

# 基于BAM和CNN-GRU混合模型的辅助动力装置 排气温度预测方法\*

何永勃, 曹祝兵, 于洁

(中国民航大学 电子信息与自动化学院, 天津 300300)

**摘要:** 对飞机辅助动力装置 (Auxiliary Power Unit, APU) 排气温度 (Exhaust Gas Temperature, EGT) 的准确预测可为APU健康管理提供重要信息。传统方法在长周期预测中精度较低。提出一种基于特征与时序的双侧注意力机制 (Bilateral Attention Mechanism, BAM) 和卷积神经网络 (Convolutional Neural Network, CNN)-门控循环单元 (Gated Recurrent Unit, GRU) 的混合模型, 选取5个与排气温度关联度较高的特征参数对EGT进行多变量预测。引入BAM可自动量化输入变量与EGT的关联度, 并加强历史关键信息对预测输出的表达; 引入CNN可提取反映EGT非平稳动态变化的高维特征。实验结果表明: 所提出的混合模型在单步与多步的长时间序列和多变量输入EGT预测均取得很好的效果。相比于BAM-GRU模型、CNN-GRU模型、GRU模型、长短期记忆 (Long Short-Term Memory, LSTM) 模型、支持向量机 (Support Vector Machine, SVM) 模型和反向传播 (Back Propagation, BP) 模型, 混合模型的预测精度有较大程度提高。

**关键词:** 辅助动力装置; 排气温度; 门控循环单元; 特征注意力机制; 时序注意力机制; 卷积神经网络

**中图分类号:** V231.1 **文献标识码:** A **文章编号:** 1001-4055 (2022) 11-210351-09

**DOI:** 10.13675/j.cnki.tjjs.210351

## Prediction Method of Auxiliary Power Unit Exhaust Temperature Based on BAM and CNN-GRU Mixed Model

HE Yong-bo, CAO Zhu-bing, YU Jie

(School of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China)

**Abstract:** Accurate prediction of exhaust gas temperature (EGT) of aircraft auxiliary power unit (APU) can provide important information for APU health management. Traditional methods have low accuracy in long-term forecasting. A hybrid model of bilateral attention mechanism (BAM) and convolutional neural network (CNN)-gated recurrent unit (GRU) based on characteristic and temporal is proposed, five characteristic parameters with high correlation degree with exhaust temperature were selected to make multivariate prediction of EGT. The introduction of BAM can automatically quantify the correlation between input variables and EGT, and strengthen the expression of historical key information on the predicted output. The introduction of CNN can extract high-dimensional features that reflect the non-stationary dynamic changes of EGT. Experimental results show that the proposed hybrid model achieves good results in single-step and multi-step long time series and mul-

\* 收稿日期: 2021-06-02; 修订日期: 2021-07-09。

基金项目: 民航科技项目基金 (MHRD20150220)。

通讯作者: 何永勃, 博士, 副教授, 研究领域为航空检测技术及智能化仪表。

引用格式: 何永勃, 曹祝兵, 于洁. 基于BAM和CNN-GRU混合模型的辅助动力装置排气温度预测方法[J]. 推进技术, 2022, 43(11):210351. (HE Yong-bo, CAO Zhu-bing, YU Jie. Prediction Method of Auxiliary Power Unit Exhaust Temperature Based on BAM and CNN-GRU Mixed Model[J]. *Journal of Propulsion Technology*, 2022, 43(11):210351.)

tivariate input EGT predictions. Compared with the BAM-GRU model, CNN-GRU model, GRU model, long short-term memory (LSTM) model, support vector machine (SVM) model and back propagation (Back Propagation, BP) model, the prediction accuracy of the hybrid model has been greatly improved.

**Key words:** Auxiliary power unit (APU); Exhaust gas temperature (EGT); Gated and recurrent (GRU); Characteristic attention mechanism; Temporal attention mechanism; Convolutional neural network (CNN)

## 1 引言

辅助动力装置(Auxiliary Power Unit, APU)是位于飞机尾部的小型涡轮发动机,是除主发动机外的一台动力装置,可向飞机提供电源和压缩空气,也有部分APU可为飞机提供附加推力,也是当飞机在空中停车后再启动的主要装备,因此成为飞机上一个不可或缺的系统<sup>[1-3]</sup>。

排气温度(Exhaust Gas Temperature, EGT)作为一个关键的气路性能参数,可直接反映APU的运行状况,是其它性能指标退化的综合表现,因此EGT可以作为判断APU健康状态的一个主要性能指标。对EGT的准确预测可以对APU的健康状态进行监控与判断,并为维修提供决策支持<sup>[4-5]</sup>。由于APU是一个高度耦合的复杂非线性系统,其各部件工作状态变化导致了EGT呈现非线性的时变规律,使得EGT的预测变得更加复杂,所以对于EGT的预测需要考虑APU内各种性能参数的共同作用<sup>[6-8]</sup>。

