

高速磁浮列车悬浮间隙仿真预测

吴 晗^{1,2}, 刘梦娟^{1,2}, 曾晓辉^{1,2}

(1. 中国科学院力学研究所 流固耦合系统力学重点实验室, 北京 100190; 2. 中国科学院大学 工程科学学院, 北京 100049)

摘要: 基于长短时记忆(LSTM)神经网络提出了一种可用于高速磁浮列车的电磁铁悬浮间隙预测方法。考虑高速磁浮列车运行过程中受到的气动荷载,建立了列车仿真模型并计算列车的动态响应;通过PyCharm建立LSTM神经网络,并以高速磁浮列车仿真模型计算结果为样本集,构建了高速磁浮列车电磁铁悬浮间隙预测模型。最后,通过对预测模型计算结果和评价指标进行评判,验证了所提出的电磁铁间隙预测算法的准确性。

关键词: 高速磁浮列车; 长短时记忆(LSTM)神经网络; 数值仿真; 动力响应预测

中图分类号: TH212; TH213. 3

文献标志码: A

Suspension Gap Prediction of High-speed Maglev Train

WU Han^{1,2}, LIU Mengjuan^{1,2}, ZENG Xiaohui^{1,2}

(1. Key Laboratory for Mechanics in Fluid Solid Coupling Systems, Institute of Mechanics of Chinese Academy of Sciences, Beijing 100190, China; 2. School of Engineering Science, University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: An electromagnet suspension gap prediction method was proposed based on long short-term memory (LSTM) neural network for high-speed maglev trains. Firstly, considering the aerodynamic load during the operation of high-speed maglev train, a train simulation model was established and the dynamic response of the train was calculated. Secondly, the LSTM neural network was established by PyCharm and the prediction model of the electromagnet suspension gap for high-speed maglev trains was built by taking the simulation calculation results as the sample set. Finally, the accuracy of the proposed electromagnet suspension gap prediction algorithm was verified by judging the calculation results and evaluation indexes of the prediction model.

Key words: high-speed maglev train; long short-term memory (LSTM) neural network; numerical simulation; dynamic response prediction

磁浮列车克服了传统车辆轮轨接触的约束限制,具有速度快、噪音小、适应能力强以及维修少等特点^[1],近年来受到了广泛关注。磁悬浮有 2 种模式:利用导轨部件中超导和感应电流之间的排斥力,或者利用铁芯电磁铁和导轨之间的电磁力。前者称为电动悬浮(EDS),后者称为电磁悬浮(EMS)。我国目前主要研究 EMS 型磁浮列车,但 EMS 型磁浮列车电磁铁系统自身为开环系统,受到任何微小扰动都会失去稳定性^[2]。因此,需对列车施加控制来实现主动悬浮,从而保证系统的稳定性,满足系统的动态特性要求。

EMS 型磁浮列车通过悬浮控制系统主动调节电磁铁电流来控制轨道与车体之间的电磁吸力,使车体与轨道脱离接触^[3]。目前磁浮列车控制系统仍然采用传统的比例-积分-微分(PID)控制,这种控制方法是基于单电磁铁建立动力学方程,在系统平衡点附近线性展开得到状态方程^[4-5]后再建立控制器,未能反映列车部件间的耦合影响,控制效果有限。随着控制技术的不断进步,出现了许多更为先进的控制算法,如鲁棒控制算法^[6]、模糊控制算法^[7]和滑模控制算法^[8-9]。鲁棒控制、模糊控制和自适应控制等对模型精度要求较高,并且大多只能解决线性系统的控制问题^[10]。然而,磁铁与导轨间的电磁力与悬浮间隙的平方成反比^[11],而且悬浮间隙为 10 mm 左右,车轨间隙很小,存在强非线性,因此传统算法并不能达到非常好的控制效果。

上述控制算法多是在系统响应已经产生后引

收稿日期: 2023-01-01

基金项目: 中国科学院稳定支持基础研究领域青年团队计划(YSBR-045)

第一作者: 吴 晗(1988—),男,高级工程师,工学博士,主要研究方向为结构动力学与控制(高速列车、磁悬浮列车等)、非线性振动与模型预测控制。E-mail: wuhan@imech. ac. cn

