

利用循环网络的降落伞开伞载荷补偿方法*

姜 添, 李 健, 戈嗣诚
(北京空间机电研究所, 北京 100094)

摘要: 为了对降落伞充气展开过程中的开伞载荷进行更加准确的预测, 提出一种基于循环神经网络的开伞载荷补偿计算方法, 包括模型架构和数据处理方式。该方法将充气时间法计算的预测值代入循环网络进行二次计算, 使最终结果能够更加贴近试验真值。使用多层前馈网络、标准循环网络与长短时记忆网络三种网络进行比较, 验证了所提模型预测结果的适用性和准确性, 研究了学习率、输入层维度和隐层维度等超参数对模型性能的影响, 并给出了基于长短时记忆网络的补偿模型最优训练条件。实验结果表明, 利用循环网络进行开伞载荷预测具有较好的拟合结果, 为机器学习与降落伞工业的学科交叉研究提供了一定的参考方向。

关键词: 降落伞; 开伞载荷; 补偿方法; 循环神经网络; 长短时记忆网络

中图分类号: V445.4 文献标志码: A 文章编号: 1001-2486(2022)02-080-08

Compensation method of parachute deployment load based on recurrent neural networks

JIANG Tian, LI Jian, GE Sicheng

(Beijing Institute of Space Mechanics & Electricity, Beijing 100094, China)

Abstract: Focusing on predicting the parachute deployment load in the process of inflation accurately, a compensation calculation method of parachute deployment load with RNN (recurrent neural networks) was proposed, including the model architecture and data processing. The predicted value calculated by inflation time method was brought into the RNN for the secondary calculation, so that the final result could be close to the airdrop experiment data. The feedforward neural networks, standard recurrent networks and long short-term memory networks were used to compare the model characteristic. The research verified the applicability and accuracy of the prediction results and analyzed the effects of hyperparameters such as learning rate, input layer dimension and hidden layer dimension on the performance. The optimal training condition for reference to the compensation model was developed through the test. The results show that the utilization of RNN for parachute deployment load prediction is effective and provides a referential significance for the interdisciplinary research of machine learning and parachute industry.

Keywords: parachute; deployment load; compensation method; recurrent neural networks; long short-term memory networks

降落伞技术是飞行器进入、下降和着陆^[1] (Entry, Descent, and Landing, EDL) 关键技术的核心部分, 降落伞的典型工作过程包括伞系拉直、充气展开、稳定减速三个阶段。其中伞衣的充气展开最为重要, 该过程的研究关注点主要面向伞的载荷变化和应力分布、伞衣变形和阻力面积等, 工程应用及科学探索对该阶段的常用研究手段包括以下三种: 完全试验法、数值模拟法与半理论半试验法。其中, 完全试验法一般用风洞实验^[2] 或空投试验^[3] 等方式直接获取伞的相关数据, 准备周期长、试验成本高, 适用于理论与产品的初样验证, 工程设计阶段已很少采用; 数值模拟法多

以任意拉格朗日-欧拉法^[4] (Arbitrary Lagrange-Eulerian method, ALE) 以及变空间域/稳定时间-空间法^[5] (Deforming-Spatial-Domain / Stabilized Space-Time, DSD/SST) 等计算机仿真方法处理物伞系统的流固耦合问题, 并在实践中有所应用^[6-7], 但受限于技术能力, 数值模拟法目前难以满足产品初步设计过程中计算简单、快速应用的需求; 为了对一些典型应用工况进行快速、准确的计算分析, 有学者结合大量的伞系试验总结出应用于物伞系统的经验公式^[8], 而后发展成为半理论半试验法, 这类方法可以让研究人员迅速获取给定条件下的开伞力及飞行速度等重要参数的预

* 收稿日期: 2020-09-10

基金项目: 国家自然科学基金资助项目(11972192)

作者简介: 姜添(1994—), 男, 黑龙江双鸭山人, 博士研究生, E-mail: jetinjiang@foxmail.com;

戈嗣诚(通信作者), 男, 研究员, 博士, 博士生导师, E-mail: gesicheng@163.com

测数值并据此判断伞的性能状态是否满足设计要求,是工程中常用和高效的方法,不足之处是具有非常强的经验参数依赖性和应用场景局限性,很多学者针对此问题对经验公式进行了改进与优化^[9-10],但仍存在较大的提升空间。近年来快速发展的机器学习理论凭借其强大的非线性拟合与泛化性能受到了部分研究者的关注,进行传统方法结合机器学习的学科交叉研究可以为提高经验公式模型的精度与适用性提供一种新的研究思路。

由于机器学习的细分种类繁多,选择合适的模型对提升训练的效率与准确性大有裨益。考虑空投试验中飞行器与降落伞的飞行状态变化,将空投过程在时间维度上进行离散,可以认为:物伞系统每一时刻的飞行状态与前一时刻或几个时刻的状态量密切相关;与较远时刻状态的相关性较小;与后续时刻状态无关。这种以时间序列为基础的数据特性尤其适用于循环神经网络(Recurrent Neural Networks, RNN)模型^[11],该类网络与其变种——长短时记忆网络^[12](Long Short-Term Memory, LSTM)目前在处理序列问题中表现出较大优势,并广泛应用于互联网中的自然语言处理相关领域,在部分非互联网行业中也有涉猎^[13-15]。而在降落伞的相关行业中,国内外使用机器学习方法进行研究的参考案例较少,且大部分限于对伞绸透气性^[16]及伞衣织物强度^[17]的研究,对展开过程中载荷特性等问题的探索有限,循环网络与降落伞的交叉应用具有很大的挖掘空间。

