

DOI: 10.13382/j.jemi.B2205658

融合小波分解和 LSTM 的目标轨迹预测*

王 江¹ 史元浩¹ 郭正玉² 田煜楷¹ 韩天翔¹ 李孟威¹

(1. 中北大学电气与控制工程学院 太原 030000; 2. 中国空空导弹研究院 洛阳 471009)

摘 要:随着目前空战武器装备的迅猛发展,对于高空高速大机动目标的轨迹预测越来越占据重要的战略地位。为了解决目前存在的目标轨迹预测不足的问题,本文提出了融合小波分解(wavelet decomposition, WD)和长短期记忆(long short term memory, LSTM)网络的模型来对机动目标的轨迹进行预测。首先,通过小波分解将输入的轨迹时间序列分解为 1 个低频分量(CD1)和 3 个高频分量(CA1, CA2, CA3)。然后,利用长短期记忆网络对时间序列处理的优势进行分量预测。最后,将分量预测结果进行重构并与原始轨迹进行对比验证,结果表明所提模型对于轨迹预测具有较高的精确度。为了排除实验结果的偶然性,本文用两组数据进行验证。通过对比实验显示,所提模型与其他两种模型相比预测误差更小。

关键词: 轨迹预测; 循环神经网络; 小波分解; 长短期记忆网络

中图分类号: TN05; TK227 **文献标识码:** A **国家标准学科分类代码:** 470. 20

Target trajectory prediction by fusing wavelet decomposition and LSTM

Wang Jiang¹ Shi Yuanhao¹ Guo Zhengyu² Tian Yukai¹ Han Tianxiang¹ Li Mengwei¹

(1. School of Electrical and Control Engineering, North University of China, Taiyuan 030000, China;

2. China Airborne Missile Academy, Luoyang 471009, China)

Abstract: With the rapid development of current air combat weaponry, trajectory prediction for high-altitude, high-speed, large maneuver targets is occupying an increasingly important strategic position. In order to solve the current problem of insufficient target trajectory prediction, this paper proposes a model integrating wavelet decomposition (WD) and long short term memory (LSTM) network to predict the trajectory of maneuvering targets. First, the input trajectory time series is decomposed into one low frequency component (CD1) and three high frequency components (CA1, CA2, CA3) by wavelet decomposition. Then, the component prediction is performed by taking advantage of the long short term memory network for time series processing. Finally, the component prediction results are reconstructed and compared with the original trajectories for verification, and the results show that the proposed model has high accuracy for trajectory prediction. In order to exclude the chance of experimental results, two sets of data are used for validation in this paper. The comparison experiments show that the proposed model has less prediction error compared with the other two models.

Keywords: trajectory prediction; recurrent neural networks; wavelet decomposition; long short term memory

0 引 言

战场局势瞬息万变,对于空战来说更是如此。近距自主空战是一种动态、竞争激烈的对抗,它要求采用更高的机动速度来实现对目标的截击和锁定,并提供武器射

击要求。由于近距空战状况错综复杂,不能像远程空战那样有充分的时间来制定战术,因此每次机动行动的实施都会对整个空中作战进程产生重要的影响。

对于目标轨迹预测技术,文献[1]针对传统粒子滤波方法存在预测精度低的问题提出了基于 Elman 神经网络的方法对空战目标轨迹进行预测。但是由于 Elman 网

收稿日期: 2022-07-06 Received Date: 2022-07-06

* 基金项目: 国家自然科学基金(72071183)、山西省自然科学基金(201901D111164)、山西省回国留学人员科研项目(2020-114)、中国高校产学研创新基金项目(2019ITA0cxy0023)资助

