

文章编号: 1000-8055(2023)08-1956-09

doi: 10.13224/j.cnki.jasp.20220590

基于机器学习的煤油液滴蒸发模型探索

王 方^{1,2,3}, 韩琪炜¹, 蔡江涛¹, 李典望¹, 甘 甜¹, 金 捷^{1,2,3}

- (1. 北京航空航天大学 能源与动力工程学院 航空发动机数值仿真研究中心, 北京 100191;
2. 北京航空航天大学 江西研究院, 南昌 330096;
3. 北京航空航天大学 成都航空动力创新研究院, 四川 彭州 611930)

摘 要: 基于厚交换层液滴蒸发理论以及煤油的实验数据, 通过机器学习理论中的线性回归、随机森林、支持向量机、极致梯度提升回归和全连接神经网络方法构建煤油液滴的蒸发模型, 检验新构建模型的适用范围和精度。对比实验数据和传统模型、机器学习蒸发模型的预测结果, 发现随机森林方法和极致梯度提升回归方法生成的蒸发模型不能合理外推, 支持向量机方法的外推效果欠佳。线性回归的厚交换层模型和全连接神经网络模型的整体效果更好, 与训练数据的均方误差分别为 2.71×10^{-2} 和 1.81×10^{-3} 。基于深度学习模型良好的预测效果, 可以构建基于实验数据的、可以合理外推的“数字蒸发模型”, 可能有更好的现实适应能力。机器学习液滴蒸发模型丰富了现有液滴蒸发模型, 为机器学习液滴蒸发模型研究打基础。

关 键 词: 液滴蒸发模型; 煤油液滴; 机器学习; 神经网络; 拟合能力; 外推能力

中图分类号: V231.2

文献标志码: A

Investigation of kerosene droplet evaporation model based on machine learning

WANG Fang^{1,2,3}, HAN Qiwei¹, CAI Jiangtao¹, LI Dianwang¹, GAN Tian¹, JIN Jie^{1,2,3}

- (1. Aeroengine Numerical Simulation Research Center,
School of Energy and Power Engineering, Beihang University, Beijing 100191, China;
2. Jiangxi Research Institute, Beihang University, Nanchang 330096, China;
3. Chengdu Innovation Research Institute on Aircraft Power,
Beihang University, Pengzhou Sichuan 611930, China)

Abstract: Based on the droplet evaporation theory of Thick Exchange layer and experimental data of kerosene, a kerosene droplet evaporation model was constructed by using linear regression, random-forest, support vector machine, extreme gradient boosting, and fully-connected neural network methods in machine learning theory to test the applicability and accuracy of the newly constructed model. Comparing the experimental data with the prediction results of traditional models and machine learning evaporation models, it was found that the evaporation models generated by the random-forest method and extreme gradient boosting method cannot be reasonably extrapolated. The extrapolation effect of support vector machine method was not good. The overall effect of the linear regression thick exchange layer model and the fully-connected neural network model was superior to others, with a mean square error of 2.71×10^{-2} and 1.81×10^{-3} compared with the training data, respectively. Based on the prediction consequences of the deep learning model, it is feasible to construct a “digital evaporation model” stemmed from experimental

收稿日期: 2022-08-14

基金项目: 国家自然科学基金(91741125, 12172345, 92041001)

作者简介: 王方(1973—), 女, 副教授, 博士, 主要从事两相湍流流动及燃烧研究。

引用格式: 王方, 韩琪炜, 蔡江涛, 等. 基于机器学习的煤油液滴蒸发模型探索[J]. 航空动力学报, 2023, 38(8): 1956-1964. WANG Fang, HAN Qiwei, CAI Jiangtao, et al. Investigation of kerosene droplet evaporation model based on machine learning[J]. Journal of Aerospace Power, 2023, 38(8): 1956-1964.

data that can be reasonably extrapolated, and may have better realistic adaptability. Machine learning droplet evaporation model enriched extant droplet evaporation models, laying the foundation for machine learning droplet evaporation model research.