国内外学者对于排气温度的预测展开了大量研究,王坤等<sup>[9]</sup>采用一种基于自适应变异粒子群的算法来对支持向量机(Support Vector Machine, SVM)参数进行优化,以此来提高APU性能参数的预测精度。曹惠玲等<sup>[10]</sup>提出了一种基于滑动时窗策略自适应优化SVM的方法,来对排气温度偏差值进行在线预测。Yilmaz<sup>[11]</sup>利用排气温度与其它发动机性能参数之间的关系对排气温度进行了评估。上述方法虽然取得了不错的预测效果,但是针对长时间序列、考虑多参数变量和多时间步进行预测时,预测精度就不是很高。对EGT的预测本质上就是对时间序列进行预测,近年来随着深度学习的迅速发展,使得对时间序列预测的研究更加有针对性<sup>[11-13]</sup>。短时神经网络的出现解决了序列长时间被遗忘的问题<sup>[14]</sup>。卷积神经网络(Convolutional Neural Network, CNN)具有强大的特征提取能力,对模型输入样本的特征进行挖掘,提取深层次的变量之间局部依赖关系,很大程度上提高了模型预测精度<sup>[15]</sup>。在时间序列预测中引入注意力机制可以为重要时段或变量进行加权,提高预

测准确度<sup>[16]</sup>。余映红<sup>[17]</sup>建立多变量的长短期记忆(Long Short-Term Memory, LSTM)模型对航空发动机性能参数进行预测。Pak等<sup>[18]</sup>搭建了CNN-LSTM的网络模型,结合相关参数变量对第二天PM2.5的平均浓度进行预测。崔宇等<sup>[19]</sup>搭建双重注意力机制的神经网络模型,对变压器中溶解气体进行多变量预测。傅颖颖等<sup>[20]</sup>将图神经网络与注意力机制进行融合,实现了对PM2.5的多步预测。Bashar等<sup>[21]</sup>提出一种基于自编码器小波的具有注意机制的深度神经网络,用于植物茎径生长的多步预测。

本文提出一种基于双侧注意力机制(Bilateral Attention Mechanism, BAM)和CNN-GRU(Gated Recurrent Unit)的混合模型来对APU的气路参数EGT进行多变量预测,选取与EGT有关的其它特征性能参数作为输入<sup>[22-23]</sup>,EGT作为输出。首先在输入侧引入特征注意力机制,对性能参数与EGT输出的关联关系进行量化;再通过一维(One Dimensional, 1D)-CNN强大的特征提取的能力,挖掘输入信息之间的局部特征关系,充分利用映射到高维空间的输入信息;最后在输出侧引入时序特征注意力机制,加强历史时刻重要信息对预测输出的表达。旨在建立时间节点下各性能参数为依赖的预测模型,挖掘APU在不同状况下性能参数的特征与EGT的联系,准确地预测EGT。

## 2 深度学习模型原理

### 2.1 1D-CNN

卷积神经网络通过局部连接和权值共享的方式对原始数据进行高维特征映射,挖掘原始数据的特征信息。1D-CNN主要用来处理时间序列,其内部结构如图1所示,主要由卷积层、池化层和全连接层等组成。对于处理时间序列,卷积层是提取数据在方向上的平移特征,提取时间序列上有效的特征向量,从数学的角度上分析就是对数据进行循环乘积与求和,具体的表达式如下

$$y(\mu) = w(\mu) \cdot v(\mu) = \sum_{\tau=0}^N w(\mu - \tau) v(\tau) M \quad (1)$$

式中 $y, w, v$ 为序列, $\mu$ 代表卷积次数, $M$ 为 $v$ 的长度。

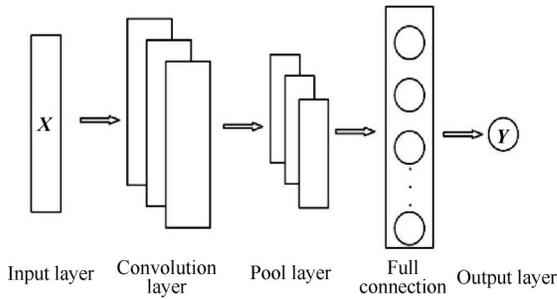


Fig. 1 1D-CNN

2.2 注意力机制

注意力机制是模拟人脑注意力的一种资源分配模型,人类大脑可以在某个时间节点上关注一些感兴趣的重要信息并忽略无关的信息,对于不同信息的注意力分配,更加能突出重要信息的影响程度。注意力模型就是通过这种对不同信息的概率分配模式,使重要信息分配更大的权重,以此来提高模型对于重要信息的提取,提高模型的预测精度。在时序预测中,注意力机制既可以作用到输入侧,来反映每个特征参数与预测输出的关联程度,也可以作用到输出侧,对历史时刻的信息进行加权表达,突出与当前预测有关的重要时间点信息。

2.3 GRU

GRU网络是LSTM网络的一种改进模式,能够捕捉时间序列的长期依赖关系。通过对LSTM网络内部的门结构进行优化,将输入门与遗忘门合并为一个更新门,同时把神经元的状态与隐层的状态进行混合,很大程度上减少了LSTM网络单元的参数数量。更新门将输入向量与 $X_t$ 与上一个时刻的状态记忆变量 $h_{t-1}$ 的合并矩阵通过激活函数的非线性变换后输入到更新门中,决定上一时刻的信息保留到当前状态的程度。重置门则以 $1 - z_t$ 倍的 $h_{t-1}$ 与 $z_t$ 倍 $\tilde{h}_t$ 的方式将先前状态信息与当前状态信息进行结合,作为当前状态信息的输出。GRU网络的基本结构如图2所示,数学表达式如式(2)所示。