络训练速度慢且容易陷入局部极小点的缺陷,导致预测模型时效性差且预测误差较大。文献[2]针对行人在移动过程中的不确定性,提出一种基于注意力机制的 LSTM 网络,并将其用于多个特征的融合,实现对行人的轨迹预测。由于将注意力机制引入到预测网络中,增强了对每一时刻的编码矢量的使用,改善了对行人跟踪的预测能力。文献[3]提出了一种结合速度控制的时空图网络算法来建立行人交互模型,提取行人轨迹序列运动特征并且关注其空间上相互作用关系的同时,编码行人序列的时间相关性,并对轨迹进行预测。文献[4]首先对目标的轨迹进行自适应分类,然后运用反向传播(back propagation, BP)神经网络对其进行预测,但 BP 网络结构自身局限性导致预测结果误差较大。文献[5]将多个车灯的轨迹预测与特征相似性相结合,实现了对多个车灯的追踪。文献[6]提出了利用隐马尔科夫模型来进行轨迹预测的方法,将该模型与参数自适应相结合,从而实现了预测区间长度的自动调节。文献[7-9]针对 BP 神经网络的特点,提出了一种利用遗传算法和粒子群优化算法进行求解的方法,实现对目标轨迹的预测。文献[10]为了实现对目标未来位置的预测,可以更好的锁定目标,为导弹的状态调整提出指导,提高命中率,提出了最优引导律和递归最小二乘法相结合的方法。文献[11]针对车辆运行的预计预测问题,提出物理和机动相结合的方法。物理和机动两种方法可以分别保证短期的预测精度和长期洞察未来的轨迹。在基于物理的预测模型中采用无迹卡尔曼滤波器,考虑了预测的不确定性。在基于机动的方法中,利用动态贝叶斯网络将不确定性随机元素引入到每次机动的轨迹中。利用自然驾驶数据,将该方法应用于车辆换道场景。对比结果表明,交互多模型能够在较长的预测期内实现更准确的预测轨迹。文献[12]提出了一种将动力学和灰色系统相结合的轨迹预测方法,采用最小方差估算的参数矢量作为实际值,并将其代入到微分方程中,从而得到轨迹预测值。文献[13]将控制量、增量和输出量的时域限制添加到预测控制器的设计中,同时引入了时间前移的有限时域优化策略,使得每个控制时域的控制行为都能在每个控制时域中获得最佳的结果。文献[14]提出运用卷积神经网络对多个数据集中行人轨迹的预测,实验结果显示卷积神经网络预测相较于其他网络预测所用时长最短。但是相较于 LSTM 网络,预测误差较大。文献[15]通过分析轨迹预测过程中误差产生的原因,提出了一种面向高速大机动目标的基于误差修正的广义回归神经网络预测算法。文献[16]提出一种基于多任务学习模型,将 CNN 与通过注意力机制优化过的双向 LSTM 并联作为训练网络,对船舶的行为识别与轨迹预测两个任务联合训练。选取船舶自动识别系统提供数据基础。通过实验与当前

较为广泛应用的 BP 神经网络和单独训练的方法对比,验证了所提方法的精确性与可靠性。文献[17]在方法上做了改进,在文献[1]的基础上运用优化算法对预测网络的初始参数进行了优化,相比以前的方法进一步减少了预测网络的训练时间而且预测效果也有明显的提升。文献[18]提出了融合小波分解和改进卷积神经网络的方法对水声目标进行识别。文献[19]提出一种基于小波变换和门控循环单元网络的预测模型用于对锂离子电池的剩余使用寿命进行预测,实验结果表明,所提模型具有较高的精确度。文献[18-19]所提的混合模型的预测结果都有较高的准确性,为本文所提方法提供思路。

针对目前高度大机动目标轨迹预测精度方面仍有待提升,且就目前武器装备性能大幅度升级,对目标轨迹预测的精度提出了更高的要求。提前对目标轨迹进行准确的预测,为我方战略机动动作准备提供指导,确保我方安全,具有很高的战略意义。基于以上研究意义,充分利用 WD 和 LSTM 各自的优点,本文提出了 WD-LSTM 的轨迹预测模型。该模型利用 WD 将轨迹时间序列分解为 4 个分量,然后利用 LSTM 对时间序列处理的优势对 4 个分量进行分别预测,最后将预测后的结果进行重构和原始数据进行对比,验证了模型的有效性。

1 算法介绍

1.1 小波分解算法介绍

与固定窗口的傅里叶变换相比,小波分析是利用不同的窗口函数对处理后的信号进行分析,从而在低频下可以得到更高的频率分辨率,在高频上得到更高的时间分辨率。

小波基函数定义为:

$$\begin{cases} W_f(a, b) = \left| \frac{1}{\sqrt{a}} \right| \int_{-\infty}^{+\infty} f(t) \varphi\left(\frac{t-b}{a}\right) dt \\ \varphi_{a,b}(t) = \left| \frac{1}{\sqrt{a}} \right| \varphi\left(\frac{t-b}{a}\right) \end{cases} \quad (1)$$