Keywords: droplet evaporation model; kerosene droplet; machine learning; neural network; fitting ability; extrapolation capability

航空发动机燃烧室内多为液雾燃烧,在该过程中存在着诸多的复杂物理化学现象,例如燃料的雾化破碎、液滴的蒸发、混气的燃烧等。液滴蒸发特性是燃烧室设计的重要参数之一。液雾燃烧数值模拟需要准确模拟液滴的蒸发过程,因此液滴蒸发特性也是数值模拟中两相模型的基础。

目前已经有多种传统液滴蒸发模型。Godsave^[1]与Spalding^[2]提出了液滴稳定蒸发的 d^2 模型。通常采用蒸发常数 C_v 来表达液滴蒸发的快慢,其值为液滴蒸发稳定段的 $d(d^2)/dt$,其中 d 为液滴直径, t 为时间。图1为蒸发环境为充满氮气的容器内,蒸发时液滴直径平方与时间的关系^[3],图中 C_v 为蒸发常数。除去最初的膨胀段外,直径平方与时间具有近似的线性关系。




图1 液滴直径平方与时间的关系^[3]

Fig. 1 Relations between square of droplet diameter and time^[3]

Abramzon和Sirignano^[4]考虑到表面吹风效应对蒸发率的影响,根据膜理论对 d^2 模型进行了修正,成为了广泛应用的A-S蒸发模型^[5]。Ranz和Marshall提出了基于努塞尔数 Nu 的R-M蒸发模型^[6]。周立行^[7]根据液滴周围的传热层和传质层的厚度远大于液滴半径等现象,提出了厚交换层蒸发模型。王方等^[8]提出了考虑自然对流的厚交换层模型(NC-TEL),具有更好的高温段精度,和燃烧室实际情况更一致。

在NC-TEL模型中,瑞利数 Ra 和雷诺数 Re 表征自然对流和强迫对流对液滴蒸发的影响,并

分别采用可调整的参数 δ 和 ζ 来表达不同的燃料。文献[8]中给出了对于煤油和航空煤油的参数 δ 和 ζ 的取值,但是煤油和航空煤油的物性存在着产地和批次的不统一,文中给出的取值并不能完全地在较广范围内适用。为了得到NC-TEL模型中参数 δ 和 ζ 的最佳取值,本文尝试机器学习理论中的线性回归法,通过不同温度下、不同速度下燃料的蒸发实验数据得到与实验误差最小的 δ 和 ζ ,来提升数值模拟的精度。此外,考虑到多种蒸发模型均包含相似的参数来反映液滴蒸发(例如雷诺数 Re 、输运数 B 等),可以借由多种机器学习方法,例如支持向量机^[9](support vector machine, SVM)回归、随机森林^[10](random forest)回归、随机梯度下降(stochastic gradient descent, SGD)^[11]回归以及全连接神经网络^[12](fully-connected network, FCN)回归等,收集不同条件下液滴的蒸发数据,以液滴蒸发时的相关参数作为输入特征,以液滴的蒸发常数作为输出特征进行建模,得到适用于单液滴蒸发的模型,为液雾两相燃烧提供更加精准的蒸发模型,为燃烧室研发服务。

1 蒸发模型和实验数据

1.1 传统蒸发模型

为了给本文机器学习模型预测结果对照和参考,本文选择了传统 d^2 模型、A-S蒸发模型和R-M蒸发模型。对于 d^2 模型,蒸发常数 C_v 表示为^[13]

$$C_v = \frac{8\lambda_g}{\rho_l c_{pg}} \ln(1 + B_T) \quad (1)$$

$$B_T = \frac{c_{pg}(T_g - T_s)}{h_{fg}} \quad (2)$$

其中 ρ_l 为液体密度, λ_g 为周围气体热导率, c_{pg} 为周围气体比定压热容, T_s 为液体表面温度, T_g 为周围气体温度, h_{fg} 为蒸发潜热。

