基于QPSO-LSTM神经网络建立 非定常气动模型的方法



魏小峰¹,魏巍²,李鹏^{1,3} 1.上海华模科技有限公司,上海 201315 2.武汉光迅科技股份有限公司,湖北 武汉 430205 3.南京林业大学,江苏 南京 210037

摘要:飞行器的空气动力学参数具有强非线性和非定常特性,利用人工智能方法建模可以避开复杂的空气动力学机制,不 仅可以降低技术门槛,还可以提高建模效率。因此,本文提出一种基于量子粒子群优化--长短时记忆(QPSO-LSTM)神经网 络的非定常气动力建模方法。以NACA0012翼型俯仰运动的非定常气动特性为研究对象,通过翼型的飞行状态参数预测翼 型在运动过程中所受到的气动力。在建模的过程中采用LSTM神经网络为基础模型,然后利用 QPSO 算法优化 LSTM 神经网 络的超参数,如层神经元个数、历史数据长度和训练批次大小。研究结果表明,QPSO 算法能较好地搜索 LSTM 神经网络超 参数的全局最优解;QPSO-LSTM 模型相比常规循环神经网络(RNN)和 LSTM 模型,在内插和外插预测气动力系数时具有更 高的精度和更好的泛化能力,该方法可被用于航空航天领域的非定常气动力预测。

关键词:QPSO; LSTM; 神经网络; 非定常; 气动力建模

中图分类号: V19

文献标识码:A

DOI: 10.19452/j.issn1007-5453.2025.02.009

气动力模型是飞行模拟机最重要的数学模型之一,气 动力/力矩的准确模拟涉及模拟机的飞行品质和逼真度,是 模拟机通过局方技术鉴定的重要评价依据^[1]。1911年, Bryan利用线性叠加法建立了线性气动模型,将气动力和力 矩参数量纲一(旧称无量纲)化表达成瞬时飞行状态参数的 线性函数关系。发展至今,线性气动力模型作为经典模型 一直广泛应用于飞机操纵性和稳定性研究^[2-3]。然而,随着 现代飞机的发展,机动性能提高导致飞行包线不断扩大,飞 行条件恶劣化使得气动力模型越来越具有强非线性和非定 常特性,如何精准建立非定常气动力模型在飞行器设计或 模拟机建模领域具有重要意义^[4]。

常规建立非定常气动力模型主要利用数学方法根据飞 行器的空气动力学物理机制和统计学规律建立气动力与飞 行状态参数的函数关系;Tobak^[5]利用积分形式将气动系数 表达为时间历程的一系列阶跃函数之和,建立了非线性非 定常气动阶跃响应模型。Goman等^[6]将状态空间方法运用 到大迎角非定常气动建模中,通过试验对比分析,该方法能 够较好地描述非定常气动特性问题。汪清等^[7-8]根据大迎 角产生的流动分离和涡结构破裂的情况,采用增量法建立 了一种大迎角非定常气动力模型,通过与风洞试验对比,该 方法能在一定程度上反映大迎角状态下的非定常气动特 性。然而这种常规建模方法虽然物理意义明确,但是结构 比较简单,对于一些强非线性且随时间变化的情况,需耦合 不同物理机制的多项式,该方法建模难度较大,且对数据质 量的要求较高。

最近随着人工智能算法和硬件设施的发展,越来越多 的研究人员转向利用人工智能方法建立气动力模型,该方 法不需要理解复杂的空气动力学机制,只需利用人工智能 模型挖掘数据背后隐藏的规律,直接将飞行状态映射为气 动力。王鹏等¹⁹¹利用传统神经网络和反向传播的算法代替 传统空气动学模型,建立了含单隐层的三层神经网络模型 和含双隐层的4层神经网络模型,预测了自由来流马赫数、

收稿日期: 2024-05-23;退修日期: 2024-10-16;录用日期: 2024-12-23 基金项目:上海市浦江人才计划(22PJ1420900)

引用格式: Wei Xiaofeng, Wei Wei, Li Peng. Method of predicting unsteady aerodynamic force based on QPSO-LSTM neural network[J]. Aeronautical Science & Technology, 2025, 36(02):102-110. 魏小峰, 魏巍, 李鹏. 基于QPSO-LSTM 神经网络建立非定常气动模型 的方法[J]. 航空科学技术, 2025, 36(02):102-110.

