

doi: 10.7690/bgzd.2021.08.001

基于 EMD 和 LSTM 的火箭炮电气系统状态预测

张建新, 李永保, 谢立中, 张震, 王小召

(湖北江山重工有限责任公司火箭炮研究院, 湖北 襄阳 441057)

摘要: 为对火箭炮电气系统状态进行预测, 提出一种基于 EMD-LSTM 的火箭炮电气系统状态数据预测方法。针对火箭炮电气系统状态数据的变化特点, 将经验模态分解(empirical mode decomposition, EMD)良好的滤波特性和长短期记忆网络(long short term memory network, LSTM)优异的数据预测能力相结合, 并进行预测分析实验。实验结果表明: 该方法预测的数据与原始数据之间的均方根误差值较小, 且优于直接对原始数据进行预测的结果, 能为火箭炮电气系统故障预测提供可靠的数据。

关键词: 火箭炮; 电气系统; 数据预测; 经验模态分解; 长短期记忆网络; 均方根误差

中图分类号: TJ393 **文献标志码:** A

State Prediction of Rocket Launcher Electrical System Based on EMD and LSTM

Zhang Jianxin, Li Yongbao, Xie Lizhong, Zhang Zhen, Wang Xiaozhao

(Rocket Launcher Institute, Hubei Jiangshan Heavy Industry Co., Ltd., Xiangyang 441057, China)

Abstract: In order to predict the state of the rocket launcher electrical system, this paper proposes a data prediction method based on EMD-LSTM. Aiming at the changing characteristics of the state data of the rocket launcher electrical system, empirical mode decomposition (EMD) and long short term memory network (LSTM) are combined, and predictive analysis experiments are performed. The experimental results show that the root mean square error between the data predicted by this method and the original data is smaller, and it is better than the result of direct prediction of the original data, so it can provide reliable data for the rocket launcher electrical system failure prediction.

Keywords: rocket launcher; electrical system; data prediction; EMD; LSTM; RMSE

0 引言

火箭炮在战争中起到了远程火力打击压制的重要作用, 能够对敌方的中远程武装力量进行有效火力覆盖, 同时也可通过发射不同弹种进行进攻掩护, 对火箭炮自动化和信息化程度的要求也越来越高。随着科学技术的发展, 大规模电路在火箭炮中得到应用, 提高了火箭炮的打击精度和信息获取能力, 但其电气系统结构也日趋复杂, 增加了发生故障的概率; 因此, 火箭炮电气系统的故障预测成为重要的研究课题。

目前, 基于数据的故障预测技术是较为实用且应用较为广泛的故障预测技术^[1], 根据输入数据对应的模型输出数据与实际数据之间的关系建立输入和输出的实际映射, 从而实现故障预测。长短期记忆网络(LSTM)是一种改进后的循环神经网络(recurrent neural networks, RNN), 解决了RNN无法处理长距离的问题, 是目前较为流行的数据预测网络, 能根据前数据有效地预测后数据, 其优异的

数据预测能力得到了广泛应用^[2-7], 在故障预测领域也得到了较好应用^[8]。EMD是一种依据数据自身的时间尺度特征对非平稳、非线性信号进行有效时频分解的方法^[9], 能将复杂信号分解为有限个本征模态函数(intrinsic mode function, IMF), 分解出的不同IMF分量包含了原信号在不同时间尺度的局部特征信号, 对各IMF进行组合可得到高通、低通和带通滤波器以消除噪声或进行特定分析^[10-12]。

针对火箭炮电气系统工作过程和状态变化的特点, 笔者提出了一种基于EMD-LSTM的火箭炮故障预测方法, 建立了火箭炮电气系统故障预测模型。实验结果验证了该方法能较准确地预测火箭炮电气系统的状态变化趋势。

1 电气系统状态特征

按照故障的形成过程, 可将故障分为渐进性故障和偶然性故障。渐进性故障的形成过程缓慢且具有一定规律性, 可以预测。偶然性故障具有突发性,

收稿日期: 2021-04-20; 修回日期: 2021-05-25

基金项目: 装备预研兵器工业联合基金(6141B012102)

作者简介: 张建新(1980—), 男, 湖北人, 硕士, 研究员级高工, 从事火箭炮发射控制及故障预测研究。E-mail: xin5137@126.com。

没有规律可循，不可预测^[13]。

通过对历史故障数据的统计分析，得到了电气系统故障原因分布如图 1 所示。电气系统故障的主要原因有器件损坏、连接线路损坏、安装松动和参数设置偏差等，其中器件损坏和连接线路损坏数量最多，分别占总数的 48.42% 和 32.11%。




图 1 火箭炮电气系统故障原因分布

火箭炮电气系统的器件损坏主要是指电子器件的损坏，包括电阻、电容、继电器和集成电路板等，其中大多数是由器件的自然老化形成，属于渐进性故障；极少数属于使用不当和外力破坏等其他因素造成，属于偶然性故障。连接线路损坏的主要模式有接插件接触不良、焊点脱落和线缆损坏等，主要原因是火箭炮行军和战斗过程中的振动、冲击及环境因素的侵蚀、破坏等，其过程是渐进性的；因此，火箭炮电气系统的状态多数情况下是可预测的。