A-S蒸发模型通过膜理论,考虑了液滴表面的吹风效应, C_v 表示为^[4]

$$C_v = \frac{4\bar{\lambda}_g}{\bar{c}_{pf}\rho_l} Nu^* \ln(1 + B_T) \quad (3)$$

$$Nu^* = 2 + \frac{Nu_0 - 2}{F_T} \quad (4)$$

$$Nu_0 = 2 + 0.552 Re^{1/2} Pr^{1/3} \quad (5)$$

$$F_T = (1 + B_T)^{0.7} \frac{\ln(1 + B_T)}{B_T} \quad (6)$$

其中 λ_g 为周围气体平均热导率, c_{pf} 为液体平均比定压热容, Pr 为普朗特数。

R-M 模型是计算流体力学软件 Fluent 的默认蒸发模型, 根据手册^[14], 蒸发常数 C_v 为

$$C_v = \frac{4\lambda_g}{c_{pg}\rho_l} (2 + 0.6 Re^{1/2} Pr^{1/3}) \ln(1 + B_T) \quad (7)$$

NC-TEL 模型在考虑了强迫对流对蒸发造成的影响外, 还额外考虑了自然对流对蒸发造成的影响, 该模型在强迫对流和自然对流条件下均有不错的预测效果。根据文献^[8], 蒸发常数 C_v 表达式为

$$C_v = \frac{4\theta_w \lambda_w}{c_{pf}\rho_l} \left[\frac{2 \ln(1 + \theta_w)}{\theta_w} \left(\frac{T_g - T_s}{2T_w} \right)^{1/2} + \frac{2}{3\zeta} \cdot \frac{\theta_w^2}{1 + \theta_w} Re^{1/3} Pr^{1/3} + \frac{2}{3\delta} \cdot \frac{\theta_w^2}{1 + \theta_w} Ra^{1/3} Pr^{1/3} \right] \quad (8)$$

$$T_w = T_g + \frac{T_s - T_g}{3} \quad (9)$$

$$\theta_w = \frac{c_{pf}(T_g - T_w)}{h_{fg}} \quad (10)$$

$$\lambda_w = \lambda_g + \frac{\lambda_s - \lambda_g}{3} \quad (11)$$

其中 λ_s 为液体表面热导率, c_{pf} 为液体比定压热容, Ra 为瑞利数, ζ 和 δ 为自由参数, 其值由燃料种类决定。

1.2 机器学习模型

1.2.1 基于 NC-TEL 蒸发模型的机器学习模型

注意到式(8)中存在根据燃料种类决定的 ζ 和 δ , 两个参数分别决定强迫对流和自然对流对于蒸发的影响, 基于不同温度 and 不同速度下煤油液滴蒸发的实验数据通过回归方法可以拟合出合适的 $\hat{\zeta}$ 和 $\hat{\delta}$ 。本文选择的拟合方法为线性回归和线性支持向量机回归, 由基于 Python 的机器学习库 Sci-kit learn 中的 LinearRegression 和 LinerSVR 实现。

1.2.2 基于机器学习的非线性蒸发模型

使用非线性的机器学习模型, 通过环境温度和速度以及燃料种类完成对蒸发常数进行预测, 脱离了传统的蒸发模型。本文选择的模型为采用

非线性的 Gaussian 核函数的 SVM 回归、基于决策树的随机森林回归和极致梯度提升回归(extreme gradient boosting, XGBoost)^[15], 并加入线性模型中的 SGD 回归来进行对照, 以上模型均采用 Sci-kit learn 中的对应模块。

在机器学习模型中除去实验提供的温度和速度特征外, 还需要进行特征的补充, 本文尝试了两种方法来提升训练信息的特征维度。第 1 种是对燃料进行区分, 因为机器学习模型无法处理文本信息, 所以将燃料的独热(one-hot)编码加入到数据中。独热编码是一组只含有一个 1 的数组, 例如将含有煤油、汽油和柴油的数据进行编码, 则可以将煤油的独热编码设置为 [1, 0, 0]、汽油的设置 [0, 1, 0], 柴油的设置 [0, 0, 1], 避免了简单数字序号对模型造成的影响。第 2 种是自行在每一组数据中加入与蒸发相关的特征数据。通过观察传统蒸发模型, 选取了 Re 、 Ra 、输运数、热导率、黏度、密度等加入到实验数据中。