迎角、侧滑角等参数对某尖楔前体飞行器气动特性的影响。 Marques等^[10]利用监督学习的方法对超过1550个翼型的气 动数据进行建模。Bouhlel等[11]利用梯度增强的人工智能 神经网络算法对亚、跨声速区翼型的气动特性进行了快速 的预测。张瑞民等^[12]利用神经网络对 X-31A 和 F-18 飞机 建立了多变量非定常气动力模型,并以该模型对大迎角非 线性气动特性问题进行了预测。付军泉等[13]利用循环神经 网络(RNN)对某飞机大迎角的非定常气动力进行建模,结 果表明RNN对非定常气动力建模,收敛快且精度高。然而 RNN 在训练长时间序列的数据时容易出现梯度弥散或者 梯度爆炸,导致训练过程较难收敛,为了解决这个问题, Hochreiter等^[14]提出了长短时记忆网络(LSTM)。何磊等^[15] 证明LSTM 神经网络相较 RNN 在建立非定常气动力模型 时具有更高的精度且更容易收敛。但是LSTM神经网络的 预测精度以及泛化能力容易受到网络模型的参数影响,如 神经元个数、神经网络层数、历史数据长度和训练批次大小 等。一般训练LSTM神经网络依靠研究人员的经验进行手 动调节,这样较难获得模型参数的全局最优解。

本文提出了一种基于量子粒子群优化-长短时记忆神 经网络(QPSO-LSTM)建立非定常气动力模型的方法,该 方法利用量子粒子群优化(QPSO)算法迭代搜索LSTM神 经网络超参数的全局最优解,模型使用了NACA0012翼型 的俯仰运动非定常气动力数据进行训练,将翼型状态参数 作为输入特征以预测翼型在运动的过程中所受到的气动 力,为了验证基于QPSO-LSTM的建模有效性,将其预测结 果与常规的RNN和LSTM模型结果进行了对比分析。

1 LSTM算法

RNN 在数据量增加的情况下,容易出现梯度弥散或者 梯度爆炸的问题,使得模型训练不能收敛^[16-17]。为了解决 该问题,LSTM增加了门控机制,分别对历史信号、输入信 号和输出信号进行选择性过滤,使得神经网络对长时间序 列具有更好的记忆功能^[18]。

图1为LSTM神经网络的基本单元结构,其核心参数 主要为细胞状态 c_t、输出信号 h_t和三个门控单元(遗忘门、 输入门和输出门)。遗忘门 f_t的作用主要是根据上个时刻 的细胞状态 c_{t-1}决定哪些历史信息需要被丢弃,该操作主要 通过式(1)中的 sigmoid 函数实现,当 sigmoid 函数输出为0 时,表示上个时刻的细胞状态都不保留,而输出信号为1 时,表示上个时刻细胞状态都保留

$$f_t = \sigma(\boldsymbol{W}_{\mathrm{f}}[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_{\mathrm{f}}) \tag{1}$$

式中, σ 为sigmoid激活函数, W_{f} 和 b_{f} 分别为遗忘门的权重 系数矩阵和偏置矩阵。

输入门的作用是有选择性地记忆当前时刻输入数据 x_i 的信息并更新细胞状态 c_i 。输入门的控制变量 i_i 主要通过 sigmoid 函数对当前时刻输入 x_i 和上个时刻的输出 h_{i-1} 进行 非线性变化获得;而当前时刻候选细胞状态 \tilde{c}_i 则利用 tanh 函数对当前时刻输入数据 x_i 和上个时刻的输出 h_{i-1} 进行非 线性变换获得,然后利用式(4)更新当前时刻细胞状态 c_i

$$i_t = \sigma(\boldsymbol{W}_i[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_i)$$
(2)

$$c_{t} = \tanh(W_{c}[h_{t-1}, x_{t}] + \boldsymbol{b}_{c})$$
(3)

$$c_{t} = (f_{t}c_{t-1} + i_{t}c_{t})$$
(4)

式中, *W*_i和*b*_i分别为输入门的权重系数和偏置矩阵, *W*_e和*b*_e 分别为细胞单元的信息权重系数和信息偏置矩阵。

输出门的作用主要是控制LSTM神经网络的输出。输出门的控制变量 o_t 是通过 sigmoid 函数对当前时刻输入数据 x_t 和上个时刻的输出 h_{t-1} 进行非线性变化得到;而当前时刻输出 h_t 则利用式(6)首先对当前时刻细胞状态 c_t 进行tanh 函数变换,然后再与输出门的控制变量 o_t 进行点乘得到

$$o_t = \sigma(\boldsymbol{W}_0[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_0)$$
(5)

$$h_i = o_i * \tanh(c_i) \tag{6}$$

式中,W。和b。分别为输出门的权重系数和偏置矩阵。



Fig.1 The basic units of LSTM model

2 量子粒子群算法

Kennedy 等^[19]于 1995 年提出经典粒子群优化(PSO)算法,该算法是基于群体行为的一种优化算法,其基本思想是模仿鸟类的迁徙和觅食行为,在个体探索和社会群体性行为之间找到平衡,通过迭代搜索使粒子在解空间内跟随最优粒子进行全局搜索。PSO算法相较一般的优化算法,具