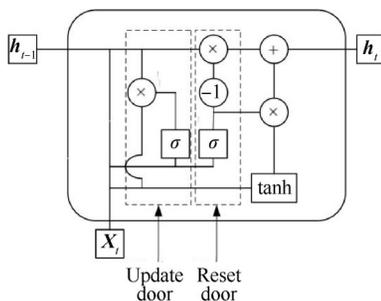


Fig. 2 GRU network

$$\begin{cases} r_t = \sigma(W_r \cdot [h_{t-1}, X_t]) \\ z_t = \sigma(W_z \cdot [h_{t-1}, X_t]) \\ \tilde{h}_t = \tanh(W_h \cdot [r_t \times h_{t-1}, X_t]) \\ h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \end{cases} \quad (2)$$

图2与式(2)中: $X_t, h_{t-1}, r_t, z_t, \tilde{h}_t, h_t$ 分别为输入信息、上一时刻的状态信息、更新门、重置门、输入向量与先前隐层状态信息的汇总、当前隐层状态的输出; $W_r, W_z, W_h$ 为各个门状态的可训练权重矩阵; $\sigma$ 表示为Sigmoid函数。

3 基于BAM和CNN-GRU混合模型的APU排气温度的预测模型

3.1 APU的排气温度的预测的数学模型

APU的EGT不仅与系统内各种部件的运转密切相关,还与外部的飞行环境有关,如大气静温、飞行高度、气压等,但是这些属于外部因素,且会间接影响系统内各部件的运行状态,进而使EGT发生变化。故根据APU内部运转规律选取低压压气机转子转速 $N_1$ ,高压压气机转子转速 $N_2$ ,燃油流量 $W_f$ ,滑油压力 $p_o$ 和滑油温度 $T_o$ 5种与EGT关联性高的性能参数作为输入参数,建立起每个时间点下相关性能参数为依赖的预测模型。

记EGT的时间序列集合为 $Y = [y_1, y_2, \dots, y_T] \in R^T$ ,输入端 $N_1, N_2, W_f, p_o$ 和 $T_o$ 5个与EGT相关特征的时间序列为 $X = [x_1, x_2, \dots, x_T] = [x^{(1)}, x^{(2)}, \dots, x^{(5)}]$ ,具体的展开式可由式(3)表示。其中 $x_t = [x_t^{(1)}, x_t^{(2)}, \dots, x_t^{(5)}]$ 表示的是5个相关特征参数变量在 $t$ 时刻测量值一个集合, $x^{(k)} = [x_1^{(k)}, x_2^{(k)}, \dots, x_T^{(k)}]$ 表示为第 $k$ 个相关特征参数在 $T$ 个历史时刻的测量值序列。

$$X = \begin{bmatrix} x_1^{(1)} & x_1^{(2)} & \dots & x_1^{(5)} \\ x_2^{(1)} & x_2^{(2)} & \dots & x_2^{(5)} \\ \vdots & \vdots & \vdots & \vdots \\ x_T^{(1)} & x_T^{(2)} & \dots & x_T^{(5)} \end{bmatrix} \in R^{T \times 5} \quad (3)$$

其中 $x^{(k)}$ 的 $k(1 \leq k \leq 5)$ 表示特征个数。 $x_t$ 的 $t(1 \leq t \leq T)$ 表示 $t$ 时刻对应特征的值。

根据与EGT相关的5种特征性能参数变量作为输入,对应时刻EGT作为模型的输出,进行未来时刻EGT的多变量预测,令整个模型的映射函数为 $F_\theta$ ,则预测值表示为

$$\tilde{y}_{T+1} = F_\theta(x_1, x_2, \dots, x_T) \quad (4)$$

为了得到每一个特征性能参数与当前时刻EGT的关联关系以及时间序列信息中的依赖关系,采用一种结合特征注意力机制与时序注意力机制的双侧

注意力与 CNN-GRU 混合模型的多变量预测方法。在输入侧引入特征注意力机制,计算出待测排气温度值与其它相关性能参数的关联程度,这样使得相关性强的特征分配到更大的权重,而削弱了相关性弱或者无关的特征信息。CNN 通过卷积池化等操作,挖掘输入信息的高维特征,有效地降低人工提取特征而产生的误差。在输出端引入时序注意力机制,目的是寻找当前时刻与长期记忆信息中历史时刻的时序关系,自主选择与当前时刻关联度高的历史关键时刻点的信息,解决 GRU 网络对于长时间序列信息的记忆衰减问题。

### 3.2 特征注意力机制

为得到 5 种特征参数与待测 EGT 的关联程度,在输入侧引入特征注意力机制,采用多层感知机的计算方式对各种特征的注意力权重进行量化。模型如图 3 所示。

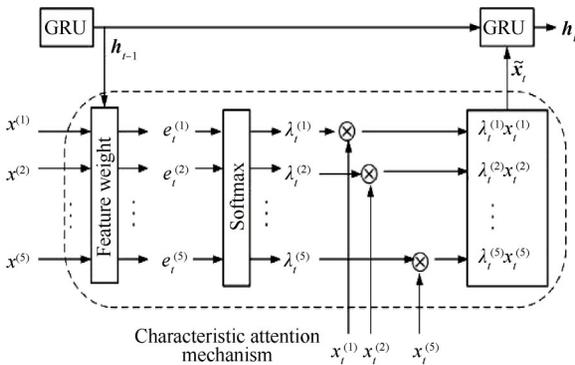


Fig. 3 Characteristic attention model

将  $t$  时刻的 5 种特征参数与前一时刻的隐层状态  $h_{t-1}$  结合,作为特征注意力机制的输入,通过式(5)计算得出此时每个特征参数所占权重,利用 Softmax 函数按式(6)对  $e_t^{(k)}$  进行归一化,即

$$e_t^{(k)} = V_e^T \text{relu}(W_e h_{t-1} + U_e x_t^{(k)} + b_e) \quad (5)$$

$$\lambda_t^{(k)} = \frac{\exp(e_t^{(k)})}{\sum_{k=1}^5 \exp(e_t^{(k)})} \quad (6)$$

