

# 采用极限学习机的流场积分吸光度快速测量方法

姜雅晶, 宋俊玲\*, 饶伟, 王凯, 姜登程, 郭建宇

航天工程大学, 激光推进及其应用国家重点实验室, 北京 101407

**摘要** 发动机是飞行器动力系统的核心组件, 发动机流场的动态监测可以掌握发动机内部流场的燃烧情况, 对于飞行器状态监测和性能评估具有重要意义。拥有先进的诊断技术是发展发动机技术的基础, 也是研制新型航空航天飞行器的必要条件之一。激光吸收光谱技术可以实现燃烧场气体参数的测量, 在发动机严苛的流场环境中, 吸收光谱波长调制技术(WMS)可以提高信噪比。但基于 WMS 解算积分吸光度和温度、浓度二维分布的方法都是以模拟退火算法(SA)为核心, 因此存在执行时间较长的问题。根据随时间演化的流场光谱参数、光线分布为固定信息这一内在关联性, 以及已有的 WMS 方法可以计算积分吸光度值, 采用机器学习方法建立谐波信号( $S_{2f/1f}$ )与积分吸光度( $A$ )的模型, 选择极限学习机算法(ELM), 其训练时间短, 预测结果快。利用神经网络可以逼近真值的特性, 仿真确定光线布局下不同流场模型的  $S_{2f/1f}$  和  $A$ , 构造数据集对神经网络开展模型训练。在数值仿真验证中, 共仿真 2 000 组数据集, 随机选取 1 800 组作为训练集训练模型, 其余 200 组作为预测集, 统计测试集的预测积分吸光度平均相对误差为 1.058%, 决定系数平均值为 0.999, 验证了训练模型的可靠性。为进一步探究模型的抗噪声性, 采用的方法是在测试集  $S_{2f/1f}$  数据集中分别加入 3%, 5% 和 10% 的随机噪声, 统计预测积分吸光度平均相对误差分别为 3.1%, 4.6% 和 8.1%, 这一结果可以表明 ELM 具有较好的抗噪声性。基于该方法, 在直连式超燃冲压发动机上开展验证实验, 实验有效时长为 5 s, 采集数据约 10 GB, 分别采用 ELM 和 WMS 两种方法解算积分吸光度, 对比发现: 结果基本一致, 且相比执行时间数小时的 WMS 方法, ELM 预测积分吸光度耗时仅为 15 s 左右, 实现了发动机流场积分吸光度的快速测量。

**关键词** 激光吸收光谱技术; 波长调制; 机器学习; 极限学习机

**中图分类号:** O433.1 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2022)05-1346-07

## 引言

发动机是飞行器的动力源泉, 其流场内部的温度和浓度等气体参数对于研究发动机燃烧和内部工作状态具有重要参考价值, 对完善发动机燃烧室设计, 提高燃烧效率等具有重要意义<sup>[1]</sup>。

可调谐半导体激光吸收光谱技术(tunable diode lasers absorption spectroscopy, TDLAS)是利用激光器的波长调谐特性, 获得被测气体的特征吸收光谱, 进而推断出流场温度、压强和组分浓度。其属于视线测量技术, 只能获得激光光线方向上的流场信息<sup>[2]</sup>。为了实现非均匀流场气体参数的二维分布测量, 采用将吸收光谱技术与计算机断层扫描技术(computer tomography, CT)相结合的可调谐半导体激光吸

收光谱断层诊断技术(tunable diode laser absorption tomography, TDLAT)<sup>[1-4]</sup>。

TDLAT 技术主要以直接吸收光谱(direct absorption spectroscopy, DAS)方法为基础, 通过离散化被测流场和设计光线布局获得不同光线的积分吸光度, 进而利用重建算法实现气体参数的二维分布测量。DAS 获取积分吸光度的原理是利用一定频率(与吸收分子的跃迁频率接近)范围的激光扫描被测流场, 透射光强与入射光强比值计算激光的衰减程度, 分析激光的衰减程度进而实现气体参数的测量。入射光强通过透射光强的未吸收部分线性拟合获得<sup>[5-6]</sup>, 因此在谱线重叠较严重或在低信噪比及高压环境中测量时, 拟合产生的入射光强误差较大, 光线积分吸光度产生偏差<sup>[5]</sup>, 这种偏差会带入到求解流场气体参数的二维分布中。

波长调制光谱(wavelength modulation spectroscopy,

收稿日期: 2021-07-21, 修订日期: 2021-10-14

基金项目: 国家自然科学基金项目(6150030923, 6150030796)资助

作者简介: 姜雅晶, 女, 1996 年生, 航天工程大学激光推进及其应用国家重点实验室硕士研究生 e-mail: jiangyajing\_2019@163.com