有易于实现、参数量少和运算效率更高等特点,但是随着目标问题的复杂性提高,该算法又容易陷入收敛速度慢、局部最优和鲁棒性差等问题^[20]。

为了解决上述问题, Sun Jun 等^[20]从量子力学理论出发 提出了QPSO算法,相较经典PSO算法,QPSO算法取消了 粒子的移动方向属性,这样粒子位置的更新与粒子的历史 运动没有直接关联性,使粒子的位置更新更具随机性,同时 QPSO算法引入平均最优位置参数,提高粒子间的协作能 力。相较经典PSO算法,QPSO算法具有参数量更少,收敛 速度快,更好的全局搜索和局部搜索能力以及不易陷入局 部最优点等特点^[21]。其公式如下

 $p(t) = \theta p_{ibest} + (1 - \theta)G_i(t) \tag{7}$

$$m_{\text{best}} = \frac{1}{M} * \sum_{i=1}^{M} P_{i\text{best}}$$
(8)

$$x(t+1) = \begin{cases} p(t) + \beta | m_{\text{best}} - x(t)| (-\ln \mu), & \mu \ge 0.5 \\ p(t) - \beta | m_{\text{best}} - x(t)| (-\ln \mu), & \mu < 0.5 \end{cases}$$
(9)

式中,p(t)为每个粒子的势中心点, p_{ibest} 为第i个粒子的局部最 优位置, θ 为[0,1]之间的随机值, $G_i(t)$ 为全局最优粒子, m_{best} 为粒子平均最优位置,M为粒子总数,x(t+1)为当前粒子的位 置, β 为收缩扩张因子,通常情况下, $\beta < 1.781, \mu$ 为[0,1]之间 的随机值。

3 QPSO-LSTM时间序列模型搭建

由于LSTM神经网络涉及的超参数比较多(如隐藏层 神经元个数、历史时间长度、预测长度、训练批次大小等), 预测精度容易受这些超参数影响,如果人为调优这些超参 数不仅效率比较低,而且较难找到全局最优参数组合。超 参数的优化目标是寻找最优超参数值以提高神经网络的预 测性能,这一过程即根据每次设置的超参数值,计算模型的 预测误差(预测值和训练样本真实值之间的差值),通过不 停迭代改变超参数值,使得预测误差最小化。

本文利用 QPSO 算法优化 LSTM 神经网络的超参数, 不仅可以有效提高 LSTM 神经网络的预测精度和训练效 率,而且会减少人为因素对模型训练的影响。QPSO-LSTM 时间序列模型的搭建步骤如下:

(1)获取非定常气动特性数据,根据飞行任务选取合适的特征参数并完成数特征数据的归一化,如飞行高度、飞行马赫数、迎角、迎角变化率等,并将数据集划分为训练集和验证集。

(2)建立LSTM神经网络,并定义需要QPSO算法优化的神经网络超参数,如LSTM神经网络层数、每层网络神经

元个数、历史数据长度、预测数据长度、训练数据的训练批次大小(batch size)等。

(3)初始化QPSO相关参数,包括粒子维度和粒子种群 大小、LSTM神经网络需要被优化的超参数、最大迭代次 数等。

(4)利用粒子位置参数来训练LSTM神经网络,并计 算每次训练粒子的适应度,粒子的适应度函数f为训练过程 中的均方误差,其表达式为

$$f = \sqrt{\frac{1}{N} \sum_{i=1}^{N} (\hat{y}_i - y_i)^2}$$
(10)

式中,N为训练集样本的个数, y_i 为训练样本真实值, $\hat{y_i}$ 为预测值。

(5)根据粒子适应度值的大小,确定粒子个体的局部 最优解和全局最优解,并根据式(9)更新粒子的位置。

(6)根据粒子适应度值大小和最大迭代步数判断是否 终止计算,如果满足条件,则输出最优粒子位置以及LSTM 神经网络的超参数,并执行第(7)步,如果不满足条件,则重 新执行第(4)~(6)步。

(7)将最优粒子位置参数输入LSTM神经网络并进行 训练,最后导出训练好的QPSO-LSTM神经网络模型。

4 建立非定常气动特性样本数据

4.1 建立原始样本数据

为了建立非定常气动特性样本数据,本文利用计算流体力学(CFD)仿真技术对NACA0012翼型的俯仰往复运动的气动特性进行了数值模拟,NACA0012翼型的弦长为1m,其迎角绕1/4弦长点变化历程为