式中: $\varphi(t)$ 为基小波或者母小波函数,经过尺度因子 a 和平移因子 b 变换后的 $\varphi_{a,b}(t)$ 统称为小波。

对于离散情况:

$$\varphi_{j,k}(t) = 2^{-j/2} \varphi(2^{-j/t} - k) \quad j, k \in Z \quad (2)$$

离散小波变换(discrete wavelet transformation, DWT)将输入的时序信号进行分解,分解后得到的信号按照频段划分,得到一个低频时序信号和一个高频时序信号。因为低频分量与原始信号更为相近因此也称为近似分量,另外一个为高频分量,更好地反映时序信号的细节,所以也称为细节分量。根据实验需要可以进一步对分解得到的低频分量做进一步的分解,本实验对输入的轨迹时间序列进行 3 层小波分解,分解得到 1 个低频分量和 3

个高频分量。

为了简化计算,本文将三维坐标进行拆分,分别对 X 轴、 Y 轴、 Z 轴坐标进行独立的预测。多层小波分解预处理后,将每层重构小波分解系数作为 LSTM 网络的输入,结果如图 1~6 所示。




图 1 X 轴小波分解系数

Fig. 1 X -axis wavelet decomposition coefficient




图 2 X 轴重构小波分解系数

Fig. 2 X -axis reconstruction wavelet decomposition coefficients

图 1~6 依次分别为 X 轴、 Y 轴和 Z 轴的第 3 层分解的小波系数以及重构以后的小波系数图。从图中可以看出分解后的低频分量与原始时间序列信号基本接近。结合图 1 和 2,图 3 和 4,图 5 和 6 比较,小波分解将原始时间序列按照频带划分,能够更好地把握信号的细节,从而有效地提高预测精度,达到预测效果。

1.2 长短期记忆网络(LSTM)

作为深度学习的一个重要分支,循环神经网络(recurrent neural network, RNN)由于其固定的循环结构,可以研究可变长序列。常规 RNN 在处理时间序列方面




图 3 Y 轴小波分解系数

Fig. 3 Y -axis wavelet decomposition coefficient




图 4 Y 轴重构小波分解系数

Fig. 4 Y -axis reconstruction wavelet decomposition coefficient

具有一定的优势,因为它当前的隐藏状态包含了之前所有的输入信息,所以输出会受到历史信息的影响。此外,它还具有隐藏层参数共享的特点。RNN 的数学表达式如式(3)~(4)所示:

$$h_t = \tanh(w_{xh}x_t + w_{hh}h_{t-1} + b) \quad (3)$$

$$y_t = f(w_{hy}h_t + c) \quad (4)$$

其中, w_{xh} 、 w_{hh} 和 w_{hy} 分别是输入到隐藏、隐藏到隐藏和隐藏到输出连接的训练权重,而 b 和 c 是允许每个节点学习偏移量的偏置向量。 x_t 、 h_t 、 y_t 分别是 RNN 的输入、隐藏状态和输出。一般来说,获取当前隐藏层的输出 h_t 过程中的激活函数为 $\tanh$,可以将隐藏层的输出限制在 $[-1, 1]$ 。但是输出 y_t 的激活函数不是固定的,要根据不同的情况来选择。由于梯度爆炸和梯度消失的问题,RNN 仍然很难处理时间序列的长期依赖性问题。LSTM 和门控循环单元(gate recurrent unit, GRU)在传统




图5 Z轴小波分解系数

Fig. 5 Z-axis wavelet decomposition coefficient




图6 Z轴重构小波分解系数

Fig. 6 Z-axis reconstruction wavelet decomposition coefficient

RNN 的基础上增加了门限机制,很好地解决了这个问题。

与 RNN 不同, LSTM 是由 Hochreiter 和 Schmidhuber 提出的,内部结构如图 7 所示。它在 RNN 框架的基础上扩展了 3 个门。每个 LSTM 单元都可以确定所需要丢弃或保留的信息,因此即使是处于早期的重要信息也会被长距离传输保留,而不是被遗忘。这样的独特结构允许 LSTM 挖掘时间序列之间的长期依赖关系。更多的文献表明, LSTM 可以处理数百个长度的时间序列,但常规 RNN 却非常有限。从式(5)~(9)可以看出,输入门、遗忘门和输出门可以从当前输出和上一时刻的隐藏状态计算出来。在每一步中,遗忘门确定过去忘记了哪些信息,输入门确定新添加到单元状态中的信息(从当前输入信息和上一时刻的隐藏状态)。此刻的隐藏状态将由输出门和单元状态决定。

$$i_t = \delta(\mathbf{w}_i \cdot [h_{t-1}, x_t] + \mathbf{b}_i) \quad (5)$$

$$f_t = \delta(\mathbf{w}_f \cdot [h_{t-1}, x_t] + \mathbf{b}_f) \quad (6)$$

$$o_t = \delta(\mathbf{w}_o \cdot [h_{t-1}, x_t] + \mathbf{b}_o) \quad (7)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (8)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tanh(\mathbf{w}_c \cdot [h_{t-1}, x_t] + \mathbf{b}) \quad (9)$$