\* 通讯作者 e-mail: songjl\_2008@163.com

WMS)是在低频扫描信号上加载高频正弦调制信号,通过锁相滤波提取谐波信号,无需拟合入射光强,能够有效抑制环境噪声的影响,极大提高 TDLAS 的测量精度和灵敏度,替代 DAS 实现恶劣环境下气体参数的测量<sup>[7]</sup>。2021 年, Song<sup>[8]</sup>等提出一种由 WMS-2f/1f 信号解算积分吸光度 A 的方法(WMS-A),其原理是将流场的线型函数表示为由多个 Voigt 线型函数组成,采用模拟退火方法实现对积分吸光度的求解,将解算的积分吸光度代入到二维重建算法中,进而实现流场参数的二维分布测量。该方法具有较高的信噪比,但通过模拟退火算法解算积分吸光度,计算量大,收敛速度慢,执行时间长,结果存在随机性。

当前波长调制谐波信号测量非均匀流场参数的方法,存在解调时间长、执行效率低的问题。2018 年 Yu 等<sup>[9]</sup>将流场离散化为网格,提出一种基于机器学习快速反演流场光线吸收系数的方法,训练得到的模型开展 50 组流场模型预测,获取结果耗时少于 30 ms。同年有研究<sup>[10]</sup>提出基于深度学习理论中卷积神经网络,实现了超光谱非线性断层吸收光谱重建,结果表明完成一次重建仅需要 0.7 ms。以上采用机器学习反演流场参数的方法,极大缩短了反演时间,但该方法模型训练是基于 DAS 的原理,不具有较好的抗噪声性能,对于严苛的工程试验情况不具有鲁棒性。

本工作提出了一种基于机器学习的流场积分吸光度的快速解调方法。选择极限学习机(extreme learning machine, ELM)算法<sup>[11-12]</sup>,通过模拟和仿真大量的流场分布,计算归一化的二次谐波信号作为输入数据集,积分吸光度作为输出层,由此进行模型训练。训练的模型具有很好的泛化能力。开展实验,将实验测得的谐波信号输入训练好的模型中,能够快速得到高精度的预测结果。

## 1 理论与方法

### 1.1 积分吸光度与谐波信号关系

光线穿过流场区域,当激光频率与目标区域被测气体吸收组分跃迁频率相同时,一部分激光能量被吸收,穿过流场的透射光线强度发生衰减。吸收系数  $\alpha$  和积分吸光度  $A$  与入射光强和透射光强的关系表达式为

$$\alpha_\nu = -\ln\left(\frac{I_t}{I_i}\right)_\nu = \int_0^L P(x)S(T(x))\chi(x)\phi_\nu dx \quad (1)$$

$$A = \int_{-\infty}^{+\infty} -\ln\left(\frac{I_t}{I_i}\right)_\nu d\nu = \int_{-\infty}^{+\infty} \alpha_\nu d\nu = \int_0^L P(x)S(T(x))\chi(x)dx \quad (2)$$

其中,  $I_i$  和  $I_t$  分别表示光线的入射光强和透射光强,  $x$  为沿光视线方向的坐标,  $P(x)$ [atm],  $T(x)$ [K]和  $\chi(x)$ 分别为位置  $x$  处的压强、温度与组分浓度,  $\phi_\nu$ [cm]为线型函数,  $S[T(x)]$ 为温度  $T(x)$ 的谱线强度,  $[cm^{-2} \cdot atm^{-1}]$ 是关于温度  $T$  的函数。

文献<sup>[13]</sup>介绍了 WMS 的谐波模型,其归一化二次谐波信号表达式为

$$S_{1f} = \sqrt{X_{1f}^2 + Y_{1f}^2}$$

$$S_{2f} = \sqrt{X_{2f}^2 + Y_{2f}^2} \quad (3)$$

$$S_{2f/1f} = \frac{S_{2f}}{S_{1f}}$$

文献<sup>[8]</sup>中已经表明波长调制的归一化二次谐波信号 2f/1f 可以独立求解流场光线积分吸光度 A;在计算流场积分吸光度和归一化二次谐波信号 2f/1f 过程中,流场是随时间演化的量,但是其中光谱参数、光线分布信息是固定的,利用这一内在关联性,拟采用机器学习的方法进行求解。将归一化的二次谐波信号作为输入,积分吸光度作为输出,选择 ELM 算法训练神经网络模型。