通信作者: 刘梦娟(1998—),女,硕士生,主要研究方向为磁浮列车动力学与控制。E-mail: liumengjuan@imech. ac. cn



论文
拓展
介绍

入,存在一定的“滞后性”,为了增强磁浮系统的稳定性,许多学者开始在控制系统中引入系统响应的预测值。张小庆^[12]通过磁浮列车悬浮系统的线性状态空间离散模型建立预测模型来预估系统未来的状态量,并建立了一种用于混合多磁铁磁浮列车悬浮系统的预测控制方法。Li^[13]基于磁浮列车直线同步电机的离散数学模型构建了转速预测模型,提出了一种针对电机速度控制的模型预测控制方法,从而有效地提高了系统的动态特性和稳态精度。Wang等^[14]为了增强柔性轨道作用下控制系统的稳定性,利用滤波器采样得到的系统状态对未来时刻的悬浮状态进行预测,但是该方法无法实现滚动预测。张振霖^[15]基于模型预测控制方法设计磁浮列车悬浮系统的无约束预测控制器,但模型中的预测方法仍是基于直接解耦的磁浮系统线性时不变状态方程建立的。综上所述,传统的基于状态方程的预测方法很难实现非线性系统的准确滚动预测。近年来,神经网络(NN)因其具有很强的非线性输入输出映射关系以及可以充分逼近任意复杂的非线性关系的特点,被陆续应用于各个领域^[16-19]。

考虑到磁浮系统的强非线性及强耦合性,提出了一种可以预测磁浮列车系统未来响应的神经网络算法。对于实际列车和列车仿真模型而言,动力响应预测算法的建立方法相同,为了方便分析,利用磁浮列车仿真模型构建预测算法。本研究所提出的预测方法共包含列车运行仿真和神经网络预测2个步骤:基于列车动力学建立列车仿真模型,随后施加气动荷载,计算列车运行时的动力响应;建立神经网络模型,将仿真模型计算得到的车辆响应作为样本数据进行训练,根据已经测得的一段时间范围内的悬浮间隙、电磁铁电流以及荷载对未来时刻的悬浮间隙进行预测。考虑列车动力响应中时间维度的影响,以长短时记忆(LSTM)神经网络为核心,提出了一种基于人工智能(AI)的悬浮间隙滚动预测算法,并通过仿真模型计算结果验证了该算法预测的准确性。

1 LSTM神经网络的基本结构

1.1 神经网络模型

神经网络结构如图1所示。神经网络由大量神经元及其之间的相互连接(也就是权值)构成,主要包括输入层、隐藏层和输出层。

人工神经网络的基本单元为人工神经元,它是




图1 神经网络结构

Fig.1 Architecture of neural network

一个单输出多输入的非线性元件,其结构如图2所示。




图2 非线性神经元结构

Fig.2 Structure of nonlinear neuron

神经元由输入、权值、激活函数和输出组成。神经元输出与输入之间的关系如下所示:

$$\begin{cases} f_i = f(a_i + b_i) \\ a_i = \sum_{j=1}^m w_{ij} x_j \end{cases} \quad (1)$$

式中: $x_i (i=1, 2, \dots, n)$ 为输入信号; $w_{ij} (j=1, 2, \dots, m)$ 为输入与第*i*个神经元之间的连接权值; a_i 为神经元输入信号的线性组合; b_i 为神经元*i*的阈值; $f(\cdot)$ 为非线性激活函数; f_i 为神经网络输出结果。

在进行列车动力响应预测模型训练时,神经网络通过正向传播计算得到动力响应预测值,并通过计算预测值与真实值之间的误差得到损失函数。损失函数表达式如下所示:

$$l_{\text{loss}} = \frac{1}{2n} \sum_{i=1}^n (f_i - y_i)^2 \quad (2)$$

式中: y_i 为真实结果(期望结果)。

神经网络训练的目的就是使预测值逐渐逼近期望值,也就是使损失函数达到较小值。由方程(1)、(2)可得

$$l_{\text{loss}} = \frac{1}{2n} \sum_{i=1}^n \left(f \left(\sum_{j=1}^m w_{ij} x_j + b_i \right) - y_i \right)^2 \quad (3)$$

实际上影响损失函数的只有权重 w_{ij} 和阈值 b_i ,

对神经网络进行训练的目的就是为每个神经元找到较合适的权重和阈值,从而使得整个神经网络的输出最接近期望值。

1.2 LSTM神经网络

磁浮列车动力响应属于时间序列问题,需采用考虑时间维度的循环神经元(RNN),但是RNN不能处理时间过长的时间序列。由此,LSTM神经元应运而生。LSTM神经网络是一种改进后的RNN神经网络,将隐藏层的RNN细胞替换为LSTM细胞,使其具有长期记忆能力,可以解决较长时间序列带来的梯度消失或梯度爆炸问题,因此利用LSTM神经网络来构建预测模型。与传统神经网络向前传递不同,LSTM神经网络通过输入门、遗忘门、输出门和细胞状态更新向前传播,流程如图3所示。

设网络中的输入值 $x^{(t)}$ 的维度为 $L \times 1$,与投入网络中的已知信息的数目有关。隐藏层输出 $h^{(t)}$ 的维度为 $1 \times h$,与网络隐藏层中的细胞个数有关。