式中: i_t 是输入门的状态值, o_t 是输出门的状态值, f_t 是遗忘门的状态值。 $\mathbf{b}_i$ 是输入门偏置向量, $\mathbf{b}_o$ 是输出门偏置向量, $\mathbf{b}_f$ 是遗忘门偏置向量, $\mathbf{b}_c$ 是细胞状态偏置向量, $\mathbf{w}_i$ 是输入门权重矩阵, $\mathbf{w}_o$ 是输出门权重矩阵, $\mathbf{w}_f$ 是遗忘门权重矩阵, $\mathbf{w}_c$ 是细胞状态的权重矩阵, c_t 表示当前时刻的单元状态, h_t 表示当前时刻的隐藏状态值, $\delta(\cdot)$ 是门函数。式(5)~(7)分别表示的是输入门、遗忘门和输出门的实现公式,式(8)~(9)是长期状态以及短期状态的更新公式。从上面的公式可以看出, LSTM 由于其巧妙的门限机制设置,不会造成对之前内容的覆盖和重写。




图7 LSTM 内部结构

Fig. 7 LSTM internal structure

在轨迹预测中发挥主要作用的是模型超参数的设置,通过优化超参数不仅可以有效提高预测模型的收敛速度,而且对预测精度也有显著的效果。在本文所提模型中,主要考虑两个重要超参数(隐含层神经元个数和 Epoch 数)对模型的影响。

1.3 小波分解-长短期记忆网络模型

小波分解预处理后,将每层重构小波分解系数作为 LSTM 的输入。由此可以得到小波分解-长短期记忆网络模型框架图如图 8 所示。

2 实例分析

本文将已有的数据集进行小波分解,分解为 4 个分量,分别为 1 个低频分量(CD1)和 3 个高频分量(CA1, CA2, CA3),分别将 4 个分量输入模型单独预测,最后将 4 个预测分量进行重构验证,得到实验结果。本文所利用的实验环境描述如下:硬件环境为 Intel(R) Core(TM) i5-4210 H CPU @ 2.90 GHz 2.90 GHz 4 GB RAM, 64 位操作系统;软件环境为 Python 3.7 中的 Tensorflow 框架。本模型设置预测起点为 500,遍历次数为 100,预测步长




图 8 WD-LSTM 模型框架

Fig. 8 WD-LSTM model framework

为单步预测。预测结果如图 9~11 所示。




图 9 X 轴预测结果

Fig. 9 X-axis prediction results




图 10 Y 轴预测结果

Fig. 10 Y-axis prediction results

预测起始点为 500,从结果图来看,所提模型具有很好的预测效果,为了更加直观的表现模型的有效性,




图 11 Z 轴预测结果

Fig. 11 Z-axis prediction results

表 1~3 给出了不同模型在 RMSE 和 MAPE 下的预测误差。图 12~14 给出对比实验的结果图。式 (10) ~ (11) 给出了 RMSE 和 MAPE 的数学表达式:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (N_{true_i} - N_{predicted_i})^2} \quad (10)$$

$$MAPE = \sum_{i=1}^n \left| \frac{N_{true_i} - N_{predicted_i}}{N_{true_i}} \right| \times \frac{100}{n} \quad (11)$$

