

基于 LSTM 的暂冲式风洞马赫数建模与控制方法

张之豪, 刘国东, 胡强, 李乾, 张江

(中国航天空气动力技术研究院 空气动力研究所, 北京 100086)

摘要: 进行亚跨声速风洞试验时, 模型迎角快速变化导致马赫数剧烈振荡, 传统 PID 控制策略难以使马赫数快速稳定。基于长短时记忆神经网络(LSTM), 提出一种适用于某暂冲式风洞的马赫数建模与智能控制一体化方法。建模方法使用同一试验模型的历史试验数据对 LSTM 网络进行训练, 以过去 20 个时间步的扰动(包括气源压力、模型迎角、阀门开度、马赫数)作为输入, 预测当前时刻试验段马赫数的输出, 建模精度达 $R^2 > 0.98$ 。基于 LSTM 模型, 提出小扰动最优化智能控制方法, 该方法在每个时间步对阀门开度进行局部扰动寻优, 使下一时刻的马赫数输出逼近目标值。结果表明: 在理想情况下, 目标马赫数 1.2、0.95、0.8 时马赫数均方根误差(RMS)分别降低 76%、82%、51%; 即使在引入 LSTM 模型预测误差后, RMS 仍分别降低 61%、56%、42%, 系统抗扰动能力得到显著提升。

关键词: LSTM; 马赫数控制建模; 智能控制; 风洞试验; 深度学习

中图分类号: V211.74

文献标识码: A

A LSTM-based modeling and control method for Mach number in an intermittent wind tunnel

ZHANG Zhihao, LIU Guodong, HU Qiang, LI Qian, ZHANG Jiang

(Institute of Aerodynamics, China Academy of Aerospace Aerodynamics, Beijing 100086, China)

Abstract: An integrated method for Mach number modeling and intelligent control is proposed based on the Long Short-Term Memory (LSTM) neural network in an intermittent wind tunnel, considering the challenge that rapid changes in the angle of attack of a test model cause severe Mach number oscillations and traditional PID control strategies fail to stabilize the Mach number quickly. The LSTM network is trained using historical test data obtained from the same test model to predict the current Mach number in the test section, with inputs of disturbance variables from the past 20 time steps, including air source pressure, angle of attack of the test model, valve opening degree, and Mach number. The prediction precision of the model achieves $R^2 > 0.98$. Based on the established LSTM model, a small-perturbation-optimization based intelligent control method is developed. At each time step, the valve opening degree is locally perturbed and optimized to drive the predicted Mach number in the next time step moving towards the target value. Simulation results demonstrate that the root mean square error (RMSE) of Mach number are reduced by 76%, 82% and 51% at target Mach numbers of 1.2, 0.95 and 0.8, respectively, under ideal conditions, while reduced by 61%, 56% and 42% considering LSTM prediction errors, indicating significantly enhanced anti-disturbance capability.

Key words: LSTM; Mach number control modelling; intelligent control; wind tunnel test; deep learning

收稿日期: 2026-04-01; 修回日期: 2026-07-10

通信作者: 刘国东(1992-), 男, 硕士, 工程师。E-mail: rendouzao@163.com

引用格式: 张之豪, 刘国东, 胡强, 等. 基于 LSTM 的暂冲式风洞马赫数建模与控制方法[J]. 航空工程进展.

ZHANG Zhihao, LIU Guodong, HU Qiang, et al. A LSTM-based modeling and control method for Mach number in an intermittent wind tunnel[J]. Advances in Aeronautical Science and Engineering. (in Chinese)

0 引言

跨声速下的马赫数控制是风洞试验中的关键难点。当马赫数趋近于1时,激波的出现导致试验模型阻力急剧增大^[1],显著提高试验段阻塞度,同时,模型迎角的大幅变化亦会加剧阻塞度的波动,引发马赫数的剧烈振荡。马赫数的不稳定不仅直接影响试验数据的精度,还会延长试验周期、增加运行成本,对控制系统的抗干扰能力提出了极高要求^[2]。

当前亚跨风洞马赫数控制系统普遍依赖PID(Proportional-Integral-Derivative)控制策略,其参数通常依靠经验手动整定,且在运行过程中保持恒定,该策略在应对模型迎角变化、气源压力波动等外部扰动时,响应速度与抑制能力不足,导致马赫数在目标值附近出现显著波动。为了提升控制精度,研究者们开展了大量工作,形成了两类控制策略。第一类是对传统PID方法的改进,包括前馈控制^[3-5]、前馈—反馈复合控制^[6-9]、模糊PID^[10]以及自适应PID^[11-12]等,这类方法多基于传统的系统辨识模型建立马赫数预测模型,但由于影响试验段马赫数的因素众多,如气源压力、阀门开度、模型迎角以及模型外形等,输入与输出之间呈现出多变量耦合、动态滞后、强非线性等复杂特征,传统辨识模型难以对映射关系进行精确描述。近年来,随着人工智能技术的迅猛发展,第二类智能控制策略应运而生,人们相继将智能优化算法^[5, 13-14]、机器学习^[2, 15-16]、深度学习^[17-23]等引入马赫数控制与建模领域,其中深度学习凭借其强大的非线性函数逼近能力,为解决复杂动态系统的建模与控制问题提供了新思路。目前,基于深度学习的方法尚处于起步阶段,研究重点集中在两方面:一是建立高精度的马赫数预测模型,为先进控制策略提供基础;二是直接或间接设计智能控制器,提升流场控制品质。在建模方面,东北大学Zhao L P课题组^[18-21]针对连续式风洞,以长短时记忆神经网络(Long Short-Term Memory, LSTM)为核心,开展了系列研究:针对风洞系统的强非线性与时滞特性,将卷积神经网络(CNN)、注意力机制(Attention)与LSTM相结合,构建了CNN-LSTM-Attention预测模型,在多工况下预测精度显著优于传统方法^[18];针对马赫数建立阶段与稳定阶段的差异化特性,分别采用LSTM、径向基函