### 1.2 极限学习机理论

1.1 节阐述了谐波信号与积分吸光度之间存在的关联,且两者关联没有明确的函数表达式,依据两者的关系可建立 WMS 谐波信号快速解算积分吸光度的解算方法。

机器学习中的“学习”就是逐渐调整权值和阈值使得网络的实际输出和期望输出一致。极限学习机作为机器学习中的一种人工神经网络模型,是一种求解单隐层前馈神经网络的学习算法,其原理为随机选取输入层权重和隐藏层偏置,输出层权重通过最小化由网络输出和样本标签最小化平方差构成的损失函数,依据 Moore-Penrose(MP)广义逆矩阵理论计算解析求出,输入数据便可计算获得网络输出,完成对输入数据的预测。图 1 所示为 ELM 网络结构,该网络模型由一个具有  $L(L < N)$  个神经元的隐藏层  $h_j(a)$ 、激活函数和大量输入输出数据集  $\{S_{2f/1f}, A\}$  构成,其中激活函数通常选择 sigmoid 函数,  $(w_{ij}, b_j)$  表示随机输入的网络权重和偏置,  $\beta_k$  表示网络输出权重。

图 1 所示的神经网络模型,单从输入输出看,可以将其看成一个“函数关系”。此“函数关系”通过训练集合经学习获得。训练集分为输入数据和输出数据,将归一化二次谐波信号  $S_{2f/1f}$  作为神经网络模型训练的输入集,积分吸光度  $A$  作为训练的输出集;训练完成之后,在输入端输入实验采集的谐波信号数据,便可以快速得到光线的积分吸光度。流程图如图 2 所示,其中实线表示训练过程,虚线表示预测反演过程。

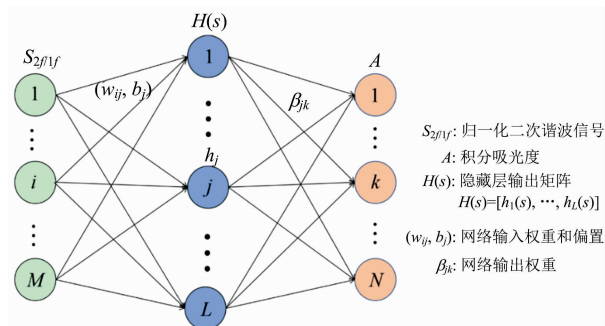


图 1 极限学习机算法单隐层前馈神经网络  
Fig. 1 Extreme learning machine algorithm single hidden layer feedforward neural network

由训练和预测过程可知,实际流场参数反演,在完成一次学习过程后,网络便完成搭建,因此可实现一次训练、多

次测试,从而避免每条光束执行的重复且耗时的迭代求解过程。并且还可以根据一些流场的先验信息,随时调整和扩充数据集。




图 2 机器学习和预测过程示意图

Fig. 2 Schematic diagram of the machine learning and prediction procedures

## 2 数值仿真

### 2.1 方法可行性验证

设计非均匀流场开展仿真实验验证方法的可行性。为了接近实际燃烧流场内部情况,选用图 3(a,b)所示的高斯非均匀流场,模拟多峰连续变化的流场,模型表达式为

$$f(x) = a \exp\left(-\frac{(x-x_1)^2}{\delta_1^2} - \frac{(y-y_1)^2}{\delta_1^2}\right) + \exp\left(-\frac{(x-x_2)^2}{\delta_2^2} - \frac{(y-y_2)^2}{\delta_2^2}\right) + b \quad (4)$$

式(4)中,  $a$ ,  $b$ ,  $x_1$ ,  $x_2$ ,  $\delta_1$ ,  $\delta_2$  为调整参数,控制  $f(x)$  的取值范围。以超燃冲压发动机流场参数作参考,温度范围 500~3 000 K,浓度范围 1%~3%,压强设置为大气压强 1 atm。模型参数的设计原则是使流场的变化尽可能大,  $a$ ,  $b$ ,  $x_1$ ,  $x_2$ ,  $\delta_1$ ,  $\delta_2$  的具体取值见表 1 所示。