在火箭炮战斗过程中，电气系统的工作时间较短，通常只有几分钟甚至更短，很难在一次工作过程中找出其状态表征量的变化规律；因此，对电气系统状态预测需综合多次工作过程中的数据进行综合判断。同时，火箭炮电气系统状态受多重不稳定因素的影响，包括温度、湿度、沙尘、盐雾和电磁波等环境因素，行军及战斗过程中振动、冲击和烧蚀等过程因素，贮存条件、维护保养周期及程度等人为因素，在不同的任务过程中其状态表征量具有较大波动。对其状态的预测是对由系统自身内在因素变化引起的总体变化趋势的预测。为减轻外在因素引起的波动对预测结果的影响，需要依赖较多的历史状态。

除了上述环境因素、过程因素和人为因素引起的波动外，电气系统的状态表征量及其采集过程还会引入噪声，包括器件间的干扰、传感器噪声和环境噪声等。为更精确地对电气系统状态变化趋势进行预测，需要对传感器采集到的状态表征量的时间序列数据进行滤波和平滑处理。

2 状态预测模型

2.1 经验模态分解

EMD 方法适用于线性和非线性、平稳和非平稳的信号分析，比其他时频分析方法能更好地反映线

性平稳信号的物理意义。EMD 方法在理论上可应用于任何类型信号的分解，能够将原始信号 $x(t)$ 分解成有限个 IMF 和一个残余分量 r ，这些 IMF 分量包含了原始信号在不同时间尺度的局部特征信号，通过对 IMF 分量进行分析可对原始信号进行特征提取或滤波处理。EMD 的信号分解步骤如图 2 所示。

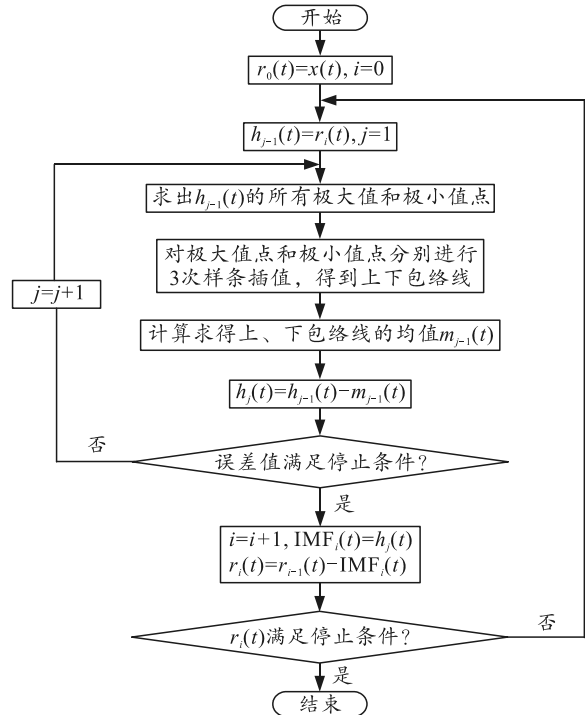


图 2 EMD 信号分解步骤

上图中的误差值 $h_j(t)$ 成为 IMF 分量需满足以下 2 个条件：整个 $h_j(t)$ 分量信号上，极值点和过零点个数相差不大于 1；整个 $h_j(t)$ 分量信号上，任意一点的上下包络线的均值为 0；但在实际的 EMD 分解中，上、下包络线的均值 $m(t)$ 很难满足任意一点的上下包络线的均值为 0 的条件，因此，对 $h_j(t)$ 做出以下判断近似于满足条件，令

$$SD = \frac{\sum [h_j(t) - h_{(j-1)}(t)]^2}{\sum [h_{(j-1)}(t)]^2} \quad (1)$$

若 SD 大于门限值 M ，则表示 $h_j(t)$ 不满足条件 2；否则，则表示 $h_j(t)$ 满足条件 2。

EMD 对信号的分解过程是否完成需对 $r_i(t)$ 进行判断，若 $r_i(t)$ 为单调函数或没有更多的单调函数可以提取，则判定 EMD 分解结束；否则将继续进行分解。经过 n 次重复后得到 $r_n(t)$ ，将 $r_n(t)$ 作为整个分解的残余分量。

分解后的原始信号表达式为：

$$x(t) = \sum_{i=1}^n IMF_i(t) + r_n(t) \quad (2)$$

2.2 长短期记忆网络

RNN 能够利用跨时间梯度反向传播算法(back propagation through time, BPTT)对网络参数进行迭代更新,但对长期依赖问题进行学习时,存在梯度消失和发散等问题,需针对以上问题来设计 LSTM。标准 RNN 的重复结构模块只有一个,且结构简单,而 LSTM 的结构模块有多个,且以一种独特的方式进行交互。