其中, N_{true_i} 与 $N_{predicted_i}$ 分别为真实轨迹数据值和预测轨迹数据值。预测误差如表 1~3 所示。

表 1 X 轴预测误差表

Table 1 X-axis prediction error table

	MAPE	RMSE
WD-LSTM	1.297 6	60.869 5
WD-BP	2.669 0	121.850 7
WD-RVM	4.722 4	243.823 9

表 2 Y 轴预测误差表

Table 2 Y-axis prediction error table

	MAPE	RMSE
WD-LSTM	0.702 7	21.874 1
WD-BP	3.134 0	89.504 1
WD-RVM	10.689 0	308.498 1

表 3 Z 轴预测误差表

Table 3 Z-axis prediction error table

	MAPE	RMSE
WD-LSTM	0.411 8	52.472 6
WD-BP	1.039 7	127.078 1
WD-RVM	7.511 5	1.024 5×10 ³

从对比实验结果图可以看出 WD-LSTM 模型的预测结果与真实值轨迹更加贴近,在单步预测结果上对比 BP 以及 RVM 两种方法具有最好的预测效果,同时通过表




图 12 X 轴对比实验结果

Fig. 12 X-axis comparison experiment results




图 13 Y 轴对比实验结果

Fig. 13 Y-axis comparison experiment results




图 14 Z 轴对比实验结果

Fig. 14 Z-axis comparison experiment results

排除实验结果的偶然性,本文增加一组数据做相同的实验,预测结果以及预测误差分别如图 15~17 和表 4~6 所示。实验结果表明,对于不同的数据集所提模型具有很好的普适性,本文所提模型的效果依然是最好的,验证了所提模型的有效性。




图 15 X 轴对比实验结果

Fig. 15 X-axis comparison experiment results




图 16 Y 轴对比实验结果

Fig. 16 Y-axis comparison experiment results




图 17 Z 轴对比实验结果

Fig. 17 Z-axis comparison experiment results

1~3 误差结果来看,WD-LSTM 模型的误差相对与 BP 和 RVM 误差最小,以此可以验证所提模型的有效性。为了

表 4 X 轴预测误差表
Table 4 X-axis prediction error table

	MAPE	RMSE
WD-LSTM	0.017 9	5.667 2
WD-BP	0.018 3	5.682 5
WD-RVM	0.091 4	26.843 4

表 5 Y 轴预测误差表
Table 5 Y-axis prediction error table

	MAPE	RMSE
WD-LSTM	0.068 7	5.089 1
WD-BP	0.561 0	41.412 5
WD-RVM	9.776 9	709.013 2

表 6 Z 轴预测误差表
Table 6 Z-axis prediction error table

	MAPE	RMSE
WD-LSTM	0.006 9	0.325 0
WD-BP	0.021 7	1.019 3
WD-RVM	0.089 9	3.929 4

3 结 论

本文针对目前大机动目标轨迹预测方案欠佳,提出融合 WD-LSTM 目标轨迹预测模型。将三维坐标分离单独进行预测。为了验证模型的可行性,结合已有数据集,利用该模型对数据集进行训练集和测试集的划分并进行有限步长的预测,得到预测结果。最后本文还对常用的两种方法进行对比,进对比发现所提模型具有较高的精度。为了验证模型的普适性,增加一组实验数据用所提模型进行相同的实验,实验结果表明,所提模型对不同的数据集预测精度依然是最高的,证明了所提模型的有效性。

参考文献

[1] 张涛,郭基联,徐西蒙,等. 基于 Elman 神经网络的战斗机空战轨迹预测[J]. 飞行力学, 2018, 36(5): 86-91.
ZHANG T, GUO J L, XU X M, et al. Prediction of fighter air combat trajectory based on Elman neural network[J]. Flight Mechanics, 2018, 36(5): 86-91.

[2] 曹昊天,施惠杰,宋晓琳,等. 基于多特征融合的行人意图以及行人轨迹预测方法研究[J]. 中国公路学报, 2022,35(10):308-318.
CAO H T, SHI H J, SONG X L, et al. Research on pedestrian intention and pedestrian trajectory prediction method based on multi-feature fusion [J]. Chinese Journal of Highways,2022,35(10):308-318.

[3] 王海峰,桑海峰,王玉,等. 结合速度控制的时空图网络行人轨迹预测模型[J]. 电子测量与仪器学报, 2022,36(5):146-154.
WANG H F, SANG H F, WANG J Y, et al. A pedestrian trajectory prediction model combined with speed control in space-time graph network[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(5):146-154.

[4] 钱夔,周颖,杨柳静,等. 基于 BP 神经网络的空中目标航迹预测模型[J]. 指挥信息系统与技术,2017,8(3): 54-58.
QIAN K, ZHOU Y, YANG L J, et al. Air target track prediction model based on BP neural network [J]. Command Information System and Technology, 2017, 8(3): 54-58.

[5] 苏金亚,张伟伟,吴训成,等. 基于多结构特征提取和轨迹跟踪的车辆远光识别[J]. 电子测量与仪器学报, 2018,32(10):103-110.
SU J Y, ZHANG W W, WU X CH, et al. Vehicle high beam recognition based on multi-structure feature extraction and trajectory tracking [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(10):103-110.

[6] QIAO S J, SHEN D Y, WANG X T, et al. A self-adaptive parameter selection trajectory prediction approach via hidden Markov models [J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16 (1): 284-296.