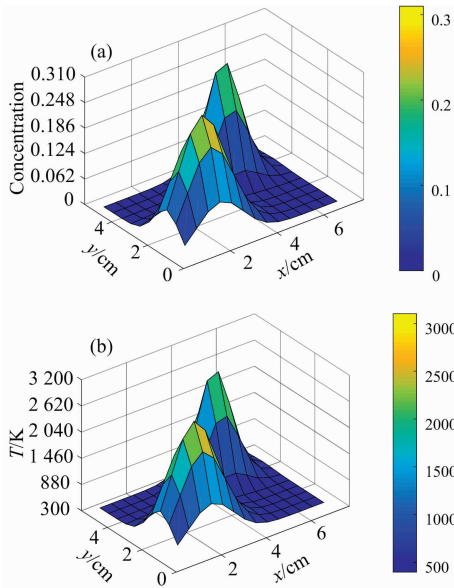


图 3 温度和浓度高斯分布模型

(a): 温度分布; (b): 浓度分布

Fig. 3 Temperature and concentration Gaussian distribution model

(a): Temperature distribution; (b): Concentration distribution

扇形光线,共计发出 88 条光线的发动机燃烧室测量环矩形构型,图 4 所示为该构型的扇形流场光线布局,将其网格离散为  $14 \times 10$ ,单个网格长度为 0.5 cm。已知上述各光谱参数情况下,每条光谱在单个流场模型可以仿真计算出 88 条光线对应的谐波信号和积分吸光度信号,因此机器学习单个训练集或测试集的数据元素数为 88。实际工程试验中,网络模型学习采用的训练集是多种双高斯分布流场模型下的光线信息数据,即为谐波信号的积分吸光度信号。且可以根据一些流场的先验信息,随时调整和扩充训练集。

表 1 模型参数设计

Table 1 Model parameter design

	$x$	$y$	$x_1/x_2$	$y_1/y_2$	$a$	$b$
$T$	-5~5	-5~5	-4~4	-4~4	3 000	500
$\chi$	-5~5	-5~5	-4~4	-4~4	0.3	0.01




图 4 流场扇形光线布局

Fig. 4 Flow field fan light layout

极限学习机算法的单隐层神经网络通过训练集重建,确定隐藏层节点数,然后向该网络输入实验测得流场光线的谐波信号信息,可以快速预测解出积分吸光度值。网络模型的预测误差及评定系数表达式为

(1) 训练精度和泛化能力衡量参数  $A\_SSE$

$$A\_SSE = \frac{\sum_{i=1}^n |A_i^{\text{orig}} - A_i^{\text{pre}}|}{\sum_{i=1}^n A_i^{\text{orig}}} \quad (5)$$

式(5)中,  $A_i^{\text{orig}}$  表示原始训练集的输出集,  $A_i^{\text{pre}}$  表示神经网络模型预测获得的输出集。  $A\_SSE$  越接近零,表明训练精度越高。

(2) 评价模型拟合程度  $R^2$

$$SST = \sum_{i=1}^n (A_i^{\text{orig}} - \bar{A})$$

$$SSE = \sum_{i=1}^n (A_i^{\text{orig}} - A_i^{\text{pre}})$$

$$R^2 = 1 - \frac{SSE}{SST} \quad (6)$$

式(6)中,  $\bar{A}$  为所有积分吸光度  $A_i^{\text{orig}}$  的平均水平。  $R^2$  越接近 1,表明该模型的拟合度越好。

针对文献[14]中大小为 7 cm×5 cm、矩阵四角发射均为

根据流场火焰分布和表 1 所示的参数范围，每种谱线各随机产生 2 000 组不同的高斯分布流场模型，总共可获得 2 000 组数据集。

以  $7\ 185.559\ 7\ \text{cm}^{-1}$  为例，随机选取 1 800 组作为训练集，其余 200 组作为测试集。确定隐藏层神经元的个数 400，激活函数选择 sigmoid 函数。图 5 是以数据集为横坐标的测试集预测误差结果图。分析可知，测试集预测误差平均水平在 1.058%，离散程度为 0.008 19。图 6 所示为各组测试集的决定系数，决定系数值整体水平值为 0.999，离散化程度为 0.002 14，这一结果反映了训练神经网络模型较好的稳定性。

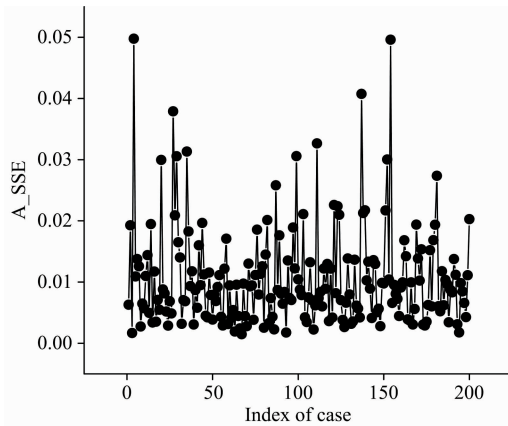


图 5 测试集误差

Fig. 5 Test set error




图 6 测试集决定系数

Fig. 6 Test set determination factor

对积分吸光度误差和决定系数的统计及数据分析表明，通过训练极限学习机的单隐层神经网络预测积分吸光度的方法具有可行性。1 800 组数据的训练学习过程耗时约 0.4 s，完成 200 组测试集的预测耗时 0.03 s，因此该方法在精确有效反演流场积分吸光度的同时，可以极大提高反演速度，实现流场积分吸光度的快速测量。