1.2.3 深度学习蒸发模型

深度学习对比机器学习的优势在于通过多层的网络配合不同的激活函数, 可以自行提取出新的特征进行拟合。本文采用的深度学习库为 Pytorch, 模型的任务是较为简单地对一维数据进行拟合, 因此本文中神经网络为简单的线性全连接神经网络, 对于输入特征的选取方式与上一节一致。

1.3 实验数据的选取与分组

本文选取了 Ghassemi 等^[9] 和 Khan 等^[16] 针对煤油液滴在常压(0.1 MPa)蒸发时的实验数据, 共计 104 组数据, 如图 2 所示, 在环境温度为 573 K 和 673 K 下进行了不同来流速度(0~0.35 m/s)的实验。




图 2 煤油蒸发实验点数据

Fig. 2 Experimental data of kerosene evaporation

同时将另一组不同来源的静止煤油液滴蒸发测量实验数据^[17]作为验证组, 检验模型准确性, 不参与模型训练, 共 8 组, 如图 3 所示。由于上述数据只含煤油一种燃料, 为了更好地研究燃料物性对蒸发的影响, 以及验证机器学习模型, 为了增加数据量以保证模型准确性和可靠性, 在训练机器学习模型时还加入了柴油^[17]、乙醇^[18]和汽油^[19]的实验数据, 共 17 组。图 3 中 Exp 代表训练数据集, Exp-validation 代表验证数据集。




图 3 部分煤油训练数据与验证数据

Fig. 3 Partial training data and validation data of kerosene

2 蒸发模型探索

2.1 NC-TEL 机器学习模型

对于 NC-TEL 模型中的 ζ 和 δ 拟合, 流程较为简单, 将每一组煤油数据的温度、速度和蒸发常数作为输入值即可。线性回归和线性 SVM 回归的拟合值与评估拟合效果的均方误差(mean squared error, MSE)如表 1 所示。

表 1 NC-TEL 拟合结果与误差

Table 1 Performance of NC-TEL regression

模型	ζ	δ	训练组 MSE/ 10^{-2}	验证组 MSE/ 10^{-3}
线性回归	0.158	6.27	2.71	2.33
线性 SVM 回归	0.246	5.47	3.16	7.48

两种模型得到的参数较为接近, 但是线性回归的拟合值与实验数据的 MSE 更小, 图 4 为针对传统模型和 NC-TEL 模型对每个实验点的预测值。从图 4 中可以发现, 两种拟合的 NC-TEL 模型在高温段(大于 700 K)时明显优于其他传统模型, 比较 NC-TEL 模型与其他传统模型可以发现, NC-TEL 通过 Ra 考虑了自然对流对蒸发的影响, 得到了更加贴近实验数据的预测值。图 5 为静止




图 4 各模型预测值与实验点数据比较

Fig. 4 Comparison among model predictions and experimental data

条件下不同温度时各模型对蒸发常数的预测值。如图 5 所示, 线性回归和线性 SVM 回归对于图中 900~1 000 K 部分数据段出现的误差点有着不同的解决策略: 线性回归更关注整体的 MSE, 因此会将误差点也考虑在内, 降低整体的 MSE; 而线性 SVM 回归具有选择性, 会根据给定的误差限 ϵ 忽略部分误差点。虽然会使评估精度的 MSE 上升, 但是与主要数据的贴合程度会更好, 这一点也可以从测试组的 MSE 中发现。




图 5 液滴静止时不同环境温度下各模型的预测值

Fig. 5 Predictions of models under different ambient temperatures when the droplet is stationary