式中  $V_e$ ,  $W_e$  和  $U_e$  为特征注意力机制的权重矩阵,  $b_e$  为对应的偏差项。

根据特征注意力机制分配的特征参数权重  $\lambda_t^{(k)}$  与对应的特征输入  $x_t^{(k)}$  相乘得到各个特征贡献率大小不同的关联特征  $\tilde{x}$ ,以此来对每个特征进行强弱相关不同的表达,具体可以表示为

$$\tilde{x}_t = (\lambda_t^{(1)} x_t^{(1)}, \lambda_t^{(2)} x_t^{(2)}, \dots, \lambda_t^{(5)} x_t^{(5)})^T \quad (7)$$

最后通过式(8)对输入信息  $\tilde{x}$  进行迭代,保证每个时刻  $t$  的隐层状态  $h_t$  都包含了关联特征  $\tilde{x}$

$$h_t = f_{\text{GRU1}}(h_{t-1}, \tilde{x}_t) \quad (8)$$

式中  $f_{\text{GRU1}}$  表示输入侧 GRU 的网络单元。

### 3.3 CNN 层

引入 1D-CNN 网络的是对经过特征注意力机制处理过的关联关系信息进行特征提取,将关联关系信息映射到高维特征空间,挖掘深层次的特征信息,提取特征变量中关键节点信息。卷积层对特征进行提取,池化层对信息进行筛选,dropout 层对部分神经元丢弃,以防止网络对于某些局部特征过度依赖而产生过拟合的情况。本文在 1D-CNN 与 GRU 的连接处,使用最大池化层与 dropout 层代替全连接层。这一操作既降低了输入到 GRU 网络的数据维度,减少了网络训练时间,又最大程度上保留了输入特征的时序信息,保证模型的预测准确性。

1D-CNN 网络的输出特征向量  $R_\varphi$ , 可表示为

$$C = \text{relu}(H \otimes W + b_1) \quad (9)$$

$$P = \text{maxpolling}(C) + b_2 \quad (10)$$

式中  $H$  为输入侧 GRU 隐层集合,输出  $C$  和  $P$  分别为卷积层与池化层的输出;  $W$  和  $b_1$  为卷积层的权重与偏置项;  $b_2$  为池化层的偏置项; CNN 层的输出为

$$R_\varphi = [r_1, r_2, \dots, r_{r_1}, \dots, r_\varphi] \quad (11)$$

### 3.4 时序注意力机制

由于排气温度的预测值受历史状态影响较大且不同时刻的隐层状态信息对于当前网络的输出影响程度也不同,此外由于时间序列长度的增加而使网络输出更加不准确。为了使预测值能自主处理历史状态信息,加强对于当前时刻输出关联度高的重要历史时刻信息进行表达,本文对于 GRU 网络的输出侧引入时序注意力机制。具体结构如图 4 所示。

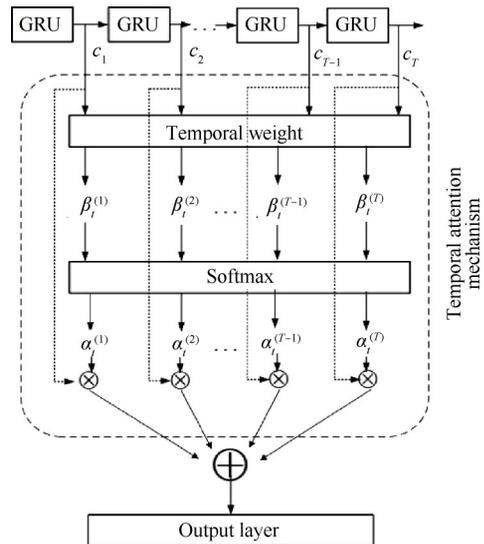


Fig. 4 Temporal attention model

包含关联关系信息的隐层状态  $\{h_{\eta}\}_{\eta=1}^T$  经过CNN处理后的时间序列信息为向量  $R_{\varphi}$ , 将其作为GRU网络的输入, 其输出表示为  $C$ , 在时间  $t$  时刻的输出表示为

$$c_t = f_{GRU2}(c_{t-1}, r_t) \quad (12)$$

式中  $f_{GRU2}$  表示输出侧GRU的网络单元。

时序注意力机制的输入为经过输出侧GRU网络处理过的输出向量  $C$ , 根据注意力机制对各时间点历史状态信息进行加权表达, 继续使用Softmax函数对于权重  $\beta_i^T$  进行归一化, 记历史各个时刻隐层状态信息对于当前时刻输出的关联程度为  $\alpha_i^{\varphi}$ 。