本文针对开伞过程中开伞力的预测,提出了一种使用循环网络结合经验公式的补偿计算模型,包括模型架构的详细设计以及对训练集与测试集的数据预处理方法等。使用3种不同的网络模型对开伞力的仿真结果进行比较分析并探索循环网络中超参数对训练结果的影响,给出本模型的最优训练参数。

1 充气时间理论

半理论半试验法中常用的计算方法有充气距离法与充气时间法,二者由动量方程的自变量不同进行区分,本文使用的是以充气时间作为自变量的充气时间法。

降落伞与回收物在开伞过程中的平面受力情况如图1所示。建立该系统运动方程时,首先给定以下假设条件:①该运动为双质点运动,伞质心位于伞衣底边中心且相对底边位置不发生变化;

②忽略物伞系统升力;③物伞轴线始终重合;④忽略伞绳弹性,物伞相对位置不发生变化。

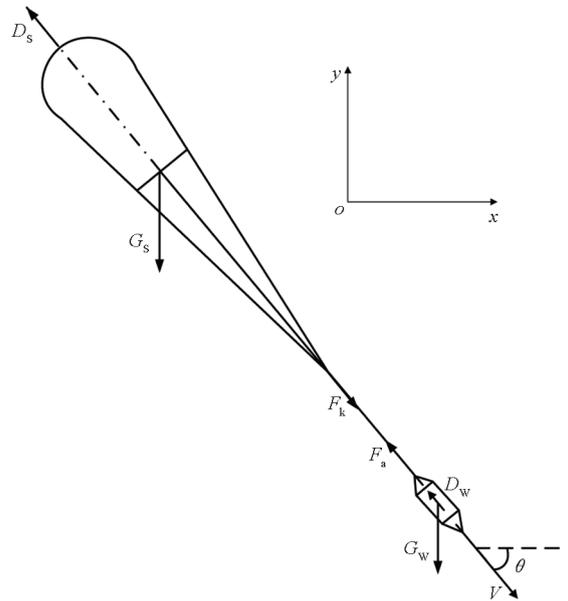


图1 平面物伞系统力学模型

Fig. 1 Mechanical model of object-parachute system

在上述假设条件的前提下,可建立物伞系统合速度 V 关于时间 t 的微分方程以及降落伞拉力 F_k 的表达式:

$$\frac{dV}{dt} = -\frac{V}{m_w + m_s + m_f} \frac{dm_f}{dt} - \frac{m_w + m_s}{m_w + m_s + m_f} g \sin \theta - \frac{1}{2} \rho V^2 \frac{C_w + C}{m_w + m_s + m_f} \quad (1)$$

$$F_k = V \frac{dm_f}{dt} - \frac{1}{2} \rho V^2 C + (m_s + m_f) \frac{dV}{dt} + m_s g \sin \theta \quad (2)$$

其中: θ 为物伞系统轴线与水平方向夹角; m_w 为回收物质量; m_s 为降落伞质量; m_f 为附加质量,

$$m_f = \rho k_t C^{1.5} \quad (3)$$

C 表示降落伞的瞬时阻力特征,

$$C = \begin{cases} k_t t & (0 \leq t \leq t_{m1}) \\ C_1 + \beta_1 (t - t_{m1})^p & (t_{m1} \leq t \leq t_m) \end{cases} \quad (4)$$

式中, t_{m1} 表示初始充气时间, t_m 表示充满时间,且各参数满足关系式:

$$\begin{cases} t_{m1} = \frac{\lambda_1 D_0}{V_L} \\ t_m = \frac{\lambda_2 D_0}{V_L} \\ k_t = \frac{C_1}{t_{m1}} \\ \beta_1 = \frac{C_s - C_1}{(t_m - t_{m1})^p} \end{cases} \quad (5)$$

式(1)~(5)中其余物理量及参数含义为: D_0 表示伞衣名义直径, V_L 表示拉直速度, C_1 表示初始充气时期的伞衣阻力特征, C_s 表示充满伞衣的阻力特征, C_w 表示回收物的阻力特征; k_f 表示附加质量系数, λ_1 是与伞型有关的常数, λ_2 是与伞衣透气性有关的常数,指数 p 在充气时间法中通常取 1~5。

上述系数和常数为经验参数,是充气时间理论的核心部分,一般通过大量试验测试综合总结获得。

2 循环神经网络

循环网络相当于是以时间顺序串联的前馈网络(Feedforward Neural Networks, FNN),其模型原理和隐层细胞结构如图 2 所示。标准 3 层 RNN 结构下 t 时刻网络的前向传播过程可由下列公式计算:

$$\begin{cases} \mathbf{h}^{(t)} = \tanh(\mathbf{b} + \mathbf{U}\mathbf{x}^{(t)} + \mathbf{W}\mathbf{h}^{(t-1)}) \\ \mathbf{y}^{(t)} = \sigma(\mathbf{c} + \mathbf{V}\mathbf{h}^{(t)}) \end{cases} \quad (6)$$

式中: $\mathbf{x}^{(t)}$ 、 $\mathbf{h}^{(t)}$ 、 $\mathbf{y}^{(t)}$ 分别表示输入向量、隐层向量与输出向量; \mathbf{U} 、 \mathbf{V} 、 \mathbf{W} 分别表示输入与隐层、隐层与输出层、隐层与隐层之间的权重参数; \mathbf{b} 和 \mathbf{c} 分别表示隐层与输出层神经元的阈值; σ 为 sigmoid 函数。