### 2.2 噪声对实验结果的影响

为进一步研究 ELM 算法神经网络在工程试验中的抗噪声性能，采用在测试集的输入数据  $S_{2f/1f}$  中分别加入 3%，

5%和 10%高斯噪声的方法，模拟实验中存在的窗口污染、光线抖动和信号噪声等问题，仍采用先验训练好的网络模型，计算预测结果与原积分吸光度的误差，评估抗噪声水平。

图 7 为随机 50 组加入噪声谐波信号  $S_{2f/1f}$  预测积分吸光度的误差曲线，黑色方形数据表示谐波信号  $S_{2f/1f}$  加入 3% 噪声，平均误差  $e_A$  约为 3.1%；红色圆形数据为  $S_{2f/1f}$  加入 5% 噪声，平均误差  $e_A$  约为 4.6%。表明 ELM 具有一定的抗噪声性能。




图 7 谐波信号  $S_{2f/1f}$  加入噪声的积分吸光度预测误差

Fig. 7 Integrated absorbance prediction error of harmonic signal  $S_{2f/1f}$  added to noise

## 3 工程试验验证

### 3.1 构建模型

实验在直连式超声速燃烧试验台上进行，试验台出口处安装扩张段，图 8 为扩张段平行光线布局示意图，共有 8 条直光路(激光发射端和接收端在同一横截面上)，其中竖直方向有 5 条，吸收光程为 11.06 cm，光线间隔 2.212 cm，水平方向有 3 条，吸收光程为 7 cm，光线间隔为 2.33 cm。以水平和竖直方向的光线交叉点为中心将流场待测横截面划分为  $5 \times 3$  的网格，单位网格大小为  $2.33\ \text{cm} \times 2.212\ \text{cm}$ 。超声速燃烧试验台流场参数范围在 2.1 节已阐述，在图 8 所示的光




图 8 直连台流场平行光线布局

Fig. 8 Direct-connected scramjet flow field parallel light layout



线布局下, 随机生成 2 000 组图 3 所示高斯分布的流场模型, 利用该模型和光线参数, 计算  $7\ 185.597$  和  $7\ 454.445\ \text{cm}^{-1}$  两个光谱的光线谐波信号  $S_{2f/1f}$  和积分吸光度  $A$ , 经过数据集集成, 建立两个光谱各自的训练集和测试集 ( $S_{2f/1f} - A$ ), 训练各自的 ELM 网络模型。

### 3.2 实验设计及结果分析

搭建的直连式超声速燃烧试验台测量系统如图 9(a, b) 所示, 图 9(a) 为试验台实物图, 直连台由喷管、隔离段、燃烧室、供气系统等构成。在燃烧室出口处安装扩张段搭建 TDLAS 测量系统, 如图 9(b) 所示, 实现对被测流场  $\text{H}_2\text{O}$  的温度和组分浓度的二维测量。

TDLAS 测量系统的工作原理为: 集成样机中固定了

一个可调谐半导体激光器 (NEL,  $1\ 391$  和  $1\ 341\ \text{nm}$ ), 由高频正弦信号 ( $240\ \text{kHz}/280\ \text{kHz}$ ) 和  $1\ \text{kHz}$  慢扫描锯齿波信号叠加驱动, 产生中心频率为  $7\ 185.6$  和  $7\ 454.45\ \text{cm}^{-1}$  的激光, 并以频分复用的方式耦合到一根单模光纤中, 经过一个 1 分 8 的分束器, 将该激光分成 8 路, 进入被测流场区域。

穿过被测流场的激光经探头接收, 由多模光纤束传输至集成样机的采集系统, 砷化镓探测器矩阵接收激光信号并转换为电信号。

转换的电信号由数据采集卡以二进制形式采集并通过网线传输到计算机 [CPU Inter(R) Xeon(R) Gold 6152 CPU @  $2.10\ \text{GHz}$ ] 中。存储的探测信号经过处理获取有效吸收段, 图 10 给出了随机截取的 5 ms 信号。