$a(\tau) = a_1 + a_2 \sin(k\tau)$	(11)
-----------------------------------	------

$\tau = t \cdot V_{\infty} / c_{\text{chord}}$	(12)
--	------

 $V_{\infty} = Ma \cdot c \tag{13}$

式中,*a*(*t*)为翼型在*t*时刻迎角,*a*₁为迎角均值,*a*₂迎角振幅,*k*为缩减频率,*t*为量纲一时间,*t*为时间,*V*_s为自由来流速度,*c*_{chord}为翼型弦长,*c*为声速。

俯仰力矩的参考轴在1/4弦长处,迎角均值a₁的取值范 围为[0°,5°],间隔为1°,迎角振幅a₂的取值范围为[2.5°, 10.0°],间隔为2.5°,缩减频率k的取值为0.05、0.08、0.12,马 赫数 Ma 的取值分别为0.50、0.60、0.70、0.75、0.80、0.85、 0.90、0.95,总共生成了576组非稳态气动样本数据,每组气 动样本数据的采集总时长为2个俯仰运动周期,而数据的 采集间隔为1/240俯仰运动周期。

使用某仿真软件生成计算域并划分网格,远场进口距

离翼型前缘、出口距离翼型尾缘、侧向边界距离翼型上下表 面都为25倍弦长,流体域采用非结构化网格生成,翼型表 面网格尺寸控制在1~8mm范围,第一层边界层网格高度 0.05mm,增长率1.2,边界层最大生成40层,总网格数为4.7 万,翼型表面周围网格分布如图2所示。

计算采用瞬态密度基求解器、SST k-w模型、理想气体 模型,环境温度设置为288.15K,来流方向为水平,翼型的俯 仰方向周期运动采用动网格方法来实现,翼型初始为零迎 角状态,俯仰角为0°。对流通量项离散采用隐式 Roe-FDS 格式,梯度计算采用最小二乘格心格式,空间离散采用二阶 迎风格式,时间离散采用双时间步一阶隐式格式。真实时 间迭代步长为一个俯仰运动周期的1/240,迭代至翼型气动 力周期稳定后,继续迭代两个周期并记录俯仰角和气动力 的时间历程。





为了验证 CFD 仿真的准确性,对翼型静止状态,迎角为2°,来流 Ma为0.77 的工况进行仿真计算,由图3 可以看出,CFD 仿真获得的翼型表面压力分布和风洞试验值基本吻合,其精度大约为93%,说明 CFD 仿真的气动特性数据可以代替试验数据作为神经网络训练与验证的样本数据。

4.2 数据清洗及样本数据划分

为了消除不同特征数据之间量级差别对模型收敛性的影响,需要对不同特征的数据采用归一化处理。本文采用minmax 归一化方法将不同特征的气动特性数据转换到[0,1]区间,min-max 归一化的公式为

$$\hat{x} = (x - x_{\min})/(x_{\max} - x_{\min})$$
 (14)



Fig.3 The comparisons of pressure distribution at NACA0012 airfoil surface between CFD and wind tunnel test

式中, *x*为每列特征归一化后的数据, *x*为每列特征原始数据, *x*_{min}为每列特征数据的最小值, *x*_{max}为每列特征数据的最大值。

本文搭建了两层LSTM 神经网络模型和一层全连接层, 然后利用QPSO算法优化神经网络模型的超参数:历史数据 长度、LSTM 神经网络每层神经元个数和训练数据的批次大 小。神经网络模型以参数马赫数 Ma 和迎角 α (τ)为输入,而 输出则为升力系数 C_L、阻力系数 C_D和俯仰力矩系数 C_m,训练 样本数为 Ma 0.50、Ma 0.60、Ma 0.75、Ma 0.80、Ma 0.85 和 Ma 0.90 共6组数据,而模型验证数据则为 Ma 0.70 和 Ma 0.95 两组数据。LSTM 神经网络的激活函数为 Relu,训练过程中 设置的损失函数为 MSE,优化器为 adam, QPSO 算法的粒子 数量为 10,粒子维度为4,收缩扩张因子 β=0.6。

训练好的 QPSO-LSTM 模型采用平均绝对误差 (MAE)和相对百分比误差(RPE)作为模型评判标准, RPE 和MAE 值越小,说明模型越好。

$$MAE = \frac{1}{N} \sum_{i=1}^{N} |\hat{y}_{i} - y_{i}|$$
(15)

$$RPE = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^{N} (\hat{y}_i - y_i)^2}}{\sqrt{\frac{1}{N} \sum_{i=1}^{N} {y_i}^2}}$$
(16)