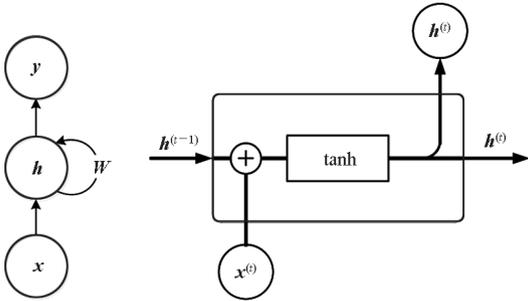


图 2 RNN 模型及其隐层细胞结构

Fig. 2 RNN model and cell structure of hidden layer

标准 RNN 模型的缺点是时间序列过长时,训练梯度会趋向于消失或者爆炸,该现象被称为循环网络的长期依赖挑战。为了缓解这一问题,近年来学者们研究了 RNN 的多种变体,其中的 LSTM 模型较为有效,其隐层细胞结构如图 3 所示。

LSTM 具有内部的循环(自环)结构,引入了状态单元 C 与“门控”的概念,包括输入门、遗忘门和输出门。新结构的加入使 LSTM 对细胞内部信息的处理变得更加细化,信息的存储与更新也更有效率,训练过程不再是简单的输入量与循环单元之间的仿射变换。相较 RNN, LSTM 的网络

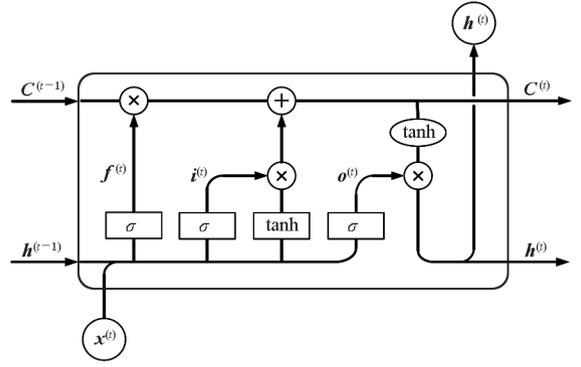


图 3 LSTM 细胞结构

Fig. 3 Cell structure of LSTM

复杂度与网络性能均有所上升,其前向传播公式为:

$$\begin{cases} \mathbf{f}^{(t)} = \sigma(\mathbf{b}_f + \mathbf{U}_f \mathbf{x}^{(t)} + \mathbf{W}_f \mathbf{h}^{(t-1)}) \\ \mathbf{i}^{(t)} = \sigma(\mathbf{b}_i + \mathbf{U}_i \mathbf{x}^{(t)} + \mathbf{W}_i \mathbf{h}^{(t-1)}) \\ \mathbf{\alpha}^{(t)} = \tanh(\mathbf{b}_\alpha + \mathbf{U}_\alpha \mathbf{x}^{(t)} + \mathbf{W}_\alpha \mathbf{h}^{(t-1)}) \\ \mathbf{C}^{(t)} = \mathbf{C}^{(t-1)} \odot \mathbf{f}^{(t)} + \mathbf{i}^{(t)} \odot \mathbf{\alpha}^{(t)} \\ \mathbf{o}^{(t)} = \sigma(\mathbf{b}_o + \mathbf{U}_o \mathbf{x}^{(t)} + \mathbf{W}_o \mathbf{h}^{(t-1)}) \\ \mathbf{h}^{(t)} = \mathbf{o}^{(t)} \odot \tanh(\mathbf{C}^{(t)}) \\ \mathbf{y}^{(t)} = \sigma(\mathbf{c} + \mathbf{V}\mathbf{h}^{(t)}) \end{cases} \quad (7)$$

式中: \mathbf{f} 、 \mathbf{i} 、 \mathbf{C} 、 \mathbf{o} 分别表示遗忘门、输入门、状态单元和输出门, \mathbf{h} 、 \mathbf{y} 表示当前隐层向量与输出向量, \mathbf{b} 、 \mathbf{U} 、 \mathbf{W} 表示对应门控的阈值、输入连接权重和隐层连接权重, σ 为 sigmoid 函数, \odot 表示向量积运算。

训练数据需通过 Min-max 标准化方法处理后,使用基于时间的反向传播算法(Back Propagation Through Time, BPTT)结合批梯度下降法(Batch Gradient Descent, BGD)进行训练,其中批尺寸 B 取 100。

3 开伞载荷补偿方法

3.1 开伞载荷补偿模型原理

本文所使用的基于充气时间法的经验公式已经具备一定的工程应用价值,开伞载荷补偿模型的原理是将基于该经验公式的理论拉力计算值代入循环网络进行训练,其目的是将理论值向试验真值进行补偿,并获取成熟的网络训练结果,使补偿后的载荷计算值更加接近试验真值,以此提高最终结果的预测精度。

考虑所能够使用的有效数据量和数据特征,并满足循环神经网络的应用能力,构建开伞载荷补偿计算模型框架如图 4 所示,该框架主要包括经验公式、网络训练和输出预测三个功能模块。

该模型的运行思路如下:①利用经验公式初步获得某工况条件下开伞过程中的开伞力预测初值;②将预测值经过数据预处理,获得可以进行网络训练的输入特征向量;③选用相应的网络模型进行训练;④训练集的网络输出参与反向传播更新网络权重,测试集的网络输出经过反标准化方法获得补偿后的开伞力输出值。