数神经网络(Proportional-Integral-Derivative, RB-FNN)进行建模,马赫数预测均方根误差(Root Mean Square Error, RMSE)达到 $10^{-3} \sim 10^{-4}$ 量级^[19];为提升模型可解释性并减少数据量依赖,提出物理信息长短时记忆网络(P-LSTM),将等熵流动方程嵌入损失函数,使预测结果严格遵循气体动力学规律, RMSE较传统LSTM降低50%以上^[20]。在控制器设计层面,王凯文^[17]利用BP(Backpropagation)神经网络对风洞系统进行离线辨识,并采用单神经元PID控制器,将误差的比例、积分、微分作为神经元输入,实现了PID参数的自整定,仿真结果表明该方法较传统PID显著改善了动态响应与抗扰性能;Tian J Y等^[23]针对2 m高速自由射流风洞,创新性地构建了调压阀特性神经网络,实现对任意马赫数下阀门开度的精准预测,并结合前馈补偿与自适应静压匹配控制,成功实现了超声速连续变马赫数运行。

总体来看,现有研究在深度学习辅助风洞马赫数控制方面取得了显著进展,但其潜力尚未被充分挖掘,仍存在进一步探索的空间:第一,多数研究集中于“预测”环节,即利用深度学习建立高精度的马赫数预测模型,却未将预测模型有效应用于马赫数控制中,且现有建模方法多针对连续式风洞,缺乏适用于暂冲式风洞的建模手段^[18-21];第二,少数涉及控制器设计的研究仍以改进PID参数为主,未能充分利用深度学习模型提供的动态信息进行在线优化决策^[17, 23]。

基于此,本文针对某暂冲式风洞,提出一种基于长短时记忆神经网络(LSTM)的建模与控制一体化方法,将LSTM预测模型嵌入控制回路,实现对迎角变化等扰动的快速补偿,提升马赫数控制的动态响应与抗扰能力。

1 某暂冲式亚跨超风洞马赫数控制系统

某暂冲式亚跨超风洞的主体布局及马赫数控制系统运行示意图如图1所示,红色箭头代表气流的运动方向,黑色箭头代表控制输入或输出方向。当前,风洞试验段的马赫数调节通过改变高压气源下游的调压阀开度实现,控制策略使用传统的PID控制,在每一时刻,计算当前马赫数 Ma 与目标马赫数 Ma_{obj} 之间的差值 e ,经PID控制器进行比

例、积分、微分运算后,输出阀门开度控制增量 ΔL 。试验段马赫数的建立过程分两个阶段:第一阶段为流场建立阶段,首先预设阀门开度,使马赫数由零快速上升,待其接近目标值后启动PID控制,采用第一组参数进行粗调;第二阶段为马赫数稳定阶段,当马赫数在目标值附近基本稳定后,切换至第二组参数进行精调,使马赫数维持在目标值。该控制方法在空风洞或模型迎角固定情况下有良好效果,但在跨声速条件下,模型迎角变化会对马赫数产生明显扰动,此时传统PID策略难以实现快速稳定控制。




图1 某暂冲式风洞主体布局及马赫数控制系统示意图
Fig. 1 Schematic diagram of the main layout and Mach number control system of an intermittent wind tunnel

某试验车次中截取的一段流场控制数据随时间变化曲线如图2所示,红色虚线表示模型迎角开始变化的时刻。





图2 某试验车次中某段流场控制数据随时间变化曲线
Fig. 2 Time-varying curves of flow field control data from a certain test run

由于气源压力随试验进程不断降低(图2(a)),阀门开度随之逐渐增加(图2(b))。当模型迎角开始变化后,由于试验段阻塞度的增加,马赫数随之下降(图2(b)),此时需增大阀门开度以使马赫数恢复到目标值附近,然而,从图2(b)可以看出:阀门开度的调节滞后于马赫数的下降,难以及时对迎角扰动进行补偿,导致马赫数出现明显波动,且波动幅度随模型迎角的增大而加剧,最大波动值达0.018。由于模型迎角与阀门开度对马赫数的扰动均呈现明显的时滞特性,使用PID控制策略无法提前对阀门开度进行补偿以使马赫数稳定,只能在马赫数发生较大波动后输出相应控制增量,因此,单纯依赖PID控制应对模型迎角变化引起的马赫数扰动效果不理想。

2 基于LSTM的马赫数建模方法

2.1 建模原理

马赫数控制建模问题属于典型的时间序列预测问题,其核心难点在于系统输入(阀门开度、气源压力、模型迎角等)对输出(马赫数)的影响存在显著的时滞性与非线性特征。LSTM是一种特殊的循环神经网络(Recurrent Neural Network, RNN),在处理时间序列预测方面具有独特优势,LSTM凭借其独特的门控机制,能够有选择地记忆和传递历史状态信息,更重要的是,LSTM本质上是一种非线性循环神经网络,通过多层神经元的非线性激活与状态传递,具有逼近任何复杂非线性系统动态过程的能力^[24-25]。为此,本文采用LSTM对马赫数控制系统进行建模,以下对LSTM的原理进行简要介绍^[25]。