[7] 谭伟,陆百川,黄美灵. 神经网络结合遗传算法用于航迹预测[J]. 重庆交通大学学报(自然科学版),2010, 29(1): 147-150.
TAN W, LU B CH, HUANG M L. Neural network combined with genetic algorithm for track prediction[J]. Journal of Chongqing Jiaotong University (Natural Science Edition), 2010, 29(1): 147-150.

[8] 甘旭升,端木京顺,孟月波,等. 基于粒子群优化的 WNN 飞行数据气动力建模[J]. 航空学报,2012, 33(7): 1209-1217.
GAN X SH, DUANMU J SH, MENG Y B, et al. Aerodynamic modeling of WNN flight data based on particle swarm optimization [J]. Chinese Journal of Aeronautics, 2012, 33(7): 1209-1217.

[9] WU Z J, TIAN S, MA L. A 4D trajectory prediction model based on the BP neural network[J]. Journal of Intelligent Systems,2019,29(1):1545-1557.

[10] AKCAL M U, URE N K, YANG C G, et al. Predictive missile guidance with online trajectory learning [J]. Defence Science Journal,2017,67(3): 332-338.

- [11] XIE G, GAO H, QIAN L, et al. Vehicle trajectory prediction by integrating physics - and maneuver-based approaches using interactive multiple models[J]. IEEE Transactions on Industrial Electronics, 2017, 65(7): 5999-6008.
- [12] WANG Q Y, ZHANG Z L, WANG Z Y, et al. The trajectory prediction of spacecraft by grey method[J]. Measurement Science and Technology, 2016, 27(8): 085011.
- [13] 张丽珍, 顾素郡, 吴迪. 基于改进的投饵船模型预测轨迹跟踪控制[J]. 制造业自动化, 2021, 43(10): 68-74.
- ZHANG L ZH, GU S J, WU D. Predictive trajectory tracking control based on an improved bait-casting ship model [J]. Manufacturing Automation, 2021, 43(10): 68-74.
- [14] NIKHIL N, MORRIS B T. Convolutional neural network for trajectory prediction[C]. Proceedings of ECCV 2018 Workshops. Switzerland: Springer, 2019: 186-196.
- [15] 杨彬, 贺正洪. 一种 GRNN 神经网络的高超声速飞行器轨迹预测方法[J]. 计算机应用与软件, 2015, 32(7): 239-243.
- YANG B, HE ZH H. A hypersonic vehicle trajectory prediction method based on GRNN neural network[J]. Computer Applications and Software, 2015, 32(7): 239-243.
- [16] 杨红, 韩鹏, 刘畅, 等. 基于多任务学习的船舶行为识别与轨迹预测[J]. 重庆交通大学学报(自然科学版), 2022, 41(4): 1-7.
- YANG H, HAN P, LIU CH, et al. Ship behavior recognition and trajectory prediction based on multi-task learning [J]. Journal of Chongqing Jiaotong University (Natural Science Edition), 2022, 41(4): 1-7.
- [17] 王新, 杨任农, 左家亮, 等. 基于 HPSO-TPFENN 的目标机轨迹预测[J]. 西北工业大学学报, 2019, 37(3): 613-620.
- WANG X, YANG R N, ZUO J L, et al. Target machine trajectory prediction based on HPSO-TPFENN [J]. Journal of Northwestern Polytechnical University, 2019, 37(3): 613-620.
- [18] 黄擎, 曾向阳. 小波分解和改进卷积神经网络相融合的水声目标识别方法[J]. 哈尔滨工程大学学报, 2022, 43(2): 159-165.
- HUANG Q, ZENG X Y. Underwater acoustic target recognition method fusion of wavelet decomposition and improved convolutional neural network [J]. Journal of Harbin Engineering University, 2022, 43(2): 159-165.
- [19] 邢子轩, 张凡, 武明虎, 等. 基于 WD-GRU 的锂离子电池剩余寿命预测[J]. 电源技术, 2022, 46(8): 867-871.
- XING Z X, ZHANG F, WU M H, et al. Remaining life prediction of lithium-ion battery based on WD-GRU[J]. Power Technology, 2022, 46(8): 867-871.

作者简介



王江, 2019 年于厦门理工学院获得学士学位, 现为中北大学硕士研究生, 主要研究方向是复杂系统的故障预测与健康管。E-mail: 953590771@qq.com

Wang Jiang received his B. Sc. degree from Xiamen University of Technology in 2019.

Now he is a M. Sc. candidate at North University of China. His main research interests include prognostics and health management.