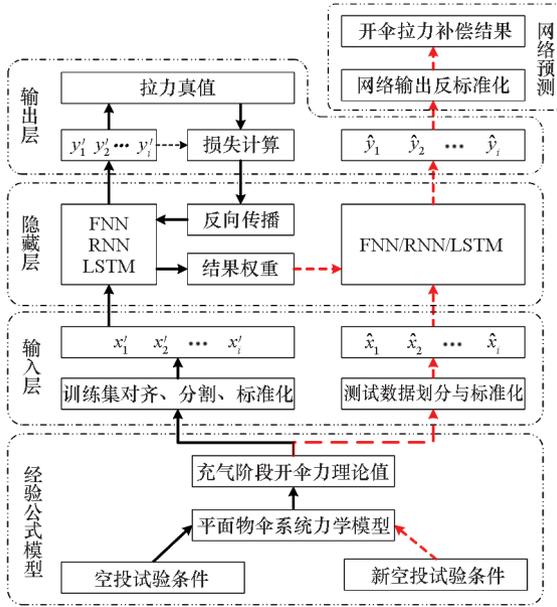


图4 开伞载荷补偿模型框架

Fig. 4 Compensation model framework of parachute deployment load

3.2 数据预处理

3.2.1 训练数据获取

试验数据来源于4种条件下的低空开伞空投试验:配重质量为6 040 kg,降落伞伞型为盘-缝-带伞,伞名义面积为200 m²,设计无限质量开伞方式。试验过程中使用拉力传感器同时采集时间与拉力信号,采样频率为2 kHz,同时搭配GPS接收机采集其他试验数据。经验公式法的初始条件由空投试验要求给定,气象条件使用当地月平均气象数据或探空气球实测数据。

本文的主要研究对象是伞充气阶段的开伞力变化,对开伞过程中伞系拉直至载荷峰值时间和开伞载荷均进行了统一的标准化处理,如图5所示,具体数据处理方式如下:

1)对空投试验拉力及经验公式计算拉力进行有效数据截取,选取区间固定为伞系拉直时刻至拉力峰值时刻;

2)通过插值方法将上述区间内的拉力数据统一规范至相同维度,本文选取的数据维度为4 000,即单次试验参与网络训练的有效数据有

4 000个;

3)将所有拉力数据采用Min-max标准化方法进行归一化处理,数据序列上下限选取为(0,200)。

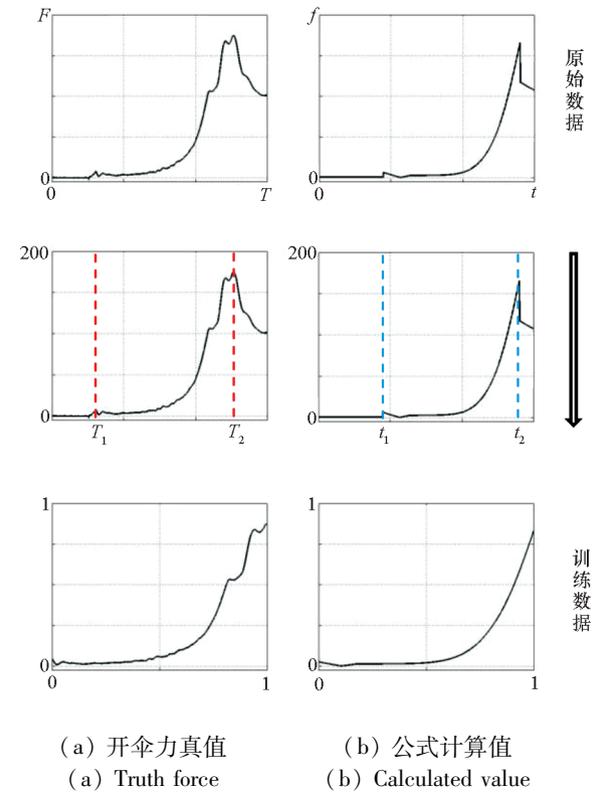


图5 开伞力数据处理过程

Fig. 5 Parachute deployment data processing

经过上述步骤处理的拉力数据在时间与量级两个方面实现了归一化,以经验公式法的计算值作为网络输入、以空投试验数据作为目标值参与网络训练。

3.2.2 样本划分与验证方法

为了满足网络训练要求与样本数据量,需要对归一化的数据进行分割,以获取训练集的输入向量与目标向量。由上节可知,单次空投条件下由经验公式产生的训练样本及对应真值为:

$$\begin{cases} \mathbf{X}_1 = (x_1, x_2, \dots, x_{4000}) \\ \mathbf{Y}_1 = (y_1, y_2, \dots, y_{4000}) \end{cases} \quad (8)$$

设循环网络输入向量维度为n,输出向量维度为m,时间维度为τ,从x₁开始顺序选取连续n个数据构成单一时刻内的输入,同理,从y₁顺序选取连续m个数据作为对应的目标向量,则第i组向量的表达式为:

$$\begin{cases} \mathbf{x}_i = (x_i, x_{i+1}, \dots, x_{i+n-1}) \\ \mathbf{y}_i = (y_i, y_{i+1}, \dots, y_{i+m-1}) \end{cases} \quad (9)$$

