是一个回归树, 可以用叶节点观察的均值作为预测值; 当数据集的因变量为离散型数值时, 该树算法就是一个分类树, 可以很好地解决分类问题。相较于决策树, 随机森林的抗过拟合能力更强。本文随机森林算法模型采用 Python 的 Scikit-learn 模块搭建, 模型由 100 棵二叉决策树 (CART) 组合而成, CART 没有最大深度限制 ( $max\_depth=None$ ), 最大特征设置为总特征乘以 0.8 ( $max\_features=0.8$ ), 其他参数为默认值。


## 4 预测结果分析

### 4.1 模型评估方法

评估模型的预测能力可通过 2 个方面进行判断：一方面是预测值与实际值之间的距离，本文采用平均绝对误差 (MAE)  $\eta_{MAE}$  作为评价指标，该值越接近 0，表示预测效果越好；另一方面是拟合优度  $R^2$  (即决定系数)，该值越接近于 1，表示预测效果越好，分别见式 (8) 和式 (9)。

$$\eta_{MAE} = \sum_{i=1}^m abs(y_i - yy_i) \quad (8)$$

$$R^2 = \frac{\sum_{i=1}^m (y_i - yy_i)^2}{\sum_{i=1}^m (y_i - y_{mean})^2} \quad (9)$$



式中:  $y$  表示实际值;  $y_{mean}$  表示实际值的平均值;  $yy$  表示预测值。

### 4.2 预测结果

将美国亚利桑那州试验的数据集 (测试集数据) 分别代入训练好的神经网络模型中进行预测, 结果如图 4 所示。通过计算结果可以看出, 对于 3 个部件的预测中, 梯度提升机模型的预测结果最佳, 神经网络和随机森林也有较好的预测结果。3 个汽车部件对应的 3 个梯度提升机模型的平均绝对误差分别为 2.48、3.25、2.46, 对应的拟合优度为: 0.971、0.901、0.919。可以看出, 该模型具有较高的预测精度, 可以用该方法预测汽车部件在相似气候地区环境下的温度变化。因此, 本文采用梯度提升机模型的预测结果进行详细分析。




图 4 3 种机器学习模型预测结果

Fig.4 Prediction results of three machine learning models

梯度提升机模型对车顶中部外表面、右外后视镜壳上表面、前保险杠中部表面 (商标处) 的温度预测值与真实值对比分别如图 5—7 所示。从图 5—7 可以看出, 3 个部件温度的预测误差分布基本上呈现正态分布。车顶中部外表面温度预测分布图以  $0^{\circ}$  误差为对称轴, 绝大多数的误差在  $-5^{\circ} \sim +5^{\circ}$ ; 右外后视镜壳上表面温度预测误差分布图基本上以  $-2^{\circ}$  误差为对称轴, 表明总体的预测值比实际值偏小, 绝大多数的误差在  $-5^{\circ} \sim +13^{\circ}$ , 说明该部件的预测模型预测效果较差; 前保险杠中部温度预测误差分布图基本上以  $-1.5^{\circ}$  误差为对称轴, 表明总体的预测值比实际值偏小, 绝大多数的误差在  $-4^{\circ} \sim +10^{\circ}$ 。

出现上述现象的原因是, 车顶部位所在平面基本上与水平面平行, 不会被遮挡, 并且用式 (2) 对部件在不同地区受到的太阳辐照进行修正, 使得模型能达到更好的预测能力。对于右外后视镜壳部位和前保险杠中部位置, 随着太阳东起西落, 个别时刻是照射不到太阳的, 不同地区由于地理纬度不同, 被太阳照射到的时间点不同, 导致该部位的预测效果不如车顶部位。又由于式 (2) 对部件受到的太阳辐照修正并




图 5 梯度提升机模型预测结果与真实值对比图 (车顶中部外表面)

Fig.5 Comparison between the prediction results of and the true value the gradient hoist model (outer surface of middle roof): a) comparison chart of some predicted value and true value; b) error distribution diagram