4.3 计算结果与分析

本文的基础LSTM神经网络模型设置参考了何磊等^[14]的研究,即利用两层LSTM建立时序神经网络结构,然后利 用一层全连接层将LSTM层输出的结果转化为任务所需的 气动力系数,为了防止训练过程出现过拟合现象,在第二层 LSTM 层和全连接层之间添加丢弃层(dropout)且设置丢弃 率为0.2。由于LSTM 神经网络的预测精度对模型的超参 数设置比较敏感(如历史数据长度、LSTM 神经元个数、训 练批次大小),本文利用 QPSO 算法对相关参数进行自动优 化,优化的历史数据长度取值范围为[5,60],两层 LSTM 神 经元个数的取值范围为[10,200],训练的批次大小取值范 围为[30,200]。经迭代收敛后,LSTM 神经网络的最优参数 如图 4 所示,历史数据长度为 38,第一层 LSTM 神经元个数 为 125,第二层 LSTM 神经元个数为 134,将上述最优网络 参数代入基础 LSTM 神经网络并使用气动样本数据进行训 练即得到 QPSO-LSTM 神经网络模型。





为了验证 QPSO 算法的优化效果,本文将 QPSO-LSTM模型的预测效果与未优化的 RNN模型和LSTM模型 进行对比,其中 RNN和LSTM模型参数设置参考了何磊 等^[14]的研究,即每层神经元个数为64,全连接层神经元个数 为3,历史数据的长度为10。使用三个训练好的模型对工 况*Ma* 0.70,*k*=0.05,*a*₁=0°,*a*₂=2.5°的样本数据进行预测,由 图 5~图7可以看出,总体上,LSTM、RNN和QPSO-LSTM 模型都能较好地反映气动力/力矩系数的变化趋势,在全迎 角范围内,QPSO-LSTM模型的预测结果都能较好地符合 CFD仿真结果,而LSTM模型在大迎角工况状态下预测升 力系数和阻力系数具有较大误差,RNN模型则在预测俯仰 力矩系数时具有较大误差。

为了验证三个模型的外插预测效果,利用三个模型对 Ma 0.95、k=0.12、a₁=0°、a₂=5.0°工况进行预测。由图 8~图 10可以看出,在外插预测时,QPSO-LSTM模型在全迎角范 围内都能较好地预测CFD仿真数据;而RNN模型在迎角范 围[-5°,-3°]预测升力系数有较大误差,且在全迎角范围内,



图5 不同人工智能模型预测的升力系数与CFD仿真结果 对比(*Ma*=0.70, *k*=0.05, *α*₁=0°, *α*₂=2.5°)

Fig.5 The comparisons of lift coefficients obtained from AI models and CFD at the condition of $Ma=0.70, k=0.05, \alpha_1=0^\circ, \alpha_2=2.5^\circ$



图6 不同人工智能模型预测的阻力系数与CFD仿真结果 对比(Ma 0.70, k=0.05, a₁=0°, a₂= 2.5°)

Fig.6 The comparison between drag coefficients obtained from AI models and CFD at the condition of $Ma \ 0.70, k=0.05, \alpha_1=0^\circ, \alpha_2=2.5^\circ$



图 7 不同人工智能模型预测的俯仰力矩系数与CFD仿真 结果对比(*Ma* 0.70, *k*=0.05, *α*₁=0°, *α*₂=2.5°)

Fig.7 The comparison between pitching moment coefficients obtained from AI models and CFD at the condition of $Ma \ 0.70, k=0.05, \alpha_1=0^\circ, \alpha_2=2.5^\circ$



图 8 不同人工智能模型预测的升力系数与CFD仿真结果 对比(Ma 0.95, k=0.12, α₁=0°, α₂= 5.0°)

Fig.8 The comparisons between lift coefficients obtained from AI models and CFD at the condition of $Ma \ 0.95, k=0.12, \alpha_1=0^\circ, \alpha_2=5.0^\circ$

预测俯仰力矩系数都不太理想;LSTM模型则在迎角范围 [-5°,3°]预测阻力系数有较大误差。

为了增加不同神经网络超参数组合对比的严密性,作者 增加了对比超参数组合数量,不同神经网络的超参数设置详 见表1。由表2和表3可以看出,在工况Ma0.70进行内插预 测时,QPSO-LSTM模型对升力系数、阻力系数和俯仰力矩系 数的预测误差都小于3%,当两层神经元数分别设置为150, 200时,LSTM模型的性能稍微逊于QPSO-LSTM模型,RNN 模型性能随着神经元数设置波动较大,当RNN模型在神经元 数分别为150和200时,模型预测性能下降明显,特别是RNN