式中,1 ≤ i ≤ 4 000 - [max(n, m) - 1]。

再从x₁和y₁开始分别顺序选取τ个向量构成满足时间维度的网络输入与目标矩阵:

$$\begin{cases} (\mathbf{x}'_i)_{n \times \tau} = (\mathbf{x}_i, \mathbf{x}_{i+1}, \dots, \mathbf{x}_{i+\tau-1})^T \\ (\mathbf{y}'_i)_{m \times \tau} = (\mathbf{y}_i, \mathbf{y}_{i+1}, \dots, \mathbf{y}_{i+\tau-1})^T \end{cases} \quad (10)$$

式中, $1 \leq i \leq 4\ 002 - \max(n, m) - \tau$ 。

由 $\mathbf{x}'_i, \mathbf{y}'_i$ 组成对应数组 $\mathbf{d}_i = [\mathbf{x}'_i, \mathbf{y}'_i]$, 将 \mathbf{d}_i 代入网络即是完成对 RNN/LSTM 的一次训练, 遍历所有样本视为完成一次循环。由此可以得到一组试验数据产生的训练样本:

$$\{\mathbf{d}^1 | \mathbf{d}^1 = (\mathbf{d}_i)\} \quad (11)$$

式中, $1 \leq i \leq 4\ 002 - \max(n, m) - \tau$ 。

本文共使用了 4 组空投试验数据, 选取其中 3 组用作网络训练, 共产生样本 $\mathbf{d}^1, \mathbf{d}^2, \mathbf{d}^3$, 将所有样本进行混合, 然后再乱序排列, 即可得到训练集总样本:

$$\{\mathbf{d} | \mathbf{d} = (\mathbf{d}_i)\} \quad (12)$$

式中: $1 \leq i \leq 3 \times [4\ 002 - \max(n, m) - \tau]$ 。

验证集数据的处理相对简单, 将未参与训练的 1 组数据用作结果验证, 首先按照上述方法获得 \mathbf{d}^4 , 代入网络计算并获得输出矩阵, 其形式为:

$$\hat{\mathbf{y}} = (\hat{\mathbf{y}}_i)_{m \times \tau} \quad (13)$$

式中, $1 \leq i \leq 4\ 002 - \max(n, m) - \tau$ 。

选取 $\hat{\mathbf{y}}_1$ 中的第 m 行数据 $(\hat{\mathbf{y}}_1)_{m1} \sim (\hat{\mathbf{y}}_1)_{m\tau}$ 作为最终输出 $\hat{\mathbf{Y}}$ 的前 τ 项, 其余由 $\hat{\mathbf{y}}_i (i \geq 2)$ 的第 $m \times \tau$ 项元素组成, 即

$$\hat{\mathbf{Y}} = ((\hat{\mathbf{y}}_1)_{m1}, \dots, (\hat{\mathbf{y}}_1)_{m\tau}, (\hat{\mathbf{y}}_2)_{m\tau}, \dots, (\hat{\mathbf{y}}_k)_{m\tau}) \quad (14)$$

式中, $2 \leq k \leq 4\ 000 - [\max(n, m) - 1]$ 。

使用该方式的目的是: 一是为了尽量减小验证过程中初始随机隐层的影响; 二是考虑到循环网络的计算特点, 过去时刻的数据会对当前时刻的样本预测结果产生影响, 该种数据处理的形式可以提高样本的利用率。

4 仿真结果分析

4.1 开伞载荷补偿结果

使用 FNN、RNN 与 LSTM 三种网络结构进行实验。其中 FNN 为 5 层结构, 包括输入层、3 层全连接隐藏层、输出层, 每层神经元个数均为 4 000, 与输入层维度相同, 网络信息遗失率 (Dropout) 取 0.5。经过前期试错, FNN 采用的训练方案是以整体经验公式计算结果作为输入, 以整体空投真值作为目标值, 该方法在网络层数为 3 层和 4 层时无法收敛, 在 5 层结构下可以获得有效结果。RNN 和 LSTM 模型则是使用 3.2 节介绍的数据处理方式与训练方法, 二者均采用输入层—隐藏层—输出层的 3 层结构, 网络输入维度 $n = 10$, 隐

层维度 $h = 6$, 输出维度 $m = 1$, 学习率 $\eta = 0.05$, 时间序列 $\tau_{\text{RNN}} = 50, \tau_{\text{LSTM}} = 100$ 。图 6 给出了验证集数据经过不同模型进行补偿后的拉力变化曲线。

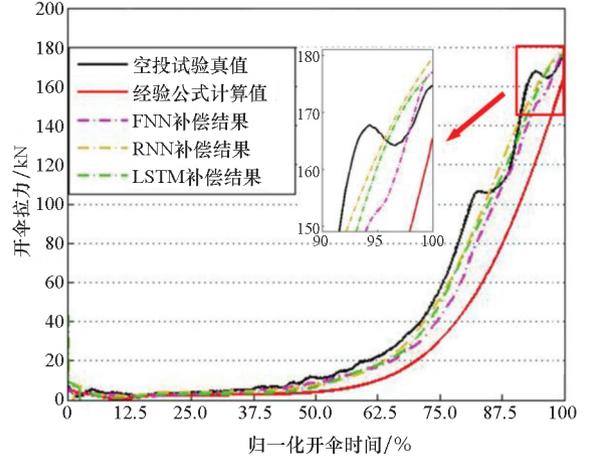


图 6 补偿模型的拟合结果

Fig. 6 Fitting result with compensation model

从图 6 可以看出, 在载荷曲线的比较中, 总体上看三种补偿结果均能正确地反映拉力变化趋势, 相较经验公式计算的开伞力, 补偿后计算值更加贴合试验真值; 在开伞力峰值的比较中, 补偿值与真值之间的相对误差明显缩小, 但是 FNN 的补偿结果整体低于循环网络; 在实验方法的比较中, 两种循环网络的计算结果相近, 且均优于 FNN。