$$\beta_i = V_c^T \text{relu}(W_c c_i + b_c) \quad (13)$$

$$\alpha_i = \frac{\exp(\beta_i)}{\sum_{j=1}^T \exp(\beta_j)} \quad (14)$$

式中  $V_c$  与  $W_c$  表示为时序注意力的相应权重矩阵,  $b_c$  为偏差。

$\alpha_i$  表示对历史的各隐层状态信息对于当前时刻预测输出的关联程度进行了量化, 将所有的  $\alpha_i^{\varphi}$  与对应的隐层状态信息进行加权求和, 时序注意力机制在  $t$  时刻的输出用  $l_t$  表示。

$$l_t = \sum_{i=1}^T \alpha_i c_i \quad (15)$$

最后经过全连接层网络对输出信息进行维度的转换, 得到最终的排气温度预测值  $\tilde{y}_{T+1}$

$$\tilde{y}_{T+1} = F_{\theta}(x_1, x_2, \dots, x_T) = \tanh(W_y l_t + b_y) \quad (16)$$

式中  $W_y$  和  $b_y$  是对网络进行维度变化的权重与偏置。

### 3.5 基于BAM和CNN-GRU的混合模型

整个预测模型结构如图5所示, 输入信息经过特征注意力机制处理后, 得到赋予不同权重的关联信息, 随后进入GRU网络进行学习, 网络的输出作为1D-CNN的输入, 经过卷积层、池化层、dropout层的处理, 信息进入输出侧GRU网络, 隐层状态作为输出侧时序注意力机制的输入, 得到的综合信息经过迭代学习与全连接层的维度变换, 得到最终的预测输出值。此模型在训练过程中, 选择Adam(Adaptive Moment Estimation)优化算法进行各种参数的更新学习, 模型的损失函数采用mse函数, 如式(17)所示。

$$Loss = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2 \quad (17)$$

式中  $n$  表示为样本个数;  $y_i$  为EGT实际值,  $\tilde{y}_i$  为模型预测的EGT值。

## 4 实验结果与分析

### 4.1 数据预处理与评价指标

本文实验数据来自某航空公司B-787飞机的APU性能参数数据。数据记录是在其启动, 并在飞机双发启动时结束, 飞机爬升到一定高度只有主发动机在运转, 而APU通常处于关闭状态。一个飞行周期内, APU只在部分时间内运转。为了保证样本

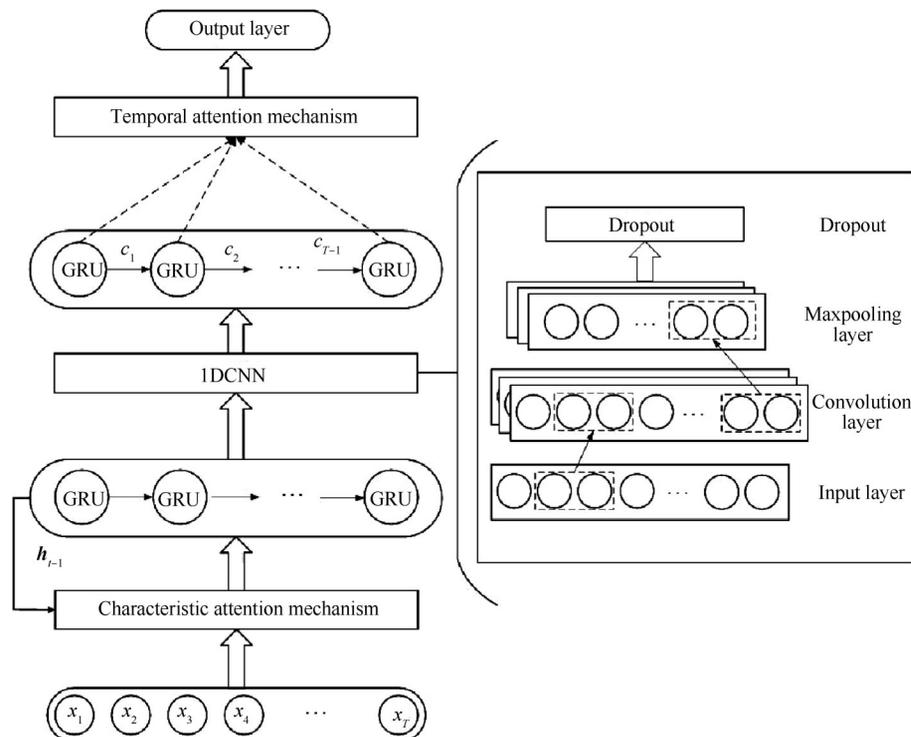


Fig. 5 Model structure based on BAM and CNN-GRU

容量能覆盖足够的航班次数,按照1min/次采集性能参数数据,共2109组数据。选取 $N_1, N_2, W_f, p_o$ 和 $T_o$ 。5个与EGT相关参数作为变量输入,对应的EGT作为输出。部分原始数据如表1所示。

Table 1 Part of raw data

Sample	EGT/°C	$N_1$ /%	$N_2$ /%	$W_f$ /(kg/h)	$p_o$ /kPa	$T_o$ /°C
1	621	64.06	93.69	2792	442.06	107.63
2	618	64.00	93.75	2823	443.99	107.56
3	615	63.94	93.75	2809	442.68	107.50
⋮	⋮	⋮	⋮	⋮	⋮	⋮
1000	648	76.31	99.25	4583	502.56	102.56
⋮	⋮	⋮	⋮	⋮	⋮	⋮