图 6 和图 7 分别为环境温度为 573 K 和 673 K 时不同来流速度下模型的预测值。在 573 K 下, 两种模型的预测欠佳, 不如 A-S 蒸发模型的预测值, 而在 673 K 下的表现较好。这说明机器学习拟合的 NC-TEL 模型受限于自身的理论模型, 通过瑞利数 Ra 模拟自然对流对蒸发的影响较好, 而通过雷诺数 Re 反映强迫对流的影响上还有不足。




图 6 环境温度为 573 K 下各模型的预测值
Fig. 6 Predictions of models when the ambient temperature is 573 K




图 7 环境温度为 673 K 下各模型的预测值
Fig. 7 Predictions of models when the ambient temperature is 673 K

2.2 非线性机器学习模型

本文选取了随机森林回归、XGBoost 回归和采用 Gaussian 核函数的 SVM 回归, 并将线性 SGD 回归作为对照加入。与前一节 NC-TEL 的回归任务不同, 在缺少特定理论模型的支持下, 需要更高维度的数据特征才能更好地检验模型, 因此加入了柴油、乙醇和汽油的实验数据。对于不同种类燃料的实验数据, 首先采取了对燃料进行独热编码的方法进行简单区分, 每一组燃料数据的形式为环境温度、来流速度、燃料编码和蒸发常数。开始训练前将输入数据标准化, 在训练完成后对煤油的蒸发常数进行预测, 如图 8 所示。

在图 8 中, XGBoost 和随机森林模型对实验点的拟合效果最好, 但是因为误差点的存在导致

了图 8(b) 中的过拟合, 而且缺乏在缺少实验点时的外推能力, 例如图 8(b) 中大于 1 100 K 的部分。SVM 模型的效果较好, 没有出现过拟合的情况, 并且具有一定的外推能力。但是从图 8(c) 中来流速度上升反而预测值降低的反常情况来看, SVM 模型在此处的外推能力有限, 需要更多的数据支撑。SGD 模型由于是线性模型, 没有过拟合和外推能力的问题, 但是从与实验值的对比中发






图 8 采用独热编码的机器学习模型对煤油蒸发常数的预测结果

Fig. 8 Prediction of evaporation constant of kerosene using a machine learning model with unique heat coding

现此模型处于欠拟合的状态,需要提升特征的维度。

除去对燃料进行编码以外,还可以将燃料的物性加入到数据中,使输入特征大大提升。在对

所有数据的物性进行添加之后,首先对数据的相关性进行了分析。图 9 为蒸发数据的相关性矩阵热力图。




图 9 蒸发数据特征的相关性矩阵热力图

Fig. 9 Heatmap of correlation matrix of evaporation data

图 9 主要关注蒸发常数与其他特征的相关性,当特征之间的相关性绝对值越接近 1 时,越具有线性关系。除黏度、热导率、普朗特数和热膨胀系数等参数与蒸发常数有高相关性外,蒸发常数与大部分数据都具有一定的相关性,因此不再对这些输入特征进行额外的处理,在训练前同样进行标准化处理,然后开始训练。图 10 为模型与实验值的对比。

对于各非线性模型而言,预测效果与独热编码类似,但是增加的输入维度提升了线性 SGD 回归的精度,表 2 为各个机器学习模型配合不同输入特征处理的 MSE。

在增加物性的模型中,SVM 和 SGD 的 MSE 更低,精度更好,说明物性等数据对输入维度的补充起到了效果。值得注意的是,随机森林模型

和 XGBoost 模型的 MSE 要远低于 SVM 和 SGD,但是并不意味着随机森林和 XGBoost 模型更加优秀,从图 10 和图 8 中过拟合和缺少外推的情况来看,并不能把 MSE 作为模型好坏的唯一标准。

2.3 深度学习模型

深度学习的优势在于可以通过多层的网络自动提取特征,本文采用了较为简单的全连接网络,输入特征采用增加物性等相关参数的方法;隐藏层共 3 层,每层共 256 个节点,采用整流线性单元(rectified linear unit, ReLU)作为激活函数,并采用 dropout 方法避免过拟合;输出层为单一线性单元,输出预测的蒸发常数。图 11 为模型的简图,训练时批大小为 32,优化器选择 adam,学习率设置为 0.001,共训练 100 轮次。