图 7 给出了各模型的归一化载荷绝对误差变化曲线。由图可知, 经验公式计算值在前 40% 的时间内与真值的绝对误差小于 0.02, 之后二者的误差迅速攀升, FNN 模型约在 60% 的时刻后才出现误差的明显增长, RNN 与 LSTM 则将该时间点向后推延至 70%, 这些曲线分歧点的延后可以说明模型仿真能力的增强, 保证了拟合结果在分歧点前与试验真值的一致性。

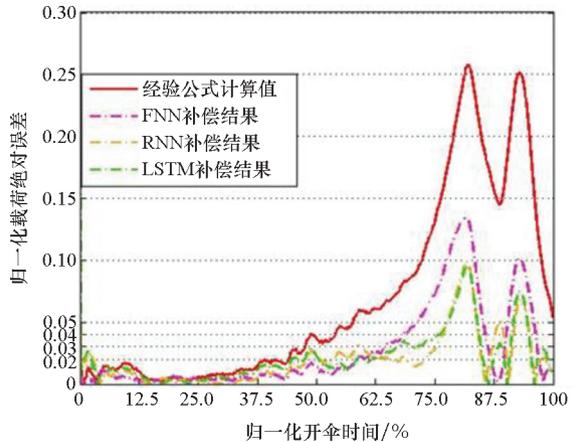


图 7 多模型归一化载荷绝对误差变化曲线

Fig. 7 Normalized load absolute error of multiple compensation models

各种拟合模型与真值的误差出现较大增长的主要因素是未能反映出图 6 空投试验数据的拉力平台期现象,基于经验公式的网络补偿方法在结果上表现出的数据规律仍与经验公式较为相似。文献[18]中利用 RNN 以同源数据的不同方案拟合出的载荷曲线可以展示出该拉力波动,表明循环网络具有训练出盘-缝-带伞充气展开过程中拉力波动的能力,说明本文实验的预测结果存在过拟合的成分,补偿模型与训练方式仍有改进的空间;文中使用的 3 组训练样本相较于其他机器学习案例来说仍然是偏少的,3.2.2 节的数据预处理过程即是针对循环网络样本不足问题所采取的数据增强手段,以求在一定程度上弥补数据量缺失的弱势。本实验中的样本数据相对有限且训练特征较为单一,结果容易存在过拟合,这样的情况在 FNN 中更为突出,这也是 FNN 训练结果不如 RNN 与 LSTM 的因素之一。

4.2 网络超参数影响分析

除此之外,本文比较了学习率、输入层维度、隐层维度等超参数对网络性能的影响。超参

数是在开始进行训练之前设置的参数值,不是通过训练得到的参数,神经网络的训练目的之一是对超参数进行优化而提高网络的学习性能。

图 8 给出了不同学习率下三种网络的峰值误差与均方误差的变化情况,具体数据如表 1 所示,训练条件与图 6 所示案例相同。

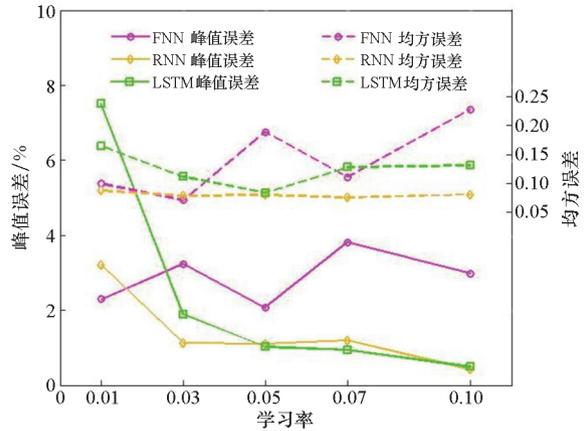


图 8 不同学习率的模型精度对比

Fig. 8 Comparison of model accuracy with different learning rate

表 1 不同学习率的模型精度

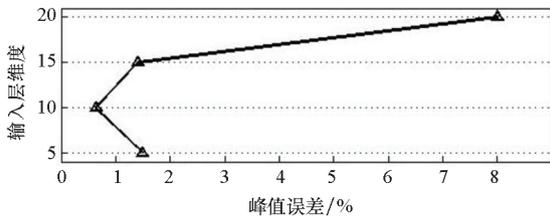
Tab. 1 Model accuracy with different learning rate

评价指标	学习率					试验真值/ kN	
	0.01	0.03	0.05	0.07	0.10		
计算峰值/ kN (峰值误差)	FNN	170.66 (2.30%)	169.02 (3.24%)	171.06 (2.07%)	168.02 (3.81%)	169.47 (2.98%)	174.68
	RNN	169.07 (3.21%)	172.71 (1.13%)	176.62 (1.11%)	172.58 (1.20%)	175.41 (0.42%)	
	LSTM	161.56 (7.51%)	177.98 (1.89%)	176.48 (1.03%)	176.32 (0.94%)	173.82 (0.49%)	
均方误差	FNN	9.94×10^{-2}	7.08×10^{-2}	1.89×10^{-1}	1.11×10^{-1}	2.28×10^{-1}	
	RNN	8.72×10^{-2}	7.84×10^{-2}	7.79×10^{-2}	7.52×10^{-2}	8.10×10^{-2}	
	LSTM	1.65×10^{-1}	1.11×10^{-1}	8.39×10^{-2}	1.28×10^{-1}	1.31×10^{-1}	