APU的排气温度与相关的特征参数在飞机航行的过程中波动范围很大,且数据的量纲级别也不同,需要对数据进行归一化的预处理。

$$x = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (18)$$

式中 $x$ 为数据归一化后的结果, $x_{\max}$ 和 $x_{\min}$ 分别为输入样本 $x_i$ 的最大值与最小值。

本文将平均绝对误差(Mean Absolute Error, MAE)、均方根误差(Root Mean Square Error, RMSE)与平均绝对误差百分比(Mean Absolute Percentage Error, MAPE)作为评价各模型预测精度的指标,表达式如下所示

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i| \quad (19)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2} \quad (20)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \tilde{y}_i|}{y_i} \times 100\% \quad (21)$$

式中 $n$ 为样本个数, $y_i$ 与 $\tilde{y}_i$ 分别为第 $i$ 个样本的实际值与模型预测值。

## 4.2 模型实验结果分析

对样本数据采用本文提出的BAM和CNN-GRU的混合模型、BAM-GRU模型、CNN-GRU模型、GRU模型、LSTM模型、BP模型和SVM模型进行预测输出。训练集和测试集以4:1的比例进行划分。上述模型中涉及GRU网络与LSTM网络结构的均采用相同的超参数(隐层神经元数量均为128,滑动窗口为6,迭代次数为400, batch\_size为256);注意力机制内

部均采用relu作为激活函数,并使用Softmax函数对其进行归一化;CNN网络的卷积层设置为64,卷积核为1,最大池化层为4,dropout为0.3;BP网络采用隐层神经元个数为8的网络结构;SVM网络采用径向基核函数。

根据本文选取的3种评价指标来评价不同模型的预测性能与精度,实验对比结果如表2所示。

Table 2 Comparison of prediction accuracy of different models

Model	MAE	RMSE	MAPE
BP	4.48	4.57	0.67
SVM	3.12	3.76	0.48
LSTM	2.96	3.47	0.46
GRU	2.71	3.17	0.42
CNN-GRU	2.02	2.98	0.32
BAM-GRU	1.97	2.39	0.30
Proposed	1.10	1.81	0.17

从表2信息得出本文算法的预测精度要优于其它6种算法,其中MAE相比于其它6种方法分别降低了75.45%,64.74%,62.84%,59.41%,45.54%,44.16%;RMSE相比于其它6种方法分别降低60.39%,51.86%,47.84%,42.90%,39.26%,24.27%;MAPE相比于其它6种方法分别降低了0.50%,0.31%,0.29%,0.25%,0.15%,0.13%。综合分析,本文算法在3种误差评价指标上都有明显的降低,表明本文算法有较为出色的预测性能。

根据误差结果分析,机器学习的方法(BP,SVM)在预测效果上不如深度学习的方法(LSTM,GRU,CNN-GRU,BAM-GRU,Proposed)突出。从表2可以看出CNN-GRU模型与BAM-GRU模型较单一的深度学习模型3种误差评价指标有了明显的下降,说明CNN网络可以通过对多变量输入性能参数的高维局部依赖关系进行挖掘,以此来提升模型的预测性能。而通过引入BAM,在输入侧量化了输入特征对输出的关联程度,自适应地提取各性能特征的贡献率,有效地避免非关键信息与次要特征信息的输出表达,而强化重要信息对于预测输出的影响;输出侧则加强了历史重要信息对于当前预测输出的关联性表达,减少信息遗漏与记忆衰减,解决了LSTM,GRU单一网络模型的预测滞后问题。

各模型在测试集上的预测输出曲线对比如图6,图7所示,由图6可以看出,传统的机器学习方法预

测效果较差,预测输出值与真实值的拟合程度较低,误差较大。

通过图7表明,深度学习模型的预测输出与真

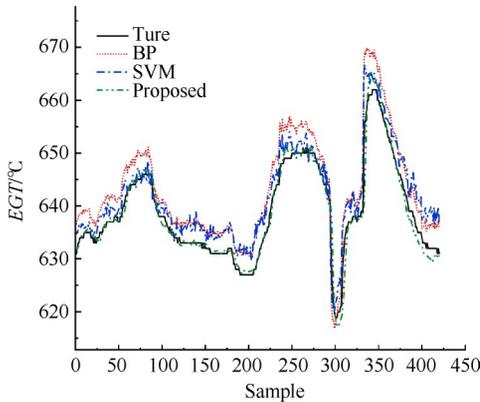


Fig. 6 Comparison of predicted values between the proposed model and the machine learning model

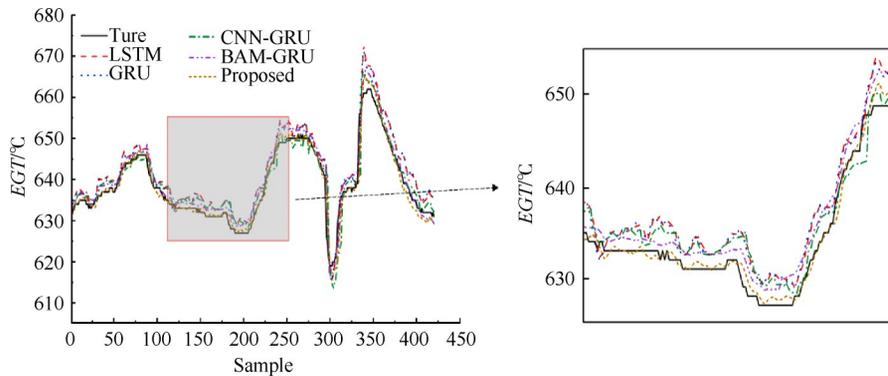


Fig. 7 Comparison between the predicted value of the proposed model and the deep learning model