图 9 不同人工智能模型预测的阻力系数与CFD 仿真结果 对比(*Ma* 0.95, *k*=0.12, *α*₁=0°, *α*₂= 5.0°)

Fig. 9 The comparisons between drag coefficients obtained from AI models and CFD at the condition of $Ma~0.95, k=0.12, \alpha_1=0^\circ, \alpha_2=5.0^\circ$



图 10 不同人工智能模型预测的俯仰力矩系数与CFD 仿真 结果对比(*Ma* 0.95, *k*=0.12, *a*₁=0°, *a*₂=5.0°)

Fig.10 The comparison between pitching moment coefficients obtained from AI models and CFD at the condition of $Ma \ 0.95$, k=0.12, $a_1=0^\circ$, $a_2=5.0^\circ$

(200)模型,在预测升力系数时,误差高达25.3%。在工况 Ma 0.95进行外插预测时,QPSO-LSTM模型对升力系数、阻力系 数和俯仰力矩系数的预测误差都小于1.5%,LSTM(150)和 LSTM(200)的预测准确率要明显低于QPSO-LSTM模型,而 RNN模型在增加神经元数时,性能下降较快,RNN(200)预测 俯仰力矩的误差高达15.8%。这说明LSTM神经网络和RNN 的超参数设置与模型性能不是线性关系,实际上是强非线性 或者非凸函数关系,单纯地增加或减少神经元个数并不能提 高模型预测性能。

表1 不同神经网络的超参数设置

Table1 The hyperparameter values of different neural networks

	历史数据	历史数据 第一层 第			
智能模型	长度	神经元/个	神经元/个	训练批次	
RNN(64)	10	64 64		100	
LSTM(64)	10	64	64	100	
RNN(150)	150	150	150	100	
LSTM(150)	150	150	150	100	
RNN(200)	200	200	200	100	
LSTM(200)	200	200	200	100	
QPSO-LSTM	38	125	134	100	

表2 不同人工智能模型的预测误差对比(Ma 0.70)

Table 2 The prediction errors of different AI models under *Ma* 0.70 condition

知此措刑	C_L		C_D		C_m	
首肥傑望	RPE/%	MAE	RPE/%	MAE	RPE/%	MAE
RNN	4.024	0.022	1.564	0.001	10.204	0.006
LSTM	4.876	0.028	2.896	0.003	4.158	0.002
QPSO-LSTM	1.566	0.009	1.443	0.001	2.781	0.001

表3 不同人工智能模型的预测误差对比(Ma 0.95)

Table 3 The prediction errors of different AI models under Ma 0.95 condition

知台出书刊	C_L		C_D		C_m	
百肥快型	RPE/%	MAE	RPE/%	MAE	RPE/%	MAE
RNN	4.008	0.018	0.862	0.001	6.822	0.008
LSTM	2.585	0.013	1.013	0.002	2.332	0.003
QPSO-LSTM	1.093	0.006	0.455	0.001	1.532	0.002

5 结论

由于LSTM模型的预测精度对神经网络的超参数设置 比较敏感,本文利用QPSO算法对LSTM模型的历史数据 长度、神经元个数和训练批次大小参数进行自动优化,该算 法根据种子粒群的位置计算粒子适应度,再基于粒子适应 度的变化求解LSTM模型超参数的全局最优解。气动特性 样本数据则通过对NACA0012 翼型进行CFD数值模拟获 得,通过改变翼型迎角的初始角度、变化频率和幅度而获得 不同工况的非定常气动特性数据。利用QPSO-LSTM模型 对气动特性样本数据进行学习并与常规RNN模型和 LSTM模型进行对比,结果表明:

(1) QPSO算法在搜索LSTM神经网络超参数的全局最优解时表现良好,在工况 Ma 0.70进行内插预测时, QPSO-

LSTM模型对升力系数、阻力系数和俯仰力矩系数的预测 误差都小于3%,当两层神经元数分别设置为150、200时, LSTM模型的性能稍逊于QPSO-LSTM模型,RNN模型性 能随着神经元个数设置波动较大,当RNN模型的神经元个 数分别为150和200时,模型预测性能明显下降,特别是 RNN(200)模型,在预测升力系数时,误差高达25.3%。