在训练完成后,同样通过煤油的实验数据进






图 10 增加物性特征的机器学习模型对煤油蒸发常数的预测结果

Fig. 10 Kerosene evaporation constant predictions of machine learning models with more physical properties

行验证, 图 12 为模型预测结果与实验值的对比。

深度学习模型的预测效果良好, 对于实验点的贴合和外推效果均为合理, 没有出现拟合和欠拟合的情况。对于煤油实验数据, 训练组 MSE 和验证组 MSE 分别为 1.81×10^{-3} 和 4.19×10^{-3} 。

深度学习模型预测能力良好的原因在于, 相较于 NC-TEL 机器学习模型和非线性机器学习模型需要自行确定机器学习模型的特征, 深度学习

模型可以自己根据数据组提取特征。因此深度学习模型提取的特征更全, 更能对数据组进行自适应, 预测效果更好。

表 2 机器学习模型误差

Table 2 Errors of machine learning models

模型	MSE/ 10^{-3}			
	独热编码 训练	独热编码 验证	增加物性 训练	增加物性 验证
随机森林	0.264	6.05	0.282	5.91
SVM	2.00	6.00	1.47	6.92
XGBoost	0.048 6	9.69	0.044 6	9.29
SGD	5.09	5.98	3.15	6.07








图 11 全连接神经网络模型简图

Fig. 11 Sketch of fully-connection network model





(c) 环境温度为573 K时不同来流速度下的预测



(d) 环境温度为673 K时不同来流速度下的预测

图 12 深度学习模型对煤油蒸发常数的预测结果
Fig. 12 Prediction results of kerosene evaporation constant using deep learning models

2.4 各个模型测试结果总结

各个模型的测试结果主要由 MSE 来衡量,同时也通过预测结果曲线图来判断每个模型的外推能力。每个方法典型模型的 MSE 和外推能力如表 3 所示。

表 3 模型预测结果总结
Table 3 Summary of model prediction results

模型	训练组 MSE/10 ⁻³	验证组 MSE/10 ⁻³	外推能力
线性回归	27.1	2.33	好
随机森林	0.282	5.91	无
SVM	1.47	6.92	差
XGBoost	0.044 6	9.29	无
SGD	3.15	6.07	一般
全连接网络	1.81	4.19	好

3 结 论

本文主要基于煤油液滴的蒸发实验数据,通过 NC-TEL 理论构建了基于机器学习的 NC-TEL 模型并与传统蒸发模型进行了对比验证,随后构

建了基于不同方法的非线性机器学习模型和深度学习模型并对燃料蒸发数据进行学习和预测,研究了不同模型对于蒸发常数的预测效果。

通过代入煤油实验数据拟合的参数,NC-TEL 模型的煤油蒸发常数预测效果优于其他模型,特别是在高温段。但是此模型的预测效果还是受限于自身理论,在 NC-TEL 中自然对流的影响模拟较好而强迫对流的模拟较差,仅调整两个自由参数无法做到所有情况下预测都能接近实验值,理论还需要进一步改进,图 6 中的预测效果较不理想。

非线性的机器学习模型摆脱了理论的约束,预测值和实验值的 MSE 优于传统模型,但是却出现了过拟合和外推效果较差的情况。特别是决策树类的模型,完全丧失了外推能力,这对于蒸发模型而言是不可接受的。SVM 模型虽然没有过拟合,但是在外推效果方面依然不佳,不过可以考虑通过与其他具有外推能力的模型结合,例如 NC-TEL 或者线性 SGD 模型,在含有数据点的部分采用 SVM,外推部分使用 SGD。此外,输入特征维度的提升也改进了模型的效果。