### 4.3 模型效果验证

为了验证本文方法在非平稳、多变量和长周期 EGT 预测上的稳定性及泛化能力,对 EGT 进行多步预测。由于机器学习的方法预测性能不佳,这里只选用深度学习的方法来对 EGT 进行多步预测。本文选用 5 种深度学习模型对 EGT 进行 3 步与 5 步预测。采用上文提出的 3 种评价指标对各模型进行对比,由图 8 与图 9 可得出,步长的增加导致了 MAE, RMSE 与 MAPE 在不同程度上的增大,相对于单步预测来说,5 种算法的 RMSE 在 3 步预测上分别增加了 9%, 13%, 11%, 9%, 10%, ; 在 5 步预测上分别增加了 17%, 18%, 15%, 20%, 30%。这是由于多步预测是建立在单步预测基础上的滚动预测,会将单步预测的误差累计。表明步长的增加会导致模型的泛化能力与稳定性变差,预测性能也就下降。本文算法 RMSE 的增幅还是较高,不过总体而言,本文提出的模型在 3 步

实值拟合程度较高,证明了深度学习在时间序列预测上的优势。本文提出的 BAM 和 CNN-GRU 的混合模型不仅在略为平滑的区间段能准确预测,在高低峰值时间段也准确地捕捉 EGT 的变化规律。其它 4 种学习方法在部分区间段也可以对 EGT 准确预测,但是在 EGT 峰值与较为剧烈波动区域时,其预测性能与本文所提方法还是有一定的差距。表明本文所提模型在建立时间序列的长时间依赖关系、有效地捕捉 EGT 动态变化规律等方面的良好性能。通过对 EGT 准确地预测,可以提前得知 EGT 的变化规律,并与相应基线值进行比较,查看其差值是否在飞机运行允许的最大范围内,再采取对应检修策略。此外当发现在某个预测时间段内,出现 EGT 的突然大幅度升降,就需要考虑 APU 运行状态是否正常,及时排查原因以避免飞机发生安全事故。

与 5 步预测中 3 种误差评价指标仍是最小的,预测值与实际 EGT 最接近,表明本文模型在一定程度上对累计的单步误差进行了修正,提高了多步预测的精度。

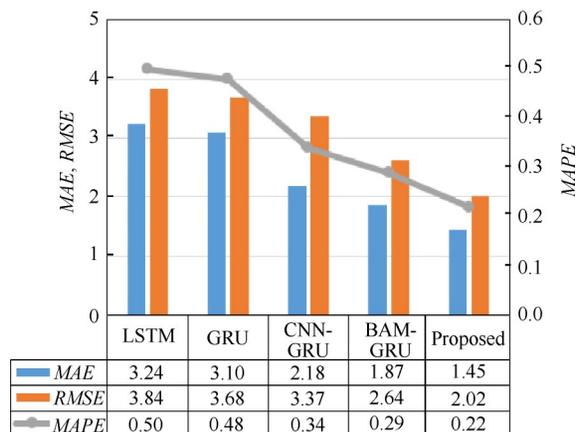


Fig. 8 Evaluation index values of different models in three-step prediction

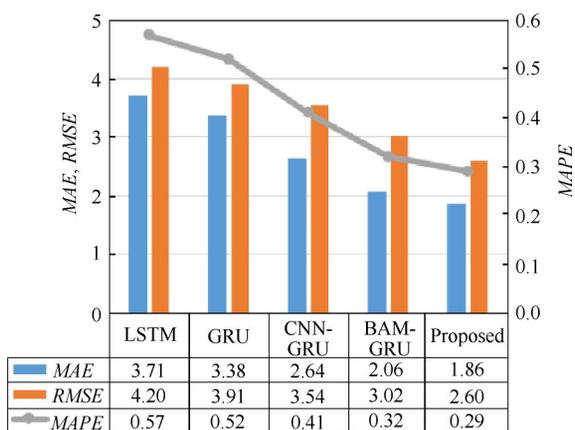


Fig. 9 Evaluation index values of different models in five-step prediction

## 5 结论

本文提出了一种基于BAM和CNN-GRU的混合模型,用以提高长周期APU排气温度模型的预测精度与稳定性。得出以下结论:

(1)构建了 $N_1, N_2, W_f, p_0$ 和 $T_0$  5个与EGT相关的性能参数特征集,利用CNN在数据挖掘上的优势,提取映射到高维空间中的特征信息,充分捕捉特征参数之间的局部依赖关系。

(2)在输入与输出两侧分别引入特征注意力机制与时序注意力机制。特征注意力机制可以量化不同特征对预测输出影响的关联程度,突出表达重要特征信息,抑制表达次要特征信息。时序注意力机制的引入可以进一步捕捉历史关键信息,并加强其对当前输出的影响程度,以此来消除对于长时间序列预测的记忆衰减问题。

(3)通过实验表明,针对长时间、多变量的APU排气温度的预测,本文提出的混合模型在单步与多步预测中,预测效果均优于其他的预测算法。但是随着预测步长的增加,模型的预测精度也随之下降,后续可以借助优化网络结构的手段,提高多步预测的稳定性。

致谢:感谢民航科技项目基金的资助。

## 参考文献

[1] 刘伟,田宏星,陈玉春,等. 航空发动机空气起动系统性能匹配计算方法[J]. 推进技术, 2020, 41(2): 277-284. (LIU Wei, TIAN Hong-xing, CHEN Yuchun, et al. Calculation Method for Performance Matching of Aero-Engine Air Starting System[J]. *Journal of Propulsion Technology*, 2020, 41(2): 277-284.)