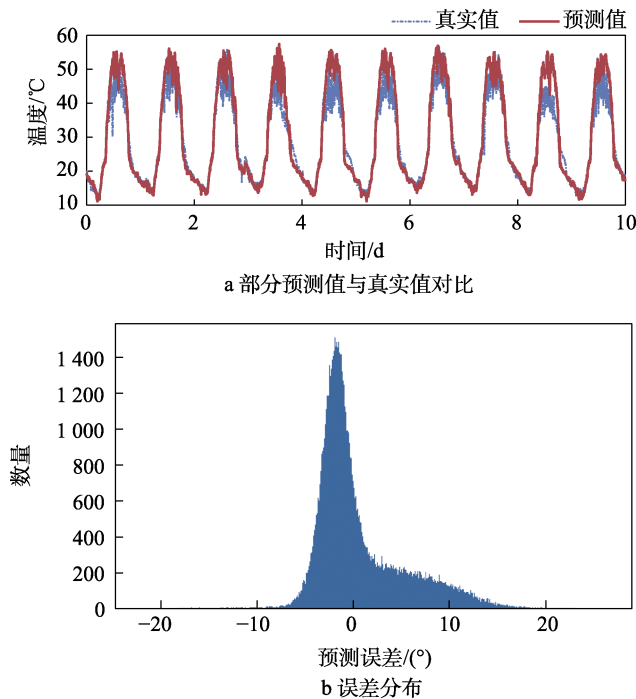


图 6 梯度提升机模型预测结果与真实值对比图  
(右外后视镜壳上表面)

Fig.6 Comparison between the prediction results and the true value of the gradient hoist model (upper surface of right outer rearview mirror housing): a) comparison chart of some predicted value and true value; b) error distribution diagram




图 7 梯度提升机模型预测结果与真实值对比  
(前保险杠中部表面)

Fig.7 Comparison between the prediction results and the true value of the gradient hoist model (the surface of the middle of the front bumper): a) comparison chart of some predicted value and true value; b) error distribution diagram

不完美,具有一定的极限性。因为只有当太阳位置处

在当地经线上(当地时正午时刻)时,该公式的修正值是准确的,太阳位置偏离当地经线越大,该公式的计算误差就会增大。考虑到汽车温度主要受太阳辐照和空气温度的影响,并且正午太阳的辐照强度最大,用式(2)对部件受到的辐照进行修正具有现实意义。要更准确地计算出部件所受到的太阳辐照值,需要精确计算出当地太阳每时每刻的高度角和方位角,从而才可精确计算出每个时刻点部件所受到太阳辐照值。由于精确计算部件受到太阳辐照的成本较大,以及计算过程较为复杂,本文采用式(2)对部件受到辐照进行近似修正计算。

## 5 结论

本文采用机器学习算法模型对整车大气暴露试验中汽车部件的温度进行了预测,通过研究可得到如下结论:

1) 通过选取时间、大气温度和汽车部件受到的太阳辐照值作为特征参数,采用 BP 神经网络、梯度提升机、随机森林等机器学习算法构建预测模型,均能达到较好的预测效果,其中梯度提升机模型的预测结果最佳。

2) 利用式(2)修正后的汽车部件受到的太阳辐照值  $R$  作为特征参数,可得到较好的预测效果。当太阳位置处在当地经线上(当地时正午时刻)时,该公式的修正值是准确的,太阳位置偏离当地经线越大,该公式的计算误差就会增大。考虑到汽车温度主要受太阳辐照和空气温度的影响,并且正午太阳的辐照强度最大,用式(2)对部件受到的辐照进行修正具有现实意义。

3) 利用我国国内的试验站点对汽车进行试验,可以对国外相似地区气象条件下的汽车部件温度变化进行预测。

## 参考文献:

- [1] 杨安志, 王文涛, 赵福全. 汽车气候老化主要环境影响因素分析[J]. 环境技术, 2011, 36(6): 39-42.  
YANG An-zhi, WANG Wen-tao, ZHAO Fu-quan. Analysis of Major Environmental Factors for Automotive Weather Aging[J]. Environmental Technology, 2011, 36(6): 39-42.
- [2] 王剑. 汽车产品在典型自然环境下的老化行为与服役寿命预测研究[D]. 广州: 广东工业大学, 2018.  
WANG Jian. Study on Aging Behavior and Service Life Prediction of Automotive Products under Typical Natural Environment[D]. Guangzhou: Guangdong University of Technology, 2018.
- [3] 厉承龙. 乘用车强化腐蚀试验及防腐措施[J]. 汽车工程师, 2015(2): 18-20.  
LI Cheng-long. Vehicle Corrosion Test and Corrosion