学习率影响着网络训练过程中梯度下降的速度,学习率过低容易使网络在训练过程中陷入局部极小,太大又会出现训练发散的情况。从图 8 中可以看出,FNN 的均方误差波动增长,且峰值误差明显大于 RNN 与 LSTM,开伞试验中峰值误差对开伞成功率的影响更为重要,从这两个方面看,FNN 的性能不如循环网络;在两种循环网络的比较中,RNN 的均方误差对学习率的变化并不敏感,LSTM 的均方误差先减小后增大,整体变化

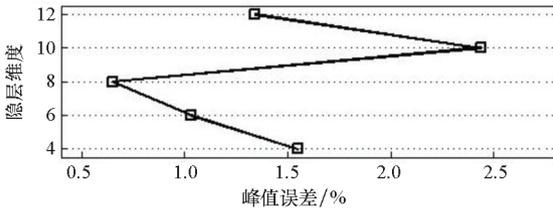
范围较小且 $\eta = 0.05$ 时有最小值,二者的峰值误差随着学习率的增大有逐渐下降的趋势,且学习率较小时 LSTM 的峰值误差变化率较大。综合图 8 与表 1 数据,在使用循环网络模型进行训练时,为保证训练要求,学习率选取 0.05,训练结果稳定且精度较高。

实验还比较了学习率为 0.05 时,LSTM 网络在不同输入维度与隐层维度下的峰值误差,如图 9 所示。其中,输入层维度变化时,固定隐层维



(a) 不同输入层的峰值误差变化

(a) Peak error variation of different input layers



(b) 不同隐层的峰值误差变化

(b) Peak error variation of different hidden layers

图 9 不同输入层、隐层维度下峰值误差对比 (学习率 $\eta = 0.05$)

Fig. 9 Comparison of peak error with different input layer dimension and hidden layer dimension (learning rate $\eta = 0.05$)

度 $h = 8$; 隐层维度变化时, 固定输入层维度 $n = 10$ 。从图中可以明显看出, 当输入层维度 $n = 10$ 、隐藏层维度 $h = 8$ 时, 峰值误差取得最小值, 模型训练结果具有最优解。

上述实验的训练过程中发现, 隐层维度取某些值时, 网络训练极易成功, 而取某些值时却连续多次训练未收敛, 由此现象本文探究了隐层维度对网络训练成功率的影响。由于计算资源有限, 本实验统计了 5 个隐层维度下各 20 次训练后的网络收敛次数, 图 10 为统计数据融合峰值误差的结果, 以颜色表示训练的难易程度。其中隐层

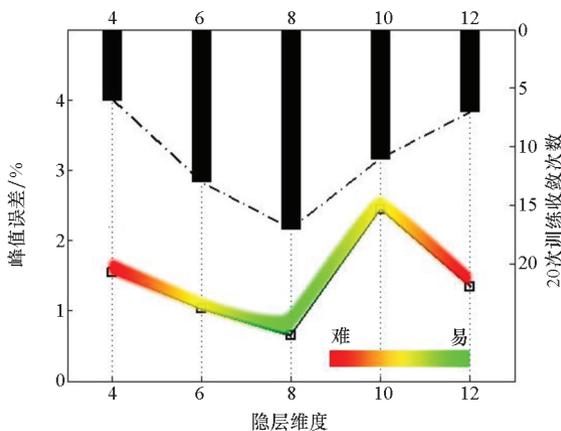


图 10 不同隐层维度下的网络收敛次数

Fig. 10 Number of convergence with different hidden layer dimension

维度 $h = 8$ 时训练成功次数明显高于其他情况, 随着隐层维度的变化, 训练成功率曲线整体类似于正态分布曲线。因此, 综合图 8、图 9 及图 10 三组实验结果可知, 本文采用的开伞载荷补偿模型在使用 LSTM 时的参考超参数为: 学习率 $\eta = 0.05$ 、输入层维度 $n = 10$ 、隐层维度 $h = 8$ 。采用该参数组合时最容易获得优质补偿结果, 且结果可复现能力强。

5 结论

针对降落伞开伞载荷的预测, 建立了一种利用循环网络的载荷补偿方法, 该方法在经验公式的计算结果上进行二次计算, 使最终结果更加贴近试验真值。本文比较了三种网络模型的补偿结果, 探讨了学习率对实验精度的影响, 并重点分析了 LSTM 模型中超参数的选择, 得到以下结论:

1) 开伞载荷补偿模型可以正确反映拉力变化趋势, 相较经验公式计算的开伞力, 经过补偿的曲线更加贴合试验真值。

2) 本模型中循环网络性能明显优于前馈网络, 随着学习率增大, 两种循环网络的峰值误差逐渐减小, 为保证训练要求, 用于训练的推荐学习率为 0.05。

3) 当学习率为 0.05 时, LSTM 在输入层维度 $n = 10$ 、隐层维度 $h = 8$ 的条件下最容易获得优质补偿结果, 且结果可复现能力强。

另外, 本文建立的开伞载荷补偿模型作为机器学习与经典力学两种方向的交叉学科研究, 目前仍处于初步探索阶段, 方法仍有很大的改进空间, 如预测结果的数据规律未能表现出盘-缝-带伞的拉力波动变化以及参与训练的样本特征较为单一等; 除此之外, 结合实践经验, 还有高低空开伞试验数据归一化方法引起的数据分布不均与不同组试验传感器差异引起的样本特征种类不一致等问题有待进一步的解决, 上述方向可为其他学者的继续研究提供一定的参考。