(1) 遗忘门输出:将储存的历史信息遗忘多少,决定有多少历史信息参与此时计算。

$$f^{(t)} = \sigma(W_{fh}h^{(t-1)} + W_{fx}x^{(t)} + b_f) \quad (4)$$

(2) 输入门:决定放什么此时的新信息(输入值)参与计算。

$$i^{(t)} = \sigma(W_{ih}h^{(t-1)} + W_{ix}x^{(t)} + b_i) \quad (5)$$

$$z^{(t)} = \tanh(W_{zh}h^{(t-1)} + W_{zx}x^{(t)} + b_z) \quad (6)$$

经过前2个门之后,可以确定历史信息的删除和新信息的增加,然后进行细胞状态的更新。

(3) 细胞状态更新

$$C^{(t)} = f^{(t)}C^{(t-1)} + i^{(t)}z^{(t)} \quad (7)$$

(4) 输出门

$$o^{(t)} = \sigma(W_{oh}h^{(t-1)} + W_{ox}x^{(t)} + b_o) \quad (8)$$

$$h^{(t)} = o^{(t)} \tanh(C^{(t)}) \quad (9)$$

式(4)~(9)中: $f^{(t)}$ 为遗忘门的输出值; $i^{(t)}$ 和 $z^{(t)}$ 为输入门的输出值; $C^{(t)}$ 为 t 时刻的细胞状态; $o^{(t)}$ 为输出门的输出值; $x^{(t)}$ 为 t 时刻的输入值; $h^{(t-1)}$ 为 t 时刻的输出当前值; σ 为sigmoid函数,其表达式为 $1/(1 + e^{-x})$ (输出值为0到1之间,0代表完全遗忘); W_{kh} 和 W_{kx} ($k=f, i, z, o$)为线性关系的系数,也就是权重系数, W_{kh} 的维度为 $h \times h$, W_{kx} 的维度为 $L \times h$; b_k ($k=f, i, z, o$)为系统的阈值,维度为 $1 \times h$ 。输出门可以将“新的细胞状态”传递到下一个时间步的计算中。

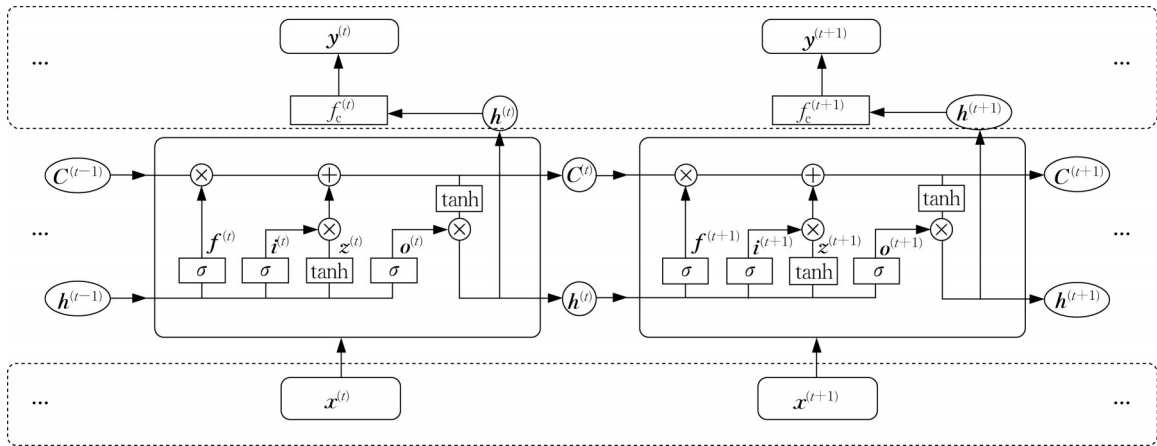


图3 LSTM神经网络

Fig.3 LSTM neural network

(5) 输出预测值

$$y^{(t)} = f_c(h^{(t)}) \quad (10)$$

式中: $y^{(t)}$ 为预测输出值; $f_c(\cdot)$ 为激活函数。

2 基于LSTM神经网络的预测模型

2.1 高速磁浮列车仿真模型

依据上海TR08单节列车物理模型建立仿真模型,然后组成3节编组的动力学仿真模型,建立的仿真模型如图4所示。

对列车进行分散控制,这样就可以通过设计单电磁铁悬浮控制系统来达到完成整车控制系统设计的目的,使控制系统更加简化。基于PID控制技术的单路悬浮控制方案如图5所示。

利用悬浮间隙测量值与额定值误差的比例、积分以及微分(用加速度积分代替)合成控制量,调节列车运行时的磁浮力,从而控制列车稳定悬浮。图5中, a 为电磁铁加速度, z 为电磁铁悬浮间隙, z_0 为电磁铁悬浮间隙额定值, K_p 、 K_i 、 K_d 分别为比例、积分以及微分系数, $F(I, z)$ 为电磁力, I 为期望控制量。