- Protection Measures[J]. *Auto Engineer*, 2015(2): 18-20.
- [4] 刘东俭. 整车腐蚀试验及评价方法的研究[D]. 长春: 吉林大学, 2020.  
LIU Dong-jian. Research on Vehicle Corrosion Test and Evaluation Method[D]. Changchun: Jilin University, 2020.
- [5] 宛萍芳, 陈拯, 于金鑫, 等. 乘用车强化腐蚀试验中划线腐蚀问题的分析[J]. *汽车工艺与材料*, 2010(10): 44-46.  
WAN Ping-fang, CHEN Zheng, YU Jin-xin, et al. Analysis of Scribed Corrosion in Enhanced Corrosion Test of Passenger Cars[J]. *Automobile Technology & Material*, 2010(10): 44-46.
- [6] 刘东俭, 沈玥, 朱淮烽. 整车强化腐蚀试验转场判定的方法[J]. *装备环境工程*, 2019, 16(8): 21-27.  
LIU Dong-jian, SHEN Yue, ZHU Huai-feng. Evaluation Method for Test Ground Transferring of Vehicle Corrosion Test[J]. *Equipment Environmental Engineering*, 2019, 16(8): 21-27.
- [7] 庄奕玲, 张齐健. 汽车涂层耐老化性能的研究[J]. *汽车技术*, 2004(7): 26-30.  
ZHUANG Yi-ling, ZHANG Qi-jian. Study on Ageing Resistance of Automotive Coat[J]. *Automobile Technology*, 2004(7): 26-30.
- [8] 张春花. 汽车油漆涂层及塑料制件的老化性能评价方法[J]. *机电工程技术*, 2010, 39(7): 57-58.  
ZHANG Chun-hua. The Evaluation Method for Automotive Coating and Polymer Materials Product Aging Properties[J]. *Mechanical & Electrical Engineering Technology*, 2010, 39(7): 57-58.
- [9] 颜景莲, 王玲, 梁星才. 汽车用高分子材料的老化测试技术及进展[J]. *汽车工艺与材料*, 2004(11): 29-32.  
YAN Jing-lian, WANG Ling, LIANG Xing-cai. Aging Test Technology and Development of Automotive Macromolecule Materials[J]. *Automobile Technology & Material*, 2004(11): 29-32.
- [10] 王俊, 揭敢新, 彭坚. 汽车保险杠用聚丙烯材料的老化研究[J]. *装备环境工程*, 2010, 7(3): 10-13.  
WANG Jun, JIE Gan-xin, PENG Jian. Study on Aging of PP Materials for Auto Bumper[J]. *Equipment Environmental Engineering*, 2010, 7(3): 10-13.
- [11] GB/T 40512—2021, 汽车整车大气暴露试验方法[S].  
GB/T 40512—2021, Test Method of Exposure to Weathering for Motor Vehicle[S].
- [12] QC/T 728—2005, 汽车整车大气暴露试验方法[S].  
QC/T 728—2005, Test Method of Exposure to Weathering for Motor Vehicle[S].
- [13] 王剑, 潘晓涛, 郑俊, 等. 某车型在海南湿热环境中的整车耐候性[J]. *腐蚀与防护*, 2019, 40(2): 131-136.  
WANG Jian, PAN Xiao-tao, ZHENG Jun, et al. Weather Resistance of a New Vehicle in Damp-Hot Environment of Hainan[J]. *Corrosion & Protection*, 2019, 40(2): 131-136.
- [14] CHAKROUN W, AL-FAHED S. Thermal Comfort Analysis Inside a Car[J]. *International Journal of Energy Research*, 1997, 21(4): 327-340.
- [15] SHOJAE M H, TEHRANI F P H, NOORPOOR A R, et al. Analysis of Vehicle Passenger Compartment HVAC Using Simulation[C]//SAE Technical Paper Series. Warrendale: SAE International, 2004.
- [16] CHIEN C H, JANG J Y, CHEN Y H, et al. 3-D Numerical and Experimental Analysis for Airflow within a Passenger Compartment[J]. *International Journal of Automotive Technology*, 2008, 9(4): 437-445.
- [17] 李丽芬. 自然暴露下汽车乘员舱及内外部件热负荷规律仿真与试验研究[D]. 广州: 华南理工大学, 2015.  