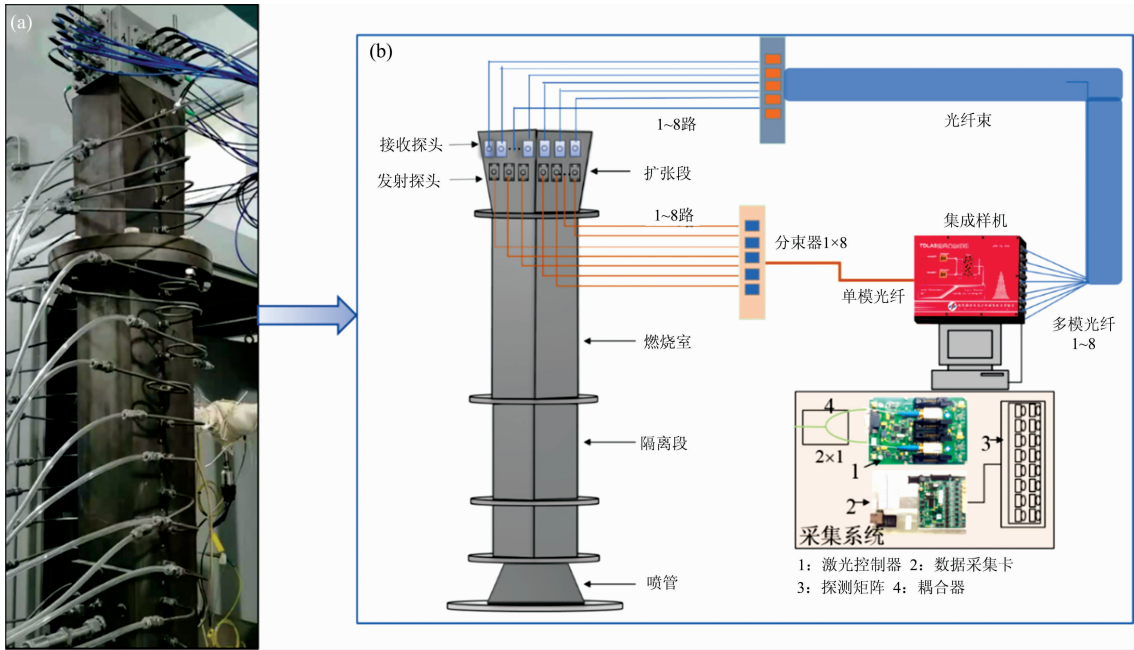


图 9 直连式超声速燃烧实验台测量系统示意图

(a): 直连式超声速燃烧实验台; (b): TDLAS 测量系统

Fig. 9 Schematic diagram of the measurement system of the direct-connected scramjet

(a): Direct-connected supersonic combustion test bed; (b): TDLAS measurement system




图 10 频分复用波长调制的吸收信号

Fig. 10 Frequency division multiplexing wavelength modulated absorption signal

实验采用氢气引导煤油点火方式, 在燃烧室布置了一个氢气喷口和两个煤油喷口。燃烧过程的工作时序图 11 所示,

空气来流进入流道 1 s 之后, 开始向燃烧室注入氢气, 持续时间约 2 s; 在气进入 0.8 s 之后, 靠近氢气入口一侧的开始注入煤油, 持续时间 3 s; 煤油喷出 1 s 后另一侧煤油开始注入燃烧, 持续时间约 2 s。因此试验总时长大概为 5 s。




图 11 实验时间序列图

Fig. 11 Time sequence of Experiment

将实验数据进行锁相滤波处理, 获得  $S_{2f/1f}$  谐波信号。

将谐波信号输入到训练学得的神经网络模型中，反演出每一时刻流场水平截面光线的积分吸光度值。图 12 所示为采用 ELM 方法和 WMS-A 方法<sup>[8]</sup>实现  $7\ 185.559\ \text{cm}^{-1}$  光谱的光线的实验积分吸光度的反演，其中实线表示采用 ELM 方法反演结果，点划线表示采用 WMS-A 方法反演结果。图中结果表明两种方法求解的流场积分吸光度结果能够较好地吻合。因此可以证明采用 ELM 的流场积分吸光度测量方法具有可靠的可行性。存在各光线积分吸光度值不稳定，短时间内来回震荡的情况，是由于实验中存在光线抖动、窗口污染和光入射镜头倾斜角不够等因素，导致干扰原始数据。

利用图 12 反演的积分吸光度开展流场截面的二维重建<sup>[15]</sup>，图 13 是由波长调制解调方法求解的表征流场温度随时间变化情况的曲线，四张图片为发动机出口处各燃烧阶段对应的流场截面二维温度重建图。图中各阶段流场变化与时序图 11 工况变化一致。

本实验有效测量时间约 5 s，采集数据达 10 GB，采用

WMS-A 反演积分吸光度需要数小时，但采用机器学习 ELM 的方法仅需要 15 s 左右，缩短了积分吸光度获取时间进而可以为流场截面的二维重建提供有力的数据支撑。