图4 TR08 3节组列车动力学模型

Fig.4 Dynamic model of TR08 maglev train with three-car formation

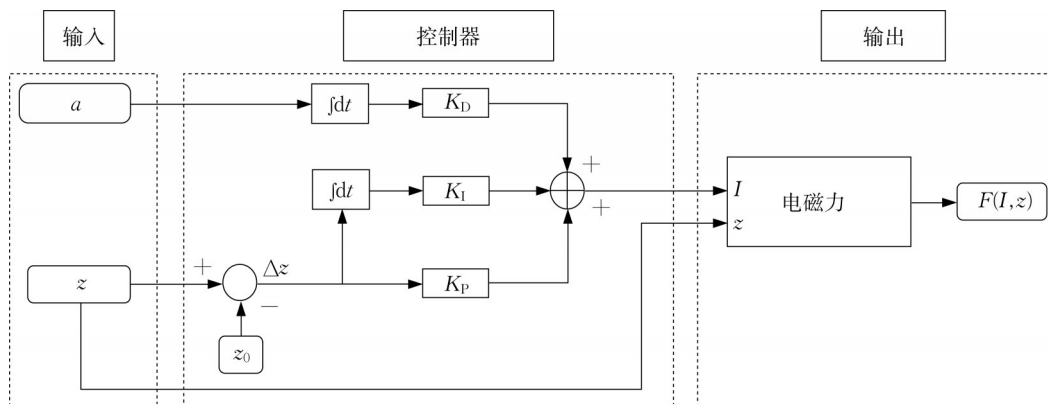


图5 PID 悬浮控制系统模型

Fig.5 PID suspension control system model

模型中,车辆两侧均布置电磁铁,电磁铁分布如图6所示。

将列车以 $500 \text{ km} \cdot \text{h}^{-1}$ 速度运行的气动力和气动力

矩施加于动力学模型车体质心,如图7所示,开展磁浮列车在气动荷载作用下的运动仿真,并将计算得到的列车动力响应数据作为样本用于神经网络模型的预测。



图6 电磁铁分布

Fig.6 Electromagnet distribution

2.2 基于LSTM神经网络的列车动力响应预测

神经网络模型的输入为气动荷载(侧向力 f_y 、升力 f_z 、侧滚力矩 m_x 、点头力矩 m_y 、摇头力矩 m_z)、列车仿真模型计算得到的电磁铁悬浮间隙 z 、电流 i 以及悬浮间隙预测值和真实值的误差 e , 输出为预测电磁铁悬浮间隙 \hat{z} 。由此可知,神经网络模型的输入数据维度为8,输出数据维度为1。预测模型根据一段已知的动力响应和气动荷载预测未来的悬浮间隙,即:

$$\begin{cases} X_i = [x_{i-L+1} \cdots x_{i-1}]^T \\ x_i = [f_{yi} \ f_{zi} \ m_{xi} \ m_{yi} \ m_{zi} \ z_i \ i_i \ e_i], i = 1, \dots, n \end{cases}$$

式中: X_i 为神经网络输入值,其中包括 t 时刻前一段时间内的历史信息 x ; L 为神经网络中输入历史信息的组数; n 为样本集中数据组数。

高速磁浮列车动力响应预测框架如图8所示,

包括训练网络和预测模型两部分。以高速磁浮列车仿真模型在 $500 \text{ km} \cdot \text{h}^{-1}$ 时的气动荷载和头车(从右到左)第1个电磁铁(H1)的计算结果为样本集对模型进行训练,数据时间步长为 0.004 s ,共5500组数据,每组数据8列,进行预测计算时使用的历史信息组数 L 为6。预测模型的建立主要包括以下步骤:

(1) 数据读取

将数据划分为用于训练网络的训练集和验证预测结果的测试集。训练集和测试集的长度可以自由定义,训练集的长度为 T ,则训练集为

$$X_{\text{Train}} = [x_1 \ x_2 \ \cdots \ x_T]^T$$

同理,测试集为

$$X_{\text{Test}} = [x_{T+1} \ x_{T+2} \ \cdots \ x_n]^T$$

(2) 数据预处理

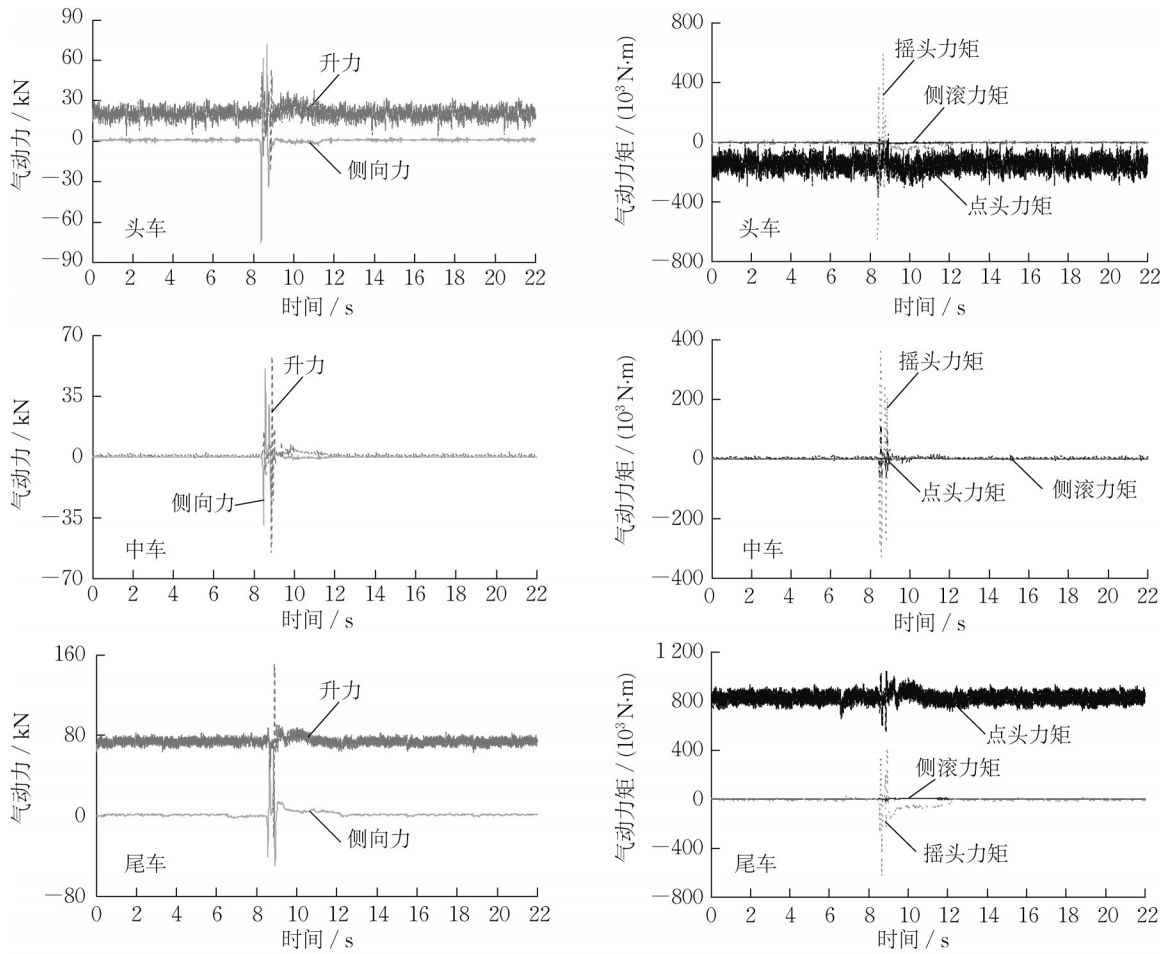


图7 气动荷载

Fig.7 Aerodynamic loads

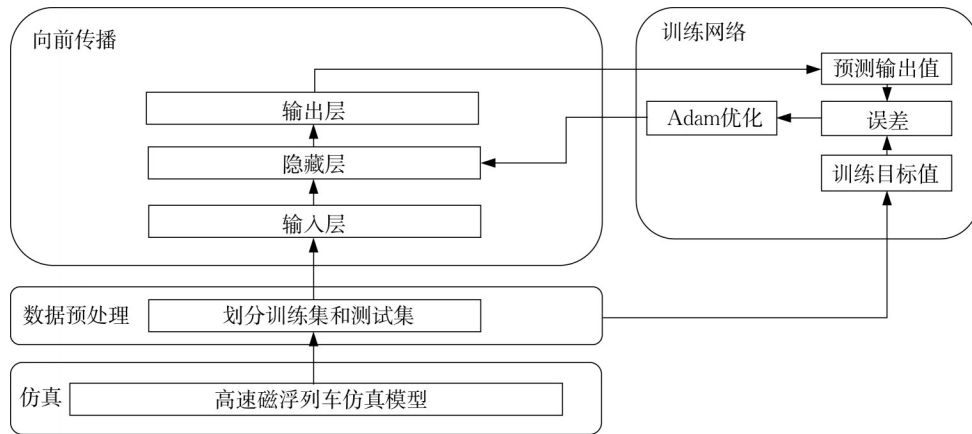


图8 高速磁浮列车动力响应预测框架

Fig.8 Dynamic response prediction framework of high-speed maglev train

在进行训练之前,按照所需历史信息数目对训练集进行划分,即:

$$\mathbf{X}_{\text{Train}} = [\mathbf{X}_1 \quad \mathbf{X}_2 \quad \cdots \quad \mathbf{X}_{T-5}]$$

$$\mathbf{X}_i = [x_i \quad \cdots \quad x_{i+5}]^T$$

对应的目标值为

$$\mathbf{Y}_{\text{Train}} = [\mathbf{y}_1^* \quad \mathbf{y}_2^* \quad \cdots \quad \mathbf{y}_T^*], \mathbf{y}_i^* = [z_i]$$