LSTM网络由输入层、隐藏层和输出层构成,网络结构示意如图3所示, x_i 为 i 时刻的输入值, c_i 为 i 时刻的记忆值, h_i 为 i 时刻的输出值。隐藏层是由循环连接的隐藏神经单元组成,每个神经单元包含3个门:输出门 σ_o 、输入门 σ_i 和遗忘门 σ_f 。

遗忘门决定上一次记忆 c_{i-1} 有多少可以保留到这次的记忆 c_i 中, i 时刻遗忘门的激活值 f_i 可表示为

$$f_i = \sigma(W_{xf}x_i + W_{hf}h_{i-1} + W_{cf}c_{i-1} + b_{sf}) \quad (1)$$

式中: $\sigma(x) = \frac{1}{1 + e^{-x}}$ 为sigmoid激活函数,可将输入映射至区间 $(0, 1)$; W 与 b 为权重与偏置。输出门用于调控历史记忆向当前输出传递的比例,即

确定当前输出应融合多少历史信息。 i 时刻输出门的激活值 o_i 可表示为

$$o_i = \sigma(W_{xo}x_i + W_{ho}h_{i-1} + W_{co}c_{i-1} + b_o) \quad (2)$$




图3 LSTM原理示意图

Fig. 3 Schematic diagram of LSTM principle

输入门通过对当前输入的状态评估,动态调整其存入记忆单元的权重,从而实现对信息写入的精准控制。 i 时刻输入门的激活值 s_i 可表示为

$$s_i = \sigma(W_{xs}x_i + W_{hs}h_{i-1} + W_{cs}c_{i-1} + b_s) \quad (3)$$

i 时刻的记忆值 c_i 与输出值 h_i 分别由下式更新:

$$c_i = f_i c_{i-1} + s_i \cdot \tanh(W_{xc}x_i + W_{hc}h_{i-1} + b_c) \quad (4)$$

$$h_i = o_i \cdot \tanh(c_i) \quad (5)$$

2.2 建模方法

基于LSTM,建立马赫数预测模型神经网络,如图4所示,包括输入层、LSTM层、输出层。假设当前时间步为 t_i ,输入层的数据包括:1)过去20个时间步(相邻时间步间隔为0.1 s)的模型迎角值 $\alpha(t_{i-20}), \alpha(t_{i-19}), \dots, \alpha(t_{i-1})$;2)过去20个时间步的气源压力值 $ps(t_{i-20}), ps(t_{i-19}), \dots, ps(t_{i-1})$;3)过去20个时间步的阀门开度值 $L(t_{i-20}), L(t_{i-19}), \dots, L(t_{i-1})$;4)过去20个时间步的马赫数 $Ma(t_{i-20}), Ma(t_{i-19}), \dots, Ma(t_{i-1})$ 。LSTM层有 m 个神经元,与输入、输出层通过全连接的方式连接,每个神经元内有20个隐藏单元,每个LSTM神经元内运算后仅保留最后一个隐藏单元的输出值。输出层为当前时刻马赫数的输出值 $Ma(t_i)$ 。值得注意的是,本文建立的神经网络拟用于马赫数的动态控制,模型的计算时间应尽量缩短以跟随控制速度,因此在保证模型预测精度的同时,应尽可能简化神经网络模型,基于上述考虑构建了如图4所示的单隐藏层的神经网络。




图4 马赫数预测模型网络示意图

Fig. 4 Schematic diagram of the Mach number prediction model network

由于不同试验模型的结构布局、阻塞度等均存在差异,会对输入与输出(马赫数)之间的映射关系造成影响,故使用同一试验模型的试验数据训练神经网络。利用历史试验车次的流场控制数据,按图4所示的输入与输出形式生成训练样本,对神经网络进行训练。此外,不同目标马赫数对应的气源压力、阀门开度范围及流动机理均有所不同,故针对各目标马赫数分别建立预测模型,以提高建模精度。 $Ma_{obj}=1.2$ 情况下,不同LSTM层数 m 对马赫数预测结果的影响如图5所示,采用预

测值与实际值之间的均方根误差(RMSE)作为精度评价指标,结果表明, $m=256$ 与 $m=512$ 时的预测精度无明显差异,但显著高于 $m=128$ 时的预测精度,综合考虑模型复杂度与预测性能,本文选择 $m=256$ 进行建模。

作为典型案例,本文以某试验模型为对象开展流场控制建模研究,该试验模型在试验过程中采用步进迎角的方式进行逐点测量。分别在 $Ma_{obj}=1.2, 0.95, 0.8$ 三种目标马赫数条件下训练神经网络,所用训练数据点数分别为3 442、2 969、

3 181,数据涵盖的气源压力、模型迎角及阀门开度范围基本覆盖了试验中可能出现的工况。基于上述数据,获得3个马赫数预测模型,分别用于 $Ma_{obj}=1.2$ 、0.95、0.8情况下的马赫数预测,训练及测试结果如表1~表3所示,可以看出:所有工况下马赫数预测精度均达到 $R^2>0.98$,RMSE在 10^{-3} 量级。

典型试验车次中马赫数预测值随时间的变化曲线如图6所示,可以看出:预测值与实际值基本吻合。上述结果表明,采用图4所示的神经网络结构对马赫数进行预测具有良好的效果,预测精度能够满足控制需求。

需要指出的是,本文所建立的LSTM预测模型是针对特定试验模型训练的。若更换试验模型,由于模型外形、阻塞度及气动特性的差异,原有模型不再适用。此时,只需采集新模型在目标