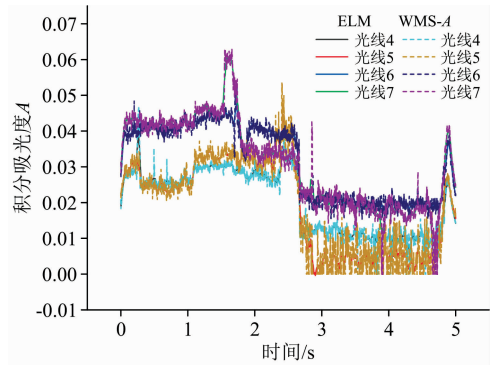


图 12 实验积分吸光度预测结果

Fig. 12 Experimental integral absorbance prediction results

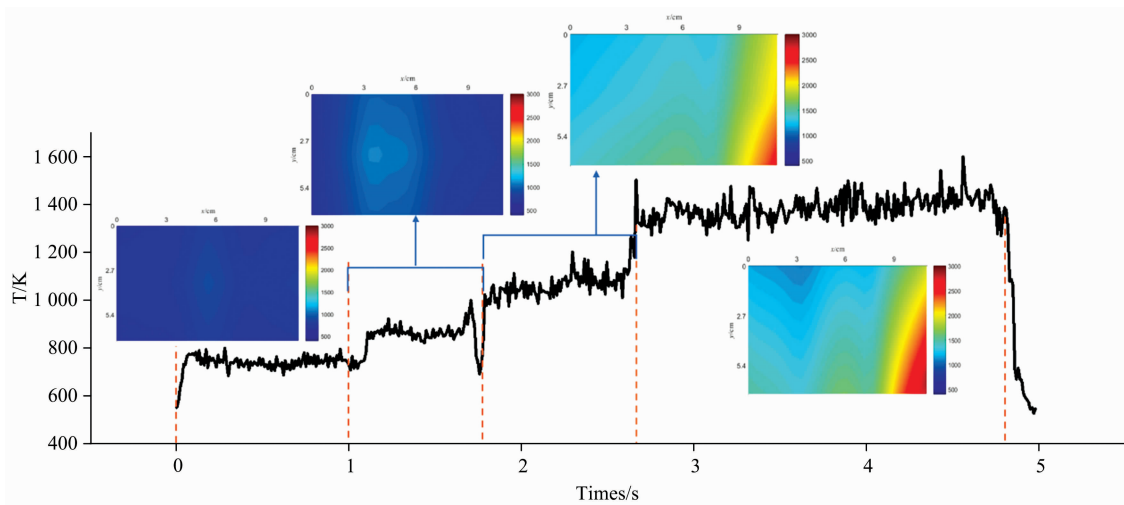


图 13 流场温度随时间变化

Fig. 13 Flow field temperature variation with time

### 4 结 论

提出了一种基于机器学习的发动机流场吸收光谱的快速测量方法。首先利用构建的流场分布仿真模型，得到归一化的谐波信号与积分吸光度的结果作为训练集，然后构建极限学习机神经网络模型开展训练，最后利用实验获得的归一化谐波信号预测积分吸光度。数值仿真结果表明，采用 1 800 组训练集训练模型，200 组数据进行模型测试，平均测试误差为 1.058%，偏差为 0.008 19。输入测试集加入 3%，5%

### References

[ 1 ] HU Zhi-yun, YE Jing-feng, ZHANG Zhen-rong, et al(胡志云, 叶景峰, 张振荣, 等). Journal of Experiments in Fluid Mechanics(实验流体力学), 2018, 32(1): 33.  
 [ 2 ] QU Dong-sheng, HONG Yan-ji, WANG Guang-yu, et al(屈东胜, 洪延姬, 王广宇, 等). Journal of Propulsion Technology(推进技术),

和 10% 的噪声时，预测误差为 3.1%，4.6% 和 8.1%，表明基于极限学习机方法测量积分吸光度方法具有抗噪声性能。在直连式超声速直连台上开展工程试验，利用机器学习的方法预测积分吸光度并进行了流场二维重建，得到了不同状态的流场二维分布，且流场二维分布结果与光路测量发动机温度走势相吻合。采用本方法获取实验数据的积分吸光度相比 WMS 解调温度、浓度和压强然后再计算积分吸光度的方法和 WMS-A 方法，计算时间短、准确性高，提高了二维重建结果质量。