深度学习模型较好地结合了外推和实验点拟合的优点,是本次建模中效果最好的。但是模型是只有 3 层隐藏层的简单网络,对于网络层数和每层的节点个数还有更深的优化空间。

在 NC-TEL 模型和机器学习模型的对比中,两者最大的区别在于数据的需求上,因为 NC-TEL 模型具有完备的理论,可以仅通过数个蒸发数据就能得出模型的参数并取得较好的效果;而无论哪一个机器学习模型都需要较多的数据才能做到预测值合理,而且外推能力更是和实验数据的广度有关。在 SVM 的预测结果中,位于实验数据范围内的预测值较为精准,一旦脱离范围就可能出现失真,例如图 10(c)中速度上升,蒸发常数反而下降的情况。

参考文献:

[1] GODSAVE G A E. Studies of the combustion of drops in a fuel spray: the burning of single drops of fuel[J]. *Symposium (International) on Combustion*, 1953, 4(1): 818-830.
[2] SPALDING D B. Combustion of liquid fuels[J]. *Nature*, 1950, 165: 160.
[3] NOBLE W S. What is a support vector machine?[J]. *Nature Biotechnology*, 2006, 24(12): 1565-1567.
[4] ABRAMZON B, SIRIGNANO W A. Droplet vaporization model for spray combustion calculations[J]. *International Journal of Heat*

- and Mass Transfer, 1989, 32(9): 1605-1618.
- [5] PENG F, AGGARWAL S K. A review of droplet dynamics and vaporization modeling for engineering calculations[R]. ASME 94-GT-215, 1994.
- [6] RANZ W E. Evaporation from drops: Part II [J]. Chemical Engineering Progress, 1952, 48(4): 173-180.
- [7] 周力行. 燃烧理论和化学流体力学[M]. 北京: 科学出版社, 1986.
- [8] WANG Fang, LIU Rui, LI Min, et al. Kerosene evaporation rate in high temperature air stationary and convective environment[J]. Fuel, 2018, 211: 582-590.
- [9] GHASSEMI H, BAEK S W, KHAN Q S. Experimental study on evaporation of kerosene droplets at elevated pressures and temperatures[J]. Combustion Science and Technology, 2006, 178(9): 1669-1684.
- [10] SVETNIK V, LIAW A, TONG C, et al. Random forest: a classification and regression tool for compound classification and QSAR modeling[J]. Journal of Chemical Information and Computer Sciences, 2003, 43(6): 1947-1958.
- [11] BOTTOU L. Large-scale machine learning with stochastic gradient descent[R]. Paris, France: 19th International Conference on Computational Statistics, 2010.
- [12] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks[R]. Sardinia, Italy: 13th International Conference on Artificial Intelligence and Statistics, 2010.
- [13] SAZHIN S S. Advanced models of fuel droplet heating and evaporation[J]. Progress in Energy and Combustion Science, 2006, 32(2): 162-214.
- [14] Ansys Inc. Ansys fluent theory guide[M]. Canonsburg, US: Ansys Inc., 2020.
- [15] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[R]. San Francisco, US: 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016.
- [16] KHAN Q, BAEK S W, LEE S Y. Effect of droplet initial diameter on droplet vaporization regimes for kerosene fuel droplet[R]. Reno, US: 45th AIAA Aerospace Sciences Meeting and Exhibit, 2007.
- [17] WANG Fang, YAO Jie, YANG Shaofeng, et al. A new stationary droplet evaporation model and its validation[J]. Chinese Journal of Aeronautics, 2017, 30(4): 1407-1416.
- [18] PINHEIRO A P, VEDOVOTO J M, NETO A D S, et al. Ethanol droplet evaporation: effects of ambient temperature, pressure and fuel vapor concentration[J]. International Journal of Heat and Mass Transfer, 2019, 143: 118472.1-118472.12.
- [19] HASHIMOTO N, NOMURA H, SUZUKI M, et al. Evaporation characteristics of a palm methyl ester droplet at high ambient temperatures[J]. Fuel, 2015, 143: 202-210.

(编辑: 秦理曼)