马赫数下的若干车次历史试验数据(通常3~4个车次),按图4所示的输入输出形式重新训练LSTM网络,即可获得适配新模型的预测模型。该重训练过程可在离线完成,计算成本较低,具有良好的工程可迁移性。




图5 LSTM神经元数量对预测精度的影响($Ma_{obj}=1.2$)

Fig. 5 Effect of the number of LSTM neurons on Mach number prediction results (under the condition of $Ma_{obj}=1.2$)

表1 目标马赫数 $Ma_{obj}=1.2$ 时的模型预测结果

Table 1 Model prediction results at target $Ma_{obj}=1.2$

	试验车次 编号	p_s 范围/MPa	α 范围/(°)	L 范围/mm	Ma 预测误差/ (RMSE $\times 10^{-3}$)	Ma 预测误差/ R^2
训练集	1	1.23 ~ 1.44	-5 ~ 20	199 ~ 223	1.20	0.996
	2	1.76 ~ 2.01	-5 ~ 20	163 ~ 184	1.26	0.994
	3	1.36 ~ 1.57	-5 ~ 20	192 ~ 214	1.14	0.996
	4	0.793 ~ 1.02	-5 ~ 20	239 ~ 278	1.33	0.992
	5	1.00 ~ 1.33	0 ~ 18	231 ~ 245	1.38	0.996
测试集	6	0.982 ~ 1.24	-5 ~ 20	218 ~ 250	1.03	0.996
	7	1.03 ~ 1.25	-5 ~ 20	218 ~ 247	1.20	0.993
	8	1.35 ~ 1.60	-5 ~ 20	189 ~ 212	1.12	0.995
	9	1.22 ~ 1.45	-5 ~ 20	201 ~ 224	1.35	0.994
	10	1.24 ~ 1.47	-5 ~ 20	200 ~ 224	1.16	0.996
	11	1.39 ~ 1.61	-5 ~ 20	188 ~ 210	1.17	0.997


表2 目标马赫数 $Ma_{obj}=0.95$ 时的模型预测结果

Table 2 Model prediction results at target $Ma_{obj}=0.95$


	试验车次 编号	p_s 范围(MPa)	α 范围(°)	L 范围(mm)	Ma 预测误差 (RMSE $\times 10^{-3}$)	Ma 预测误差 (R^2)
训练集	12	0.966 ~ 1.17	-5 ~ 20	205 ~ 233	1.39	0.994
	13	1.38 ~ 1.56	-5 ~ 20	168 ~ 193	1.33	0.989
	14	1.01 ~ 1.19	-5 ~ 20	211 ~ 228	1.36	0.995
	15	0.768 ~ 0.933	-5 ~ 20	224 ~ 261	1.32	0.993
测试集	16	0.871 ~ 1.06	-5 ~ 20	223 ~ 247	1.54	0.987
	17	1.08 ~ 1.29	-5 ~ 20	201 ~ 221	1.39	0.992
	18	1.21 ~ 1.40	-5 ~ 20	190 ~ 207	1.69	0.981
	19	1.04 ~ 1.23	-5 ~ 20	206 ~ 224	1.72	0.989
	20	1.14 ~ 1.33	-5 ~ 20	198 ~ 214	1.70	0.992

表3 目标马赫数 $Ma_{obj} = 0.8$ 时的模型预测结果
Table 3 Model prediction results at target $Ma_{obj} = 0.8$


	试验车次 编号	p_s 范围 (MPa)	α 范围 ($^{\circ}$)	L 范围 (mm)	Ma 预测误差 (RMSE $\times 10^{-3}$)	Ma 预测误差 (R^2)
训练集	21	1.29 ~ 1.47	-5 ~ 20	175 ~ 189	1.54	0.990
	22	1.27 ~ 1.44	-5 ~ 20	171 ~ 192	1.56	0.993
	23	0.866 ~ 1.03	-5 ~ 20	217 ~ 237	1.74	0.995
	24	0.734 ~ 0.889	-5 ~ 20	226 ~ 256	1.70	0.993
测试集	25	0.763 ~ 0.928	-5 ~ 20	215 ~ 251	1.98	0.985
	26	0.812 ~ 1.02	-5 ~ 20	211 ~ 244	2.25	0.988
	27	0.702 ~ 0.873	-5 ~ 20	224 ~ 261	2.20	0.983
	28	1.33 ~ 1.52	6 ~ 12	171 ~ 185	1.98	0.984
	29	1.08 ~ 1.25	-5 ~ 20	196 ~ 209	2.31	0.983
	30	1.07 ~ 1.23	-5 ~ 20	197 ~ 211	2.12	0.984
	31	1.13 ~ 1.27	-5 ~ 20	192 ~ 205	2.11	0.991



(a) $Ma_{obj} = 1.2$, 试验车次 7



(b) $Ma_{obj} = 0.95$, 试验车次 17



(c) $Ma_{obj} = 0.8$, 试验车次 26

图6 模型预测结果与实际值的比较:

Fig. 6 Comparison of Ma between model prediction results and actual values

3 基于 LSTM 的马赫数智能控制方法

3.1 小扰动最优化动态补偿控制方法

基于马赫数预测模型(图4),提出小扰动最优化控制方法进行马赫数控制,其控制思想是:在每个时间步对阀门开度进行局部扰动寻优,利用训练好的模型预测下一时间步的马赫数输出,使其逼近目标值。控制逻辑框图如图7所示,主要包括以下步骤:

1) 在当前时刻 t_i , 基于历史数据预测 t_{i+1} 时刻的马赫数输出值 $Ma(t_{i+1})$ 。

2) 计算马赫数与目标值的差值 $e = Ma(t_{i+1}) - Ma_{obj}$, 及马赫数变化率 $\Delta Ma = Ma(t_{i+1}) - Ma(t_i)$ 。

3) 根据 e 与 ΔMa 判断如何施加阀门增量。若 e 很大 ($|e| > \theta$), 则直接施加正方向或负方向的阀门增量 dL ; 若 e 较小 ($|e| < \theta$), 则根据马赫数的变化方向判断是否进行控制: ① 若 $e > 0$ 且 $Ma(t_{i+1}) > 0$, 即马赫数大于目标值且仍在增大, 施加负方向的阀门增量 dL ; ② 若 $e < 0$ 且 $Ma(t_{i+1}) < 0$, 即马赫数小于目标值且仍在减小, 施加正方向的阀门增量 dL ; ③ 其他情况, 不进行控制, 即阀门增量为 0。

4) 根据累积的阀门增量 $\Delta L = \sum dL$ 更新 $Ma(t_{i+1})$ 。

5) 重复步骤(2)~步骤(4) N 次, 将最终的 ΔL 输出给控制器, 作为 t_i 时刻的阀门控制增量。




图7 小扰动最优化控制方法逻辑框图

Fig. 7 Logical diagram of the small perturbation optimization control method

控制参数按照如下原则选取: 阈值 θ 依据马赫数控制精度要求 (通常期望波动小于 ± 0.005) 及传感器测量噪声水平设定, 本文取 $\theta = 0.005$; 单步扰动步长 dL 与阀门作动器的最小控制分辨率与马赫数对阀门开度的敏感度有关, 通过仿真测试确定, 不同目标马赫数下分别取值为 0.04 mm ($Ma = 1.2$)、 0.02 mm ($Ma = 0.95$) 和 0.015 mm ($Ma = 0.8$); 最大扰动步数 N 应兼顾控制精度与计算效率, 本文取 $N = 4$ 可使寻优范围 ($\pm 4 dL$) 覆盖典型扰动所需的补偿量, 且穷举计算时间控制在可接受范围内。

上述控制方法可形式化为如下优化问题, 在当前时刻 t_i , 定义系统的状态向量 $s(t_i)$ 为过去 20 个时间步内各变量的序列: $\alpha(t_i) = [\alpha(t_{i-19}), \alpha(t_{i-18}), \dots, \alpha(t_i)]$; $ps(t_i) = [ps(t_{i-19}), ps(t_{i-18}), \dots, ps(t_i)]$; L

$(t_i) = [L(t_{i-19}), L(t_{i-18}), \dots, L(t_i)]$; $Ma(t_i) = [Ma(t_{i-19}), Ma(t_{i-18}), \dots, Ma(t_i)]$ 。控制输入为阀门开度增量 $\Delta L(t_i)$, 目标是使下一时间步的马赫数 $Ma(t_{i+1})$ 尽可能接近 Ma_{obj} 。据此, 可定义如下离散优化问题:

$$\min_{\Delta L \in U} |Ma(t_{i+1}|s(t_i), \Delta L) - Ma_{obj}|^2 \quad (6)$$

式中: $U = \{-N \cdot dL, -(N-1) \cdot dL, \dots, 0, \dots, N \cdot dL\}$ 为离散控制变量集合; N 为单次寻优的最大扰动步数。本文按图 7 所示逻辑对 U 中的部分元素进行穷举搜索, 以平衡计算效率与控制精度。该方法属于模型预测控制 (Model Predictive Control, MPC) 的一种简化形式, 其控制量集合离散且有限, 每个时间步仅执行一步向前预测, 并选择使下一时刻预测误差最小的控制量, 其本质上是一种贪婪算法。

关于收敛性, 在 LSTM 模型具有足够高预测精度 (本文所有工况下 $R^2 > 0.98$) 且实际风洞控制系统满足局部 Lipschitz 连续性的前提下, 上述贪婪策略能够使马赫数的控制误差最终进入一个与步长 dL 及阈值 θ 相关的有界邻域内。3.2 与 3.3 节中的仿真结果表明, 该方法在典型工况下具有良好的收敛表现和鲁棒性。

关于控制的实时性问题, 在本文的 Matlab 仿真环境下 (计算机配置: Intel Core i7-10700 CPU、16 GB 内存、NVIDIA GeForce GTX 970 显卡), 当单次寻优最大扰动步数 $N = 4$ 时, 单次控制计算耗时约为 30~40 ms。考虑第 1 节所述风洞控制系统中硬件通讯与软件控制等环节带来的 5~10 ms 延迟, 总控制延迟约为 35~50 ms。该风洞系统的控制周期为 100 ms (对应采样频率 10 Hz), 实际控制延迟小于控制周期, 表明算法具有充足的时间裕度。

3.2 控制仿真

基于 3.1 节所述的小扰动最优化控制方法, 进行控制仿真。仿真流程的逻辑框图如图 8 所示, 在 t_i 时刻利用智能控制器 (即小扰动最优化控制方法), 输出当前时刻所需的阀门开度控制增量 $\Delta L(t_i)$, 并利用马赫数预测模型代替实际的风洞控制系统, 预测下一时刻的马赫数 $Ma(t_{i+1})$, 并更新历史数据, 如此循环往复, 完成所有时刻的控制仿真。