式中: \mathbf{y}_i^* 为神经网络中的目标值,也就是电磁铁悬浮间隙仿真计算值。

(3) 定义神经网络模型向前传播

根据控制对象选择神经网络的初始参数。设置

隐藏层层数为1,节点数为20,学习率为0.001。输入值经过隐藏层门控后的计算值为

$$y_i = \text{LSTM}(X_{i-6}, C, h), 7 \leq i \leq T$$

式中: y_i 为神经网络中的预测值。

(4) 设置损失函数

本模型中,采用均方误差(MSE)作为损失函数,表达式如下所示:

$$l_{\text{loss}} = \frac{1}{T-6} \sum_{i=7}^T (y_i^* - y_i)^2$$

(5) 利用训练集数据训练神经网络

步骤1 对每个神经元的权重和阈值随机赋值。

步骤2 通过正向传递对输入值进行计算,得到悬浮间隙预测值。

步骤3 对悬浮间隙仿真计算值(真实值)与预测值求输出层的误差,然后将误差反向传递求出每一层每个神经元的误差。

步骤4 利用误差计算得到每个神经元权重和阈值的增量 Δw 、 Δb ,计算式如下所示:

$$\Delta w_{ij} = -\eta \frac{\partial l_{\text{loss}}}{\partial w_{ij}}, \Delta b_i = -\eta \frac{\partial l_{\text{loss}}}{\partial b_i}$$

式中: η 为学习率。然后,将每个神经元的权重 w 和阈值 b 更新为 $w + \Delta w$ 、 $b + \Delta b$ 。

步骤5 利用新的权重和阈值重复步骤2到步骤4的流程,不断修改权重使损失函数达到较小,然后输出训练结果。

(6) 预测与检验

利用步骤5训练好的结果根据测试集数据进行预测计算。在预测计算结束后,利用测试集目标值和预测结果对训练模型进行测试验证。

3 预测模型计算结果

3.1 预测模型评价指标

预测模型最终实现的功能为准确预测磁浮列车运行时的电磁铁悬浮间隙,因此选用可以评价预测值与仿真计算值接近程度的指标来评价预测模型的性能。

选用可以直观评价预测值 \hat{z}_i 和仿真计算值 z_i 之间误差大小的均方误差(e_{MSE})和平均绝对误差(e_{MAE}),对预测模型的计算误差进行分析。

(1) 均方误差

均方误差是指参数估计值与参数真值之差平方的期望值,表达式为

$$e_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (\hat{z}_i - z_i)^2$$

均方误差是衡量测量精度的一种数值指标,其值越小,说明预测模型越能准确地描述实验数据。

(2) 平均绝对误差

平均绝对误差表示预测值和观测值之间绝对误差的平均值。平均绝对误差是一种线性分数,所有个体差异在平均值上的权重都相等,表达式为

$$e_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |\hat{z}_i - z_i|$$

同均方误差一样,平均绝对误差的值越小,说明预测值和真实值越接近。

高速磁浮列车电磁铁悬浮间隙一般在10 mm左右波动,数量级较小。均方误差和平均绝对误差受数量级影响会出现“假性小误差”,也就是误差值较小是因为数据数量级小,而不是预测模型计算精度高。为了消除这种影响,还选用了平均绝对百分比误差(e_{MAPE})和决定系数(R^2)对磁浮列车电磁铁悬浮间隙预测模型的优劣进行分析。 e_{MAPE} 和 R^2 的分子分母数量级在同一级别,可以有效消除数量级对误差评价的影响。

(3) 平均绝对百分比误差

上述2种评价指标都受数据量级的影响,因此引入了平均绝对百分比误差作为评价指标,表达式如下所示:

$$e_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{z}_i - z_i}{z_i} \right|$$

平均绝对百分比误差的值越小,说明模型预测精度越高。

(4) 决定系数

R^2 可以反映因变量的全部变动能通过回归关系被自变量解释的比例。 R^2 越接近于1,系统预测拟合效果越好,一般认为超过80%的模型拟合度比较高,代表预测值与真实值较为接近。 R^2 的表达式如下所示:

$$R^2 = 1 - \frac{\sum_{i=1}^n (z_i - \hat{z}_i)^2 / n}{\sum_{i=1}^n (z_i - \bar{z})^2 / n}$$