[2] 施彬彬. 飞机辅助动力装置控制技术研究[D]. 南京: 南京航空航天大学, 2013.

[3] 赵运生,胡骏,吴铁鹰,等. 大型民用飞机辅助动力装置性能仿真[J]. 航空动力学报, 2011, 26(7): 1590-1598.

[4] 刘连胜,张晗星,刘晓磊,等. 面向飞机辅助动力装置在翼剩余寿命预测的性能参数扩增方法[J]. 仪器仪表学报, 2020, 41(7): 107-116.

[5] 董平. APU系统的状态监测与维修决策研究[D]. 南京: 南京航空航天大学, 2018.

[6] 黄江博. 航空发动机排气温度预测研究[D]. 天津: 中国民航大学, 2018.

[7] Christos S, Fakhre A, Ian J. Experimental Investigation and Simulation of a Boeing 747 Auxiliary Power Unit[J]. *Journal of Engineering for Gas Turbines and Power*, 2020, 142(8).

[8] Volponi A J, Tang L. Improved Engine Health Monitoring Using Full Flight Data and Companion Engine Information[J]. *SAE International Journal of Aerospace*, 2016, 9(1): 91-102.

[9] 王坤,侯树贤,王力. 基于自适应变异PSO-SVM的APU性能参数预测模型[J]. 系统工程与电子技术, 2021, 43(2): 526-536.

[10] 曹惠玲,王冉. 基于滑动时窗策略自适应优化支持向量机的航空发动机性能参数在线预测[J]. 推进技术, 2020, 41(8): 1887-1894. (CAO Hui-ling, WANG Ran. On-Line Prediction of Aeroengine Performance Parameters Based on Sliding Time Window Strategy Adaptive Optimization Support Vector Machine[J]. *Journal of Propulsion Technology*, 2020, 41(8): 1887-1894.)

[11] Yilmaz I. Evaluation of the Relationship Between Exhaust Gas Temperature and Operational Parameters in CFM56-7B Engines[J]. *Proceedings of the Institution of Mechanical Engineers*, 2009, 223(4): 433-440.

[12] 万晨. 基于深度学习的多变量时间序列预测算法与应用研究[D]. 南京: 南京大学, 2020.

[13] Kamara A F. 基于深度学习的时间序列分类和预测研究[D]. 合肥: 中国科学技术大学, 2020.

[14] Li F, Liu M, Zhao Y J, et al. Feature Extraction and Classification of Heart Sound Using 1D Convolutional Neural Networks[J]. *EURASIP Journal on Advances in Signal Processing*, 2019, 59: 117-171.

[15] Barzegar R, Aalami M T, Adamowski J. Short-Term Water Quality Variable Prediction Using a Hybrid CNN-LSTM Deep Learning Model[J]. *Stochastic Environmental Research and Risk Assessment*, 2020, 34(8): 1-19.

[16] Liu Y Q, Gong C Y, Yang L, et al. DSTP-RNN: A Du-

- al-Stage Two-Phase Attention-Based Recurrent Neural Network for Long-Term and Multivariate Time Series Prediction[J]. *Expert Systems with Applications*, 2020, 143(11).
- [17] 余映红. 基于深度学习的航空发动机气路参数基线建模和趋势预测研究[D]. 厦门: 厦门大学, 2019.
- [18] Pak U, Ma J, Ryu U, et al. Deep Learning-Based PM2.5 Prediction Considering the Spatiotemporal Correlations: A Case Study of Beijing, China[J]. *Science of the Total Environment*, 2020, 699(13).
- [19] 崔宇, 侯慧娟, 胥明凯, 等. 基于双重注意力机制的变压器油中溶解气体预测模型[J]. *中国电机工程学报*, 2020, 40(1): 338-347.
- [20] 傅颖颖, 张丰, 杜震洪, 等. 融合图卷积神经网络和注意力机制的PM2.5小时浓度多步预测[J]. *浙江大学学报(理学版)*, 2021, 48(1): 74-83.
- [21] Bashar A, Stefanos K, Georgios L, et al. An Autoencoder Wavelet Based Deep Neural Network with Attention Mechanism for Multi-Step Prediction of Plant Growth[J]. *Information Sciences*, 2021, 560: 35-50.
- [22] 皮骏, 黄江博, 黄磊, 等. 基于改进QPSO-SVR的航空发动机排气温度预测[J]. *振动、测试与诊断*, 2019, 39(2): 267-272.
- [23] 张帅, 杜军, 严智. 基于输出层增强的LSTM发动机排气温度模型[J]. *电子测量与仪器学报*, 2019, 3(8): 124-132.

(编辑:梅 瑛)