- 2017, 38(6): 1395.
- [ 3 ] QU Dong-sheng, HONG Yan-ji, WANG Guang-yu, et al(屈东胜, 洪延姬, 王广宇, 等). Chinese Journal of Lasers(中国激光), 2018, 45(1): 281.
- [ 4 ] Wang Zhenhai, Fu Pengfei, Chao Xing. Applied Sciences, 2019, 9(13): 2723.
- [ 5 ] JIA Jun-wei, LI Wei, CHAI Hao, et al(贾军伟, 李 伟, 柴 昊, 等). Infrared and Laser Engineering(红外与激光工程), 2019, 48(5): 202.
- [ 6 ] Zhao W, Xu L, Huang A, et al. IEEE Sensors Journal, 2020, 20(8): 4179.
- [ 7 ] Liu C, Xu L. Applied Spectroscopy Reviews, 2018, 54(1): 1.
- [ 8 ] Song J, Xin M, Rao W, et al. Applied Optics, 2021, 60: 5056.
- [ 9 ] Yu T, Cai W, Liu Y. Review of Scientific Instruments, 2018, 89(4): 043101.
- [10] Huang J, Liu H, Dai J, et al. Journal of Quantitative Spectroscopy and Radiative Transfer, 2018, 218: 187.
- [11] XU Rui, LIANG Xun, QI Jin-shan, et al(徐 睿, 梁 循, 齐金山, 等). Chinese Journal of Computers(计算机学报), 2019, 42(7): 1640.
- [12] Ding S, Zhao H, Zhang Y, et al. Artificial Intelligence Review, 2015, 44(1): 103.
- [13] Goldenstein C S, Strand C L, Schultz I A, et al. Applied Optics, 2014, 53(3): 356.
- [14] SONG Jun-ling, JIANG Ya-jing, RAO-wei, et al(宋俊玲, 姜雅晶, 饶 伟, 等). Infrared and Laser Engineering(红外与激光工程), 2021, 50(10): 234.
- [15] Song J, Hong Y, Xin M, et al. Chinese Journal of Aeronautics 2017, 30: 1697.

## Rapid Measurement of Integrated Absorbance of Flow Field Using Extreme Learning Machine

JIANG Ya-jing, SONG Jun-ling\*, RAO Wei, WANG Kai, LOU Deng-cheng, GUO Jian-yu

State Key Laboratory of Laser Propulsion and Its Applications, University of Aerospace Engineering, Beijing 101407, China

**Abstract** The engine is the core component of the vehicle power system. The dynamic monitoring of the engine flow field can grasp the combustion situation of the internal flow field of the engine, which is of great significance for the vehicle condition monitoring and performance evaluation. Therefore, advanced diagnostic technology is the basis for the development of engine technology and one of the necessary conditions for the development of new aerospace vehicles. The laser absorption spectroscopy technique can realize the measurement of gas parameters in the combustion field, and the absorption spectroscopy wavelength modulation technique (WMS) can improve the signal-to-noise ratio in the harsh flow field environment of the engine. However, the WMS-based methods for solving the integrated absorbance, temperature, and concentration are centered on simulated annealing algorithms (SA) and suffer from long execution times. Based on the intrinsic correlation of the spectral parameters of the flow field evolving and the light distribution as fixed information, a machine learning method is used to model the harmonic signal ( $S_{2f/1f}$ ) and the integrated absorbance ( $A$ ), and the extreme learning machine algorithm (ELM) is selected, which has a short training time and fast prediction results. Using the neural network's property can approximate the true value, the simulation determines  $S_{2f/1f}$  and  $A$  for different flow field models under light layout and constructs data sets to carry out model training for the neural network. In the method validation, 2 000 data sets were simulated, 1 800 sets were selected as the training set to train the model, and the remaining 200 sets were used as the prediction set. The average relative error of the predicted integrated absorbance of the test set was 1.058%, and the coefficient of determination was 0.999, which verified the reliability of the training model. Random noise of 3% and 5% was added to the input  $S_{2f/1f}$  data set, and the average relative errors of predicted integrated absorbance were 1.89% and 3.2%, respectively, which showed that ELM has better noise resistance. Based on this method, experimental validation was carried out on a direct-connected scramjet with a practical test duration of 5 s and about 10GB of collected data, and the integrated absorbance was solved by both ELM and WMS methods respectively, and the results were consistent. Compared with the WMS method, which takes several hours to perform, the ELM predicts the integrated absorbance in about 15 seconds, enabling the rapid measurement of the integrated absorbance of the engine flow field.

**Keywords** Laser absorption spectroscopy; Wavelength modulation; Machine learning; Extreme learning machine

\* Corresponding author

(Received Jul. 21, 2021; accepted Oct. 14, 2021)