图8 智能控制仿真逻辑图

Fig. 8 Logical diagram of the intelligent control simulation progress

选取2.2节所述试验模型的某些典型试验车次进行控制仿真： $Ma_{obj}=1.2$ 情况下的试验车次6； $Ma_{obj}=0.95$ 情况下的试验车次16； $Ma_{obj}=0.8$ 情况下的试验车次24，试验车次编号对应工况如表1~表3所示，各试验车次所使用的智能控制器参数值如表4所示。


表4 各仿真车次智能控制器参数设置
Table 4 Parameter sets of the intelligent controller for each simulation test

试验车次编号	Ma_{obj}	θ	dL/mm	N
6	1.2	0.005	0.04	4
16	0.95	0.005	0.02	4
25	0.8	0.005	0.015	4


控制仿真结果如图9~图11所示，智能控制在 $t=2\text{ s}$ 时刻开始运行，并与原PID控制结果进行比较。用于对比的原PID控制参数由现场试验工程师依据临界比例度法初定，并结合多年风洞运行经验手动微调至最佳状态，已在大量吹风试验中验证为当前控制系统的最优整定结果。

结果表明，相比于原PID控制，智能控制能够使马赫数迅速稳定在目标值附近（图9(b)、图10(b)、图11(b)），从图9(c)、图10(c)、图11(c)可以看出：当模型迎角发生变化时，使用智能控制能够使阀门提前动作，实现对迎角扰动所引起马赫数波动的有效补偿，相比较而言，PID控制方法的阀门开度变化存在明显滞后，无法有效抑制马赫数的波动。在图9~图11所示的控制仿真中，采用智能控制后，马赫数的RMS值分别降低了76%、82%和51%，马赫数波动幅度显著减小。马赫数RMS值的大幅降低主要源于对比基准—原PID控


制策略在处理模型迎角快速变化时具有局限性，PID控制本质上依赖误差反馈，其控制参数固定且响应滞后，难以对迎角变化引起的阻塞度突变进行及时补偿，控制能力相对有限。相比之下，本文提出的LSTM智能控制方法通过时序建模，能够提前预测迎角等扰动的变化趋势并输出超前控制量，实现了从被动反馈到主动预测的转变，因此取得了显著优于PID的控制效果。不同目标马赫数下RMS降低幅度存在差异（76%、82%、51%），这与各工况下PID基准控制能力的差异密切相关，其中 $Ma_{obj}=0.95$ 的工况最接近声速，模型迎角变化引起的阻塞效应最为剧烈，PID控制效果最差、基准RMS最高，因此智能控制的改善幅度最大。上述结果验证了本文所提控制方法的有效性。



(a) 迎角



(b) 马赫数



(c) 阀门开度

图9 智能控制与原PID控制结果的比较
($Ma_{obj}=1.2$, 试验车次6)

Fig. 9 Comparison of the control effect between intelligent control and original PID control ($Ma_{obj}=1.2$, test No. 6)






图10 智能控制与原PID控制结果的比较
($Ma_{obj}=0.95$, 试验车次16)

Fig. 10 Comparison of the control effect between intelligent control and original PID control
($Ma_{obj}=0.95$, test No. 16)






图11 智能控制与原PID控制结果的比较
($Ma_{obj}=0.8$, 试验车次24)

Fig. 11 Comparison of the control effect between intelligent control and original PID control
($Ma_{obj}=0.8$, test No. 24)

3.3 预测模型误差对控制效果的影响分析

在实际风洞控制系统中,基于LSTM的马赫数预测模型不可避免地存在一定误差。为评估该误差对本文所提智能控制方法在真实风洞系统中控制效果的影响,在闭环仿真中引入额外的马赫数输出扰动,用以模拟模型预测误差。具体做法为:在每个时间步,对LSTM模型输出的马赫数预测值 $Ma(t_{i+1})$ 叠加一个随机扰动 ϵ ,即实际用于控制计算的马赫数为 $Ma_{act}(t_{i+1})=Ma(t_{i+1})+\epsilon$ 。假设马赫数模型预测误差 ϵ 的概率密度分布满足均值为0的截断高斯分布,即:


$$f(\epsilon) = \frac{1}{\sigma} \cdot \frac{\varphi\left(\frac{\epsilon}{\sigma}\right)}{\Phi\left(\frac{b}{\sigma}\right) - \Phi\left(\frac{a}{\sigma}\right)} \quad (a < \epsilon < b) \quad (7)$$

式中: φ 为标准正态分布的概率密度函数; Φ 为标准正态分布的累积分布函数; σ 为标准差; a 与 b 分别为截断下限与截断上限。标准差 σ 根据表1~表3中测试集 RMSE 的均值确定: $Ma_{obj}=1.2$ 时, $\sigma_e=0.0012$; $Ma_{obj}=0.95$ 时, $\sigma_e=0.0016$; $Ma_{obj}=0.8$ 时, $\sigma_e=0.0021$ 。该取值反映了LSTM模型在不同