式中: \bar{z} 为 z_i 的均值。

3.2 训练集与测试集的计算结果

通过对仿真模型计算得到的数据进行深度学习训练,得到了气动荷载扰动下整车各个电磁铁悬浮间隙的训练结果和预测结果,列车仿真计算时考虑了每节车厢受到的升力、侧向力、点头力矩、摇头力矩以及侧滚力矩。以图6(从右到左)头车第1个电磁铁(H1)、头车与中车连接处的电磁铁(M1)、中车和尾车连接处的电磁铁(M9)以及尾车最后1个电磁铁(T7)的悬浮间隙模型计算结果为例,对提出的预

测方法进行分析。每个电磁铁样本集的总组数 $n=5\,500$ 。在机器学习中,若数据共有万组,可以按照6:4设置训练数据和测试数据。本研究中设置训练集组数为2 750,测试集组数为2 750。

模型训练结果如图9所示。经过多次迭代训

练,所提出的神经网络预测算法可以很好地对训练集数据进行学习,得到预测误差较小的网络模型。

为了检验模型的学习成果,根据训练集得到的神经网络训练结果对测试集中的悬浮间隙时间序列进行预测,结果如图10所示。




图9 电磁铁悬浮间隙训练结果

Fig.9 Training results of electromagnetic suspension gap




图10 电磁铁悬浮间隙预测结果

Fig.10 Prediction results of electromagnetic suspension gap

由图 10 可知,3 节编组磁浮列车头尾处的电磁铁悬浮间隙波动幅度较大,预测模型可以准确地预测未来时刻每个电磁铁悬浮间隙的变化趋势。为了

对模型预测精度进行评判,还给出了预测结果与真实值的误差曲线(见图 11)和模型评价指标计算结果(见表 1)。




图 11 电磁铁悬浮间隙真实值与预测值的误差曲线

Fig.11 Error curve between actual value and predicted value of electromagnet suspension gap

表 1 模型评价指标计算结果

Tab.1 Calculation results of model evaluation index

电磁铁	e_{MSE}	e_{MAE}	e_{MAPE}	R^2
H1	1.20×10^{-5}	0.002 7	0.042 8	0.999 9
M1	5.01×10^{-6}	0.002 0	0.151 8	0.996 3
M9	4.35×10^{-7}	0.000 5	0.116 1	0.999 4
T7	1.21×10^{-5}	0.002 7	0.037 5	0.999 9

由表 1 可知,误差相较于预测结果数值很小,并且两者不在一个数量级。 e_{MSE} 和 e_{MAE} 的值极小, e_{MAPE} 均小于 0.2,决定系数 R^2 非常接近 1,这说明提出的神经网络算法预测得到的悬浮间隙与仿真计算得到的实测悬浮间隙误差很小,预测模型精度很高。

3.3 预测结果对比

现有的预测方法大致有 2 种:状态方程预测和卡尔曼滤波预测。基于直接解耦的电磁铁状态方程预测方法未能考虑列车各个悬浮单元之间的非线性耦合影响,不利于表现列车的整车特征。不仅如此,状态方程还需要施加系统输入才能进行计算,预测结果受输入量的影响。

卡尔曼滤波预测和本研究提出的神经网络预测的计算结果(以头车 H1 处电磁铁为例)如图 12 所示。

与直接解耦的电磁铁状态方程预测方法相比,




图 12 电磁铁悬浮间隙预测结果对比(H1)

Fig.12 Comparison of predicted results of electromagnet suspension gap(H1)

状态方程预测未能考虑列车各个悬浮单元之间的非线性耦合影响,不利于表现列车的整车特征。利用磁浮列车整车在气动荷载作用下的动力响应建立预测模型,更加符合列车实际的非线性系统。与卡尔曼滤波预测方法相比,所提出的预测方法具有更高的预测精度。

4 结语

基于上海 TR08 列车建立了 3 节编组磁浮列车仿真模型,并将气动荷载作用下模型的计算结果作

为预测模型的样本集,之后利用LSTM神经网络构建了预测算法。由仿真模型计算结果和所提出的预测算法的预测结果分析可知,计算得到的悬浮间隙预测值与实际值误差很小,而且预测指标均符合要求。因此,所提出的预测算法可以根据列车实时响应准确地预测未来时刻的悬浮间隙。该预测算法的思路和流程同样适用于实际列车的动力响应预测。

作者贡献声明:

吴 晗:总体方案设计和悬浮控制算法设计。

刘梦娟:仿真计算和文章整理。

曾晓辉:算法检验和文章校核。

参考文献:

- [1] ZHANG L, HUANG J, HUANG L, *et al.* Stability and bifurcation analysis in a maglev system with multiple delays[J]. *International Journal of Bifurcation & Chaos*, 2015, 25(5): 1.
- [2] RICHES E. Will maglev lift off? [J]. *IEE Review*, 1989, 34(11):427.
- [3] 刘颖硕. EMS型磁悬浮列车悬浮控制系统及动力学建模研究[D]. 石家庄: 石家庄铁道大学, 2021.
LIU Yingshuo. Research on levitation control system and dynamic modeling of EMS maglev train [D]. Shijiazhuang: Shijiazhuang Tiedao University, 2021.
- [4] LINDLAU J D, KNOSPE C R. Feedback linearization of an active magnetic bearing with voltage control [J]. *IEEE Transactions on Control Systems Technology*, 2002, 10(1): 21.
- [5] 罗继康,康贵荣. 基于PID控制的磁悬浮控制系统研究[J]. *科技视界*, 2013(32): 2.
LUO Jigeng, KANG Guirong. Research on magnetic levitation control system based on PID control [J]. *Science and Technology Vision*, 2013(32): 2.
- [6] NI F, MU S, KANG J, *et al.* Robust controller design for maglev suspension systems based on improved suspension force model [J]. *IEEE Transactions on Transportation Electrification*, 2021, 7(3): 1765.
- [7] BENOMAIR A M, FIRDAUS A R, TOKHI M O. Fuzzy sliding control with non-linear observer for magnetic levitation systems[C]// 2016 24th Mediterranean Conference on Control and Automation (MED). Athens: IEEE, 2016: 256-261.
- [8] YANG J, SU J, LI S, *et al.* High-order mismatched disturbance compensation for motion control systems via a continuous dynamic sliding-mode approach [J]. *IEEE Transactions on Industrial Informatics*, 2014, 10(1): 604.
- [9] 孙友刚,徐俊起,贺祯宇,等. 基于误差交叉耦合的多电磁铁悬浮系统滑模协同控制[J]. *西南交通大学学报*, 2022, 57(3): 558.
SUN Yougang, XU Junqi, HE Zhenyu, *et al.* Sliding mode cooperative control of multi-electromagnet suspension system based on error cross coupling[J]. *Journal of Southwest Jiaotong University*, 2022, 57(3): 558.
- [10] LEE H W, KIM K C, JU L. Review of maglev train technologies [J]. *IEEE Transactions on Magnetics*, 2006, 42(7): 1917.
- [11] 孙友刚,徐俊起,王素梅,等. 基于向量式有限元法的磁浮列车磁力耦合系统建模与数值分析[J]. *同济大学学报(自然科学版)*, 2021, 49(12): 1635.
SUN Yougang, XU Junqi, WANG Sumei, *et al.* Modeling and numerical analysis of maglev train magnetic coupling system based on vector form intrinsic finite element method[J]. *Journal of Tongji University (Natural Science)*, 2021, 49(12): 1635.
- [12] 张小庆. 混合多磁铁磁浮列车悬浮系统协调预测控制研究[D]. 北京: 北京交通大学, 2021.
ZHANG Xiaoqing. Study on coordinated predictive control of suspension system of hybrid multi-magnet maglev train [D]. Beijing: Beijing Jiaotong University, 2021.
- [13] LI Y. The research on model predictive control for linear synchronous motor of maglev train [J]. *Science Discovery*, 2017, 5(2):77.
- [14] WANG H, ZHONG X, SHEN G. Analysis and experimental study on the maglev vehicle-guideway interaction based on the full-state feedback theory[J]. *Journal of Vibration and Control*, 2015, 21(2): 408.
- [15] 张振霖. 磁浮列车悬浮系统的预测控制研究[D]. 北京: 北京交通大学, 2015.
ZHANG Zhenlin. Research on model predictive control of maglev levitation system [D]. Beijing: Beijing Jiaotong University, 2015.
- [16] 王佳楠,王玉莹,何淑林,等. 基于改进遗传算法优化BP神经网络的土壤湿度预测模型[J]. *计算机系统应用*, 2022, 31(2):273.
WANG Jianan, WANG Yuying, HE Shulin, *et al.* Optimized BP neural network model based on improved genetic algorithm for soil moisture prediction [J]. *Computer Systems & Applications*, 2022, 31(2): 273.
- [17] 苏烨,凌路加,段亚灿,等. 基于神经网络预测控制的主汽温优化控制[J]. *计算机仿真*, 2021, 38(9): 114.
SU Ye, LING Lujia, DUAN Yacan, *et al.* Optimization control of main steam temperature based on neural network predictive control [J]. *Computer Simulation*, 2021, 38(9): 114.
- [18] SUN Y, XU J, LIN G, *et al.* RBF neural network-based supervisor control for maglev vehicles on an elastic track with network time delay [J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(1): 509.
- [19] 王鑫,吴际,刘超,等. 基于LSTM循环神经网络的故障时间序列预测[J]. *北京航空航天大学学报*, 2018, 44(4): 772.
WANG Xin, WU Ji, LIU Chao, *et al.* Exploring LSTM based recurrent neural network for failure time series prediction [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2018, 44(4): 772.