(2) 在工况 Ma 0.95 进行外插预测时, QPSO-LSTM 模型对升力系数、阻力系数和俯仰力矩系数的预测误差都小于1.5%, LSTM (150)和 LSTM (200)的预测准确率要明显低于 QPSO-LSTM 模型, 而 RNN 模型在增加神经元个数时,性能下降较快, RNN (200)预测俯仰力矩系数的误差高达15.8%。

(3) LSTM 神经网络和 RNN 神经网络的超参数设置与 模型性能不是线性关系,实际上是强非线性,单纯地增加或 减少神经元个数并不能提高模型预测性能。

参考文献

- 张俊杰,李刚,伍小东,等.飞行模拟机数据包发展综述[J]. 测控技术, 2021, 40(7): 51-56.
 Zhang Junjie, Li Gang, Wu Xiaodong, et al. Overview of flight simulator data package development[J]. Measurement & Control Technology, 2021, 40(7): 51-56. (in Chinese)
 江涛 萬心無 飞机士攻魚信計力建模研究世展印,信計京
- [2] 汪清,蔡金狮.飞机大攻角气动力建模研究进展[J]. 气动实 验与测量控制, 1994, 8(3):7-16.

Wang Qing, Cai Jinshi. Advance in aerodynamic modeling of airplane at high angles of attack[J]. Aerodynamic Experiment and Measurement & Control, 1994, 8(3): 7-16. (in Chinese)

 [3] 魏小峰, 吴宏. 带抑涡支孔结构新型气膜孔的实验研究[J]. 航空科学技术,2015,26(1): 49-54.
 Wei Xiaofeng, Wu Hong. Experimental investigation on improvement of film cooling effectiveness with anti-vortex

holes[J]. Aeronautical Science & Technology, 2015, 26(1): 49-54. (in Chinese)

- [4] Chen Si, Li Hao, Guo Shijun, et al. Unsteady aerodynamic model of flexible flapping wing[J]. Aerospace Science and Technology, 2018, 80: 354-367.
- [5] Tobak M. On the use of the indicial function concept in the analysis of unsteady motion of wings and wing-tail combinations[R]. NACA R-1188, 1954.
- [6] Goman M, Khrabrov A. State-space representation of aerodynamic characteristics of an aircraft at high angles of

attack[J]. Journal of Aircraft, 1994, 31(5): 1109-1115.

[7] 汪清,蔡金狮.飞机大攻角非定常气动建模与辨识[J]. 航空 学报, 1996, 17(4): 391-398.

Wang Qing, Cai Jinshi. Unsteady aerodynamic modeling and identification of airplane at high angles of attack[J]. Acta Aeronautica et Astronautica Sinica, 1996, 17(4): 391-398. (in Chinese)

 [8] 汪清,何开峰,钱炜祺,等.飞机大攻角空间机动气动建模研 究[J]. 航空学报, 2004, 25(5): 447-450.
 Wang Qing, He Kaifeng, Qian Weiqi, et al. Aerodynamic

modeling of spatial maneuvering aircraft at high angle of attack [J]. Acta Aeronautica et Astronautica Sinica, 2004, 25(5): 447-450. (in Chinese)

- [9] 王鹏, 胡远思, 金鑫, 等. 尖楔前体飞行器 FADS 系统的神经 网络算法[J]. 空气动力学报, 2017, 35(6): 777-780.
 Wang Peng, Hu Yuansi, Jin Xin, et al. Neural network algorithm for FADS system applied to the vehicles with sharp wedged fore-bodies[J]. Acta Aerodynamica Sinica, 2017, 35 (6): 777-780. (in Chinese)
- [10] Marques A N, Wang Q, Marzouk Y. Data-driven integral boundary-layer modeling for airfoil performance prediction in laminar regime[J]. AIAA Journal, 2017, 56(11): 1-15.
- [11] Bouhlel M, He S, Martins J. Scalable gradient-enhanced artificial neural networks for airfoil shape design in the subsonic and transonic regimes[J]. Structural and Multidisciplinary Optimization, 2020, 61: 1363-1376.
- [12] 张瑞民,张石玉,赵俊波.基于神经网络的非定常气动力建模 研究[J]. 计算机仿真, 2017, 34(2): 106-110.
 Zhang Ruimin, Zhang Shiyu, Zhao Junbo. The research of neural network in modeling of unsteady aerodynamics[J].
 Computer Simulation, 2017, 34(2): 106-110. (in Chinese)
- [13] 付军泉,史志伟,陈坤,等.基于EKF的实时循环神经网络的 非定常气动力建模中的应用[J].空气动力学报,2018,36(4): 658-663.

Fu Junquan, Shi Zhiwei, Chen Kun, et al. Applications of realtime recurrent neural network based on EKF in unsteady aerodynamics modeling[J]. Acta Aerodynamica Sinica, 2018, 36(4): 658-663. (in Chinese)

[14] Hochreiter S, Schmidhuber J. Long short-term memory[J].