目标马赫数下的实际预测误差量级。

为使模拟误差尽可能贴近真实风洞控制系统的动态特性,以避免完全随机的误差扰动可能带来的非物理行为,截断上下限的设定与当前时刻的阀门开度变化方向及马赫数变化率相关联。具体规则如下:若当前时刻 t_i 阀门开度增量为正($\Delta L(t_i) > 0$),表明控制器试图增大阀门以提升马赫数,此时,误差的截断下限 a 设为马赫数二阶差分的相反数 $\Delta^2 Ma(t_i) = [Ma(t_i) - Ma(t_{i-1})] - [Ma(t_{i+1}) - Ma(t_i)]$,截断上限 $b = 0.01$,这一设置考虑了当阀门正向动作时,模型误差不太可能使马赫数过度低于预期。同理,若当前时刻阀门开度增量为负($\Delta L(t_i) < 0$),表明控制器试图减小阀门以降低马赫数。此时,截断下限 $a = -0.01$,截断上限 b 设置为马赫数的二阶差分 $\Delta^2 Ma(t_i)$,即当阀门负向动作时,误差不太可能使马赫数过度高于预期。上述截断规则确保了所注入的扰动与系统当前的变化趋势相一致。


基于上述误差引入规则,重新进行3.2节中的控制仿真,结果如图12所示。



(a) $Ma_{obj} = 1.2$, 试验车次 6



(b) $Ma_{obj} = 0.95$, 试验车次 16



(c) $Ma_{obj} = 0.8$, 试验车次 24

图12 加入扰动后的智能控制、无扰动智能控制与原PID控制结果比较

Fig. 12 Comparison of results among intelligent control with disturbance, intelligent control without disturbance, and original PID control

从图12可以看出:尽管马赫数的波动幅度较无误差的理想仿真情况有所增大,但本文方法仍能有效抑制扰动,使马赫数快速收敛至目标值附近。具体而言,相较于原始PID控制,在目标马赫数分别为1.2、0.95和0.8的工况下,马赫数RMS值仍分别降低了61%、56%和42%。这表明,即使LSTM模型存在一定程度的预测偏差,本文所提出的智能控制方法依然能够保持优于传统PID的控制品质,具有较强的鲁棒性。

4 结 论

1) 采用同一试验模型的历史数据训练LSTM网络,以过去20个时间步的扰动信息(包括气源压力、模型迎角、阀门开度、马赫数)为输入,预测当前时刻的试验段马赫数,预测精度达 $R^2 > 0.98$,验证了LSTM在暂冲式风洞中对马赫数时序特征的有效捕获能力。

2) 基于所建LSTM马赫数预测模型,提出小扰动最优化智能控制方法。该方法在每个时间步对阀门开度进行局部扰动寻优,利用模型预测下一时刻的马赫数响应,使输出值逐步逼近目标值。仿真结果表明:在理想情况下,目标马赫数为1.2、0.95和0.8时马赫数RMS分别降低76%、82%和51%,系统抗扰动能力显著增强;即使在引入LSTM模型预测误差后,RMS仍分别降低61%、56%和42%,表明该方法具有良好的鲁棒性。

需要指出的是,本文所提智能控制方法目前

仅在基于真实历史数据训练的LSTM模型上进行了闭环仿真验证,尚未在真实风洞环境中部署测试。这主要是由于当前暂冲式风洞试验资源有限,且控制算法与现有控制系统的集成尚需时间。值得注意的是,本文所使用的LSTM马赫数预测模型在多个独立测试车次上均取得了 $R^2>0.98$ 的预测精度,表明该模型对系统动态特性的复现能力已通过大量真实试验数据验证,因此基于该模型的仿真结果具有较高的可信度。尽管如此,真实风洞试验仍是确认方法实际有效性的必要环节,后续将在条件具备时开展真实风洞试验,进一步验证本文方法的实际控制效果。此外,真实风洞阀门作动器存在物理惯性及死区特性,会导致算法输出的理想控制量难以精确执行,是后续部署该算法的重要挑战之一,后续拟在阀门端引入内环PID控制,以实现阀门开度的快速、准确定位。