参考文献 (References)

[1] 高兴龙, 张青斌, 高庆玉, 等. 无限质量降落伞充气动力学数值模拟[J]. 国防科技大学学报, 2017, 39(3): 58-63.
GAO X L, ZHANG Q B, GAO Q Y, et al. Numerical simulation on parachute's infinite mass inflation dynamics[J]. Journal of National University of Defense Technology, 2017, 39(3): 58-63. (in Chinese)

[2] PASQUALINI S, JIN Z Y, YANG Z G. Measurement of the flow structures in the wakes of different types of parachute canopies [J]. Acta Mechanica Sinica, 2018, 34(2):

- 225 - 237.
- [3] 徐宏, 曹义华. 降落伞典型开伞过程的试验研究[J]. 飞行力学, 2012, 30(1): 74 - 78.
XU H, CAO Y H. Experimental investigation in typical parachute opening process [J]. Flight Dynamics, 2012, 30(1): 74 - 78. (in Chinese)
- [4] 马晓冬, 郭锐, 刘荣忠, 等. 涡环旋转伞流固耦合特性分析[J]. 国防科技大学学报, 2015, 37(1): 84 - 89.
MA X D, GUO R, LIU R Z, et al. Fluid-structure interaction characteristics analysis of vortex ring parachute[J]. Journal of National University of Defense Technology, 2015, 37(1): 84 - 89. (in Chinese)
- [5] TEZDUYAR T E, BEHR M, MITTAL S, et al. A new strategy for finite element computations involving moving boundaries and interfaces—The deforming-spatial-domain/space-time procedure: II. Computation of free-surface flows, two-liquid flows, and flows with drifting cylinders [J]. Computer Methods in Applied Mechanics and Engineering, 1992, 94(3): 353 - 371.
- [6] TEZDUYAR T E, SATHE S, SCHWAAB M, et al. Fluid-structure interaction modeling of ringsail parachutes [J]. Computational Mechanics, 2008, 43(1): 133 - 142.
- [7] TUTT B, TAYLOR A. The use of LS-DYNA to simulate the inflation of a parachute canopy [C]//Proceedings of the 18th AIAA Aerodynamic Decelerator Systems Technology Conference and Seminar, 2005.
- [8] WOLF D. A simplified dynamic model of parachute inflation[J]. Journal of Aircraft, 1974, 11(1): 28 - 33.
- [9] 荣伟, 陈旭, 陈国良. 低密度大气中降落伞开伞动载的研究[J]. 航天返回与遥感, 2006, 27(4): 7 - 11.
RONG W, CHEN X, CHEN G L. The study of the parachute opening load in low atmospheric density [J]. Spacecraft Recovery & Remote Sensing, 2006, 27(4): 7 - 11. (in Chinese)
- [10] 郭叔伟, 董杨彪, 王海涛, 等. 降落伞充气环境对充气性能的影响[J]. 中国空间科学技术, 2008, 28(6): 45 - 51.
GUO S W, DONG Y B, WANG H T, et al. Influence of inflation conditions parachute inflation [J]. Chinese Space Science and Technology, 2008, 28(6): 45 - 51. (in Chinese)
- [11] SAON G, PICHENY M. Recent advances in conversational speech recognition using convolutional and recurrent neural networks [J]. IBM Journal of Research and Development, 2017, 61(4/5): 1: 1 - 1: 10.
- [12] GRAVES A. Long short-term memory [M]. Berlin: Springer, 2012: 1735 - 1780.
- [13] MA X L, TAO Z M, WANG Y H, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data [J]. Transportation Research Part C: Emerging Technologies, 2015, 54: 187 - 197.
- [14] 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 - 784.
WANG X, WU J, LIU C, 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 - 784. (in Chinese)
- [15] HANSON J, YANG Y D, PALIWAL K, et al. Improving protein disorder prediction by deep bidirectional long short-term memory recurrent neural networks [J]. Bioinformatics, 2016, 33(5): 685 - 692.
- [16] 赵敏, 许家骅, 肖冲. BP 神经网络预测降落伞绸透气性的研究[J]. 产业用纺织品, 2008, 26(8): 22 - 25.
ZHAO M, XU J H, XIAO C. A study of prediction of air permeability of the parachute fabric by BP neural network [J]. Technical Textiles, 2008, 26(8): 22 - 25. (in Chinese)
- [17] ONAL L, ZEYDAN M, KORKMAZ M, et al. Predicting the seam strength of notched webbings for parachute assemblies using the Taguchi's design of experiment and artificial neural networks [J]. Textile Research Journal, 2009, 79(5): 468 - 478.
- [18] 姜添, 戈嗣诚, 李健. RNN 在降落伞开伞特性研究中的应用[J]. 航天返回与遥感, 2019, 40(6): 35 - 43.
JIANG T, GE S C, LI J. Application of RNN in the study of parachute opening characteristics [J]. Spacecraft Recovery & Remote Sensing, 2019, 40(6): 35 - 43. (in Chinese)