Neural Computation, 1997, 9(8): 1735-1780.

[15] 何磊,张显才,钱炜祺,等.基于长短时记忆神经网络的非定 常气动力建模方法[J].飞行力学,2021,39(5):8-12.

He Lei, Zhang Xiancai, Qian Weiqi, et al. Unsteady aerodynamics modeling method based on long short-term memory neural network[J]. Flight Dynamics, 2021, 39(5): 8-12. (in Chinese)

 [16]何昆鹏,赵瑾玥,周琪,等.基于LSTM神经网络的机载光纤 陀螺温度冲击误差补偿技术[J].航空科学技术,2024,35(2): 31-38.

He Kunpeng, Zhao Jinyue, Zhou Qi, et al. Temperature shock error compensation technology for airborne fiber optic gyroscopes based on LSTM neural networks[J]. Aeronautical Science & Technology, 2024, 35(2):31-38. (in Chinese)

[17] 王思宇,卢瑞涛,黄攀,等.基于Swin Transformer 和注意力机 制的红外无人机检测算法[J]. 航空科学技术,2024,35(2): 39-46.

Wang Siyu, Lu Ruitao, Huang Pan, et al. Infrared UAV detection algorithm based on Swin Transformer and attention mechanism[J]. Aeronautical Science & Technology, 2024, 35 (2):39-46.(in Chinese)

- [18] 王志刚,王业光,杨宁,等.基于LSTM的飞行数据挖掘模型 构建方法[J]. 航空学报, 2021, 42(8): 525800.
 Wang Zhigang, Wang Yeguang, Yang Ning, et al. Construction method of flight data mining model based on LSTM[J]. Aata Aeronautica et Astronautica Sinica, 2021, 42(8): 525800. (in Chinese)
- [19] Kennedy J, Eberhart R C. Particle Swarm Optimization[C]// Proceedings of ICNN' 95 International Conference on Neural Networks, 1995: 1942-1948.
- [20] Sun Jun, Xu Wenbo, Feng Bin. A Global search strategy of quantum-behaved particle swarm optimization [C]// Proceedings of IEEE Conference on Cybernetics and Intelligent Systems, 2004: 111-116.
- [21] 沈佳宁.基于QPSO算法求解多目标优化问题及其应用[D]. 无锡:江南大学, 2008.
 Shen Jianing. Solving Multi-objective problem base on QPSO algorithm [D]. Wuxi: Jiang Nan University, 2008. (in Chinese)

Method of Predicting Unsteady Aerodynamic Force Based on QPSO–LSTM Neural Network

Wei Xiaofeng¹, Wei Wei², Li Peng^{1,3}

1. China Simulation Sciences Co., Ltd., Shanghai 201315, China

2. Accelink Technologies Co., Ltd., Wuhan 430205, China

3. Nanjing Forestry University, Nanjing 210037, China

Abstract: Aircraft aerodynamic parameters are highly nonlinear and exhibit significant unsteady characteristics, making traditional modeling approaches complex and technically demanding. Leveraging artificial intelligence (AI) methods can bypass these complexities, lower the technical barriers, and enhance modeling efficiency. This paper proposes a method of predicting unsteady aerodynamic force by using QPSO-LSTM neural network. The QPSO-LSTM model is constructed by initially employing the LSTM algorithm as the base neural network model, followed by the application of QPSO algorithm to globally optimize the neural network hyperparameters. The hyperparameters include the number of neurons per network layer, historical length of training data, and batch size during the training process. To validate the effectiveness of the modeling approach, the neural network is trained by using aerodynamic force data obtained from numerical simulations of NACA0012 airfoil under various periodic pitching motion conditions. The results indicate that QPSO algorithm is a good choice for optimizing LSTM neural network hyperparameters, which could effectively search for the global optimal solution and avoid human factors to influence the results in setting the hyperparameters. The QPSO-LSTM neural network also demonstrates the capability of precisely predicting unsteady aerodynamic force coefficient across various flight conditions, solely relying on limited flight input parameter. This feature could make the modeling method to be conveniently deployed. Furthermore, compared to conventional RNN and LSTM models, the QPSO-LSTM model demonstrates superior accuracy and enhances generalization capabilities in predicting unsteady aerodynamic force coefficients in both interpolation and extrapolation scenarios. This approach holds significant potential for applications in unsteady aerodynamic force prediction within the aerospace sector.

Key Words: QPSO; LSTM; neural network; unsteady; modeling aerodynamic force