参考文献

- [1] Anderson J D. Fundamentals of aerodynamics[M]. 5th ed. New York: McGraw-Hill Higher Education, 2011.
- [2] 王晓军. 基于大数据的风洞马赫数集成建模方法的研究[D]. 沈阳: 东北大学, 2016.
Wang Xiaojun. The research of ensemble methods based on big data for the Mach number prediction in wind tunnel[D]. Shenyang: Northeastern University, 2016. (in Chinese)
- [3] 袁平, 易凡, 肖宇航, 等. 面向攻角变化的风洞流场模型预测控制器[J]. 控制与决策, 2018, 33(6): 1026-1032.
Yuan Ping, Yi Fan, Xiao Yuhang, et al. Orienting of attack angle based model prediction controller of wind tunnel flow[J]. Control and Decision, 2018, 33(6): 1026-1032. (in Chinese)
- [4] 易凡, 李欣蕊, 杜宁, 等. 基于迭代学习的风洞马赫数控制方法[J]. 控制工程, 2020, 27(1): 109-113.
Yi Fan, Li Xinrui, Du Ning, et al. Iterative learning based control for wind tunnel Mach number[J]. Control Engineering of China, 2020, 27(1): 109-113. (in Chinese)
- [5] 朱天成. 连续变姿态角工况下风洞马赫数的控制方法研究[D]. 沈阳: 东北大学, 2021.
Zhu Tiancheng. Research on control method of Mach number in wind tunnel with continuous variable attitude angle[D]. Shenyang: Northeastern University, 2021. (in Chinese)
- [6] 刘为杰, 凌忠伟, 田嘉懿, 等. 2 m高速自由射流风洞流场前馈-反馈复合控制方法研究与应用[J]. 西北工业大学学报, 2025, 43(3): 574-581.
Liu Weijie, Ling Zhongwei, Tian Jiayi, et al. Feedforward-feedback compound control method and application for flow field in 2 meter high-speed free jet wind tunnel[J]. Journal of Northwestern Polytechnical University, 2025, 43(3): 574-581. (in Chinese)
- [7] 刘为杰, 凌忠伟, 邓晓曼, 等. 风洞流场抗时变干扰控制研究[J]. 实验流体力学, 2025, 39(5): 53-59.
Liu Weijie, Ling Zhongwei, Deng Xiaoman, et al. Research on anti time-varying disturbance control of wind tunnel flow field[J]. Journal of Experiments in Fluid Mechanics, 2025, 39(5): 53-59. (in Chinese)
- [8] 张廷丰. 大型跨声速风洞建模与控制方法研究[D]. 沈阳: 东北大学, 2019.
Zhang Tingfeng. Research on modeling and control methods for large transonic wind tunnel[D]. Shenyang: Northeastern University, 2019. (in Chinese)
- [9] Yu W S, Du N, Rao Z Z, et al. Perturbation analysis and control of Mach number 2.4-meter transonic wind tunnel[J]. Journal of Aircraft, 2020, 57(6): 1148-1155.
- [10] 金志伟, 杜宁, 邢盼, 等. 基于前馈-模糊PID策略的风洞控制器应用[J]. 兵工自动化, 2024, 43(7): 48-51.
Jin Zhiwei, Du Ning, Xing Pan, et al. Application of wind tunnel controller based on feedforward-fuzzy PID strategy[J]. Ordnance Industry Automation, 2024, 43(7): 48-51. (in Chinese)
- [11] 马靖雯, 张廷丰, 陆明超. 基于数据驱动的跨声速风洞控制方法研究[J]. 辽宁工业大学学报(自然科学版), 2024, 44(5): 298-302, 309.
Ma Jingwen, Zhang Tingfeng, Lu Mingchao. Research on data-driven control methods for transonic wind tunnels[J]. Journal of Liaoning University of Technology (Natural Science Edition), 2024, 44(5): 298-302, 309. (in Chinese)
- [12] 陈旦, 王众, 鲁相, 等. 某连续式超声速风洞控制系统设计研究[J]. 西北工业大学学报, 2022, 40(1): 167-174.
Chen Dan, Wang Zhong, Lu Xiang, et al. The control system design and study for continuous supersonic wind tunnel[J]. Journal of Northwestern Polytechnical University, 2022, 40(1): 167-174. (in Chinese)
- [13] 尼文斌, 董金刚, 刘书伟, 等. 自适应遗传PID算法在风洞风速控制中的应用[J]. 实验流体力学, 2015, 29(5): 84-89.
Ni Wenbin, Dong Jingang, Liu Shuwei, et al. Application of PID based on adaptive genetic algorithms in wind velocity control system of wind tunnels[J]. Journal of Experiments in Fluid Mechanics, 2015, 29(5): 84-89. (in Chinese)
- [14] Yu W S, Su B C, Rao Z Z, et al. Genetic algorithm-based

- Mach number control of multi-mode wind tunnel flow fields [J]. *Processes*, 2022, 10(10): 2038.
- [15] 高赫. 基于机器学习的连续式风洞马赫数控制[D]. 南京: 南京航空航天大学, 2020.
- Gao He. Mach number control of continuous wind tunnel based on machine learning[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2020. (in Chinese)
- [16] 王晓军, 袁平, 毛志忠, 等. 基于随机森林的风洞马赫数预测模型[J]. *航空学报*, 2016, 37(5): 1494-1505.
- Wang Xiaojun, Yuan Ping, Mao Zhizhong, et al. Wind tunnel Mach number prediction model based on random forest [J]. *Acta Aeronautica et Astronautica Sinica*, 2016, 37(5): 1494-1505. (in Chinese)
- [17] 王凯文. 神经网络PID控制在FD12风洞亚跨流场校测中的应用[D]. 哈尔滨: 哈尔滨工程大学, 2011.
- Wang Kaiwen. The application of neural network PID control in the test of FD12Supersonic and transonic wind tunnel [D]. Harbin: Harbin Engineering University, 2011. (in Chinese)
- [18] Zhao L P, Wu K Y. Mach number prediction for a wind tunnel based on the CNN-LSTM-attention method[J]. *Instrumentation*, 2023(4): 6-11.
- [19] Yu W S, Su B C, Liu G, et al. Mach number prediction of wind tunnel flow field based on RBFNN and LSTM[C]// 2024 36th Chinese Control and Decision Conference (CCDC). Xi'an, China: IEEE, 2024: 2462-2466.
- [20] Zhao L P, Wang C. Physical information-based Mach number prediction and model migration in continuous wind tunnels[J]. *Aerospace*, 2025, 12(8): 701.
- [21] Liu L, Mao Z Z. Hybrid deep LSTM-GAT network with mechanism information for prediction of Mach number[J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 2514813.
- [22] Sutcliffe P, Rennie M R. Neural network model predictive control of wind tunnel test conditions[C]// 54th AIAA Aerospace Sciences Meeting. San Diego, California, USA: AIAA, 2016: 1150-1162.
- [23] Tian J Y, Ling Z W, Liu W J, et al. Flow field control for 2-meter high-speed free-jet wind tunnel[J]. *Chinese Journal of Aeronautics*, 2023, 36(10): 77-89.
- [24] Yu Y, Si X S, Hu C H, et al. A review of recurrent neural networks: LSTM cells and network architectures[J]. *Neural Computation*, 2019, 31(7): 1235-1270.
- [25] Hochreiter S, Schmidhuber J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.

(编辑:马文静)