LI Li-fen. Simulation and Experimental of Vehicle Cabin and Components Thermal Load under Natural Exposure[D]. Guangzhou: South China University of Technology, 2015.
- [18] 陈吉清, 郭巧嫣, 李丽芬, 等. 老化试验过程中汽车内外表面传热特性和温度场变化的研究[J]. *汽车工程*, 2015, 37(11): 1253-1259.  
CHEN Ji-qing, GUO Qiao-yan, LI Li-fen, et al. A Research on the Heat Transfer Characteristics and Temperature Field Change of Vehicle Internal and External Surfaces during Ageing Test[J]. *Automotive Engineering*, 2015, 37(11): 1253-1259.
- [19] LIU Lu-yao, ZHAO Yi, CHANG Dong-liang, et al. Prediction of Short-Term PV Power Output and Uncertainty Analysis[J]. *Applied Energy*, 2018, 228: 700-711.
- [20] LIU Ting-li, LIU Lun-yang, CUI Feng-chao, et al. Predicting the Performance of Polyvinylidene Fluoride, Polyethersulfone and Polysulfone Filtration Membranes Using Machine Learning[J]. *Journal of Materials Chemistry A*, 2020, 8(41): 21862-21871.
- [21] SUN Wen-bo, ZHENG Yu-jie, YANG Ke, et al. Machine Learning-Assisted Molecular Design and Efficiency Prediction for High-Performance Organic Photovoltaic Materials[J]. *Science Advances*, 2019, 5(11): eaay4275.
- [22] 吴超勇. 大数据驱动的轴承寿命预测关键技术研究[D]. 武汉: 华中科技大学, 2017.  
WU Chao-yong. Research on Key Technologies of Big Data-Driven Bearing Useful Life Prediction[D]. Wuhan: Huazhong University of Science and Technology, 2017.
- [23] HAN Shuang, ZHANG Lu-na, LIU Yong-qian, et al. A Data Sample Division Method for Wind Power Prediction Based on China's 24 Solar Terms[J]. *International Transactions on Electrical Energy Systems*, 2020, 30(7): 834-851.
- [24] TOMASZ D. 数据分析实战[M]. 刁寿钧译. 北京: 机械工业出版社, 2018.  
TOMASZ D. Practical Data Analysis Cookbook[M]. DIAO Shou-jun Translated. Beijing: China Machine Press, 2018.
- [25] 王小川, 史峰, 郁磊. MATLAB神经网络43个案例分析[M]. 北京: 北京航空航天大学出版社, 2013.  
WANG Xiao-chuan, SHI Feng, YU Lei. Analysis of 43 Cases of MATLAB Neural Network[M]. Beijing: Beijing

- University of Aeronautics & Astronautics Press, 2013.
- [26] 弗朗索瓦·肖莱. Python 深度学习[M]. 张亮译. 北京: 人民邮电出版社, 2018.
- CHOLLET François. Deep Learning with Python[M]. ZHANG Liang Translated. Beijing: Posts & Telecom Press, 2018.
- [27] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
- ZHOU Zhi-hua. Machine Learning[M]. Beijing: Tsinghua University Press, 2016.
- [28] TARIQ R. Python 神经网络编程[M]. 林赐译. 北京: 人民邮电出版社, 2018.
- TARIQ R. Make Your Own Neural Network[M]. LIN Ci Translated. Beijing: Posts & Telecom Press, 2018.
- [29] LEWIS N D. Python 深度学习[M]. 颀青山译. 北京: 人民邮电出版社, 2018.
- LEWIS N D. Deep Learning Step by Step with Python[M]. ZHUAN Qing-shan Translated. Beijing: Posts & Telecom Press, 2018.
- [30] KŮRKOVÁ V. Kolmogorov's Theorem and Multilayer Neural Networks[J]. Neural Networks, 1992, 5(3): 501-506.

责任编辑: 刘世忠