LSTM 通过在整个循环周期内定义和维护神经元状态来建立整个网络的时间连接,通过输入门(input gate)、遗忘门(forget gate)和输出门(output gate)实现神经元状态信息的保护和控制,其神经元内部结构如图 3 所示。




图 3 LSTM 神经元内部结构

1) 遗忘门。

当上一个神经元输出和当前神经元输入进入当前神经元时,需对上一个神经元状态中的信息进行筛选,遗忘门能通过一个 sigmoid 函数给出一组 0~1 的数值对神经元状态信息进行筛选,其中数值的大小代表对应信息的保留程度:1 代表完全保留,0 表示完全舍弃其计算过程,如式(3)所示。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

2) 输入门。

根据上一个神经元输出和当前神经元输入来决定有多少信息可加入到神经元状态中,实现这个过程先利用 tanh 层得到新的候选神经元信息,再通过 sigmoid 层来筛选新的候选神经元信息,其计算过程如式(4)和式(5)所示。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (5)$$

通过遗忘门和输出门便可对上一个神经元状态信息进行更新,得到新的神经元状态,其计算过程如式(6)所示。

$$C_t = f_t \cdot C_{t-1} + i_t \tilde{C}_t \quad (6)$$

3) 输出门。

根据上一个神经元输出、当前神经元输入和已更新过的神经元状态信息来决定当前神经元的哪些

状态特征可以输出,实现此过程同样需要一个 tanh 层对当前神经元状态信息进行处理得到-1~1 之间的向量,用该向量与 sigmoid 层的判断条件相乘得到当前神经元的输出,其计算过程如式(7)和式(8)所示。

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

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

式(3)~(8)中: C_{t-1} 、 C_t 、 \tilde{C}_t 分别表示上一神经元状态、当前神经元状态和备选状态; x_t 表示当前神经元输入; h_{t-1} 、 h_t 分别表示上一神经元和当前神经元的输出; W 和 b 分别为遗忘门、输入门和输出门的权重系数矩阵和偏置; f_t 、 i_t 、 o_t 分别为遗忘门、输入门和输出门; σ 和 \tanh 分别为 sigmoid 函数和双曲正切激活函数。

2.3 预测模型及模型评价指标

为排除状态表征量数据的波动和噪声对预测结果的影响,首先基于 EMD 对原始数据进行滤波平滑处理,然后利用 LSTM 进行预测。笔者构建的火箭炮电气系统状态预测模型如图 4 所示。

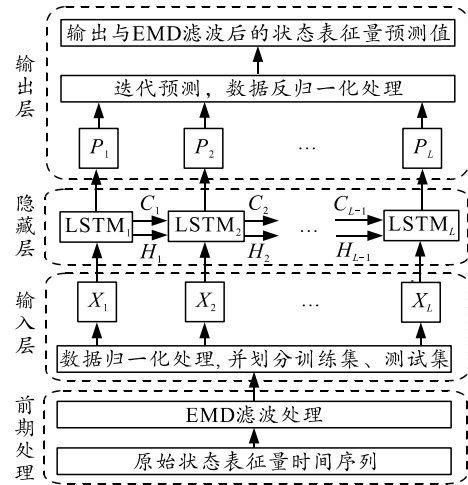


图 4 EMD-LSTM 预测模型

为评价滤波效果和预测精度,利用均方根误差(root mean square error, RMSE)作为 EMD 滤波和 LSTM 预测的评判标准:

$$RMSE = \sqrt{\sum_{t=1}^T (m_t - n_t)^2 / T} \quad (9)$$

式中:对于 EMD 滤波, m_t 是滤波后的值, n_t 是实际值, T 是所有值的个数;对于 LSTM 预测, m_t 是预测值, n_t 是实际值, T 是预测长度。

3 预测分析实验

随着使用时间的增加,电子器件的固有物理参

数逐渐劣化，造成功能输出偏离设计指标达到一定程度而引起系统故障。电子器件的功能输出通常可以表征其健康状态，如输出电压、输出电流、脉冲宽度和接触电阻等。

以某型火箭炮电气系统中的配电箱为例，进行故障预测。配电箱负责各个部件的供电工作，若配电箱出现故障将造成整个系统处于瘫痪状态。电阻分压电路应用较为广泛，随着使用次数的增多和环境的影响，其分压电阻的阻值可能会发生变化，造成电压和电流大小偏离正常使用的状态，导致系统故障。

利用高温、低温、盐雾和振动等试验环境模拟恶劣的使用条件，对配电箱进行反复试验。如图 5 所示，以 100 次通断为一个周期进行数据采集，共得到 500 组数据，将所有数据按照采集时间进行排序。




图 5 测试点电压值

3.1 EMD 滤波处理

为得到测试点电压的变化趋势，采用 EMD 对原始电压数据进行滤波处理，经验模态分解能将信号从高频到低频逐次进行分解，可将测试点电压值的噪声滤除。

为减轻电压值中白噪声的影响，分解前先成对添加 20 组符号相反的白噪声，再分别进行 EMD 分解，将所有添加白噪声的电压值波形进行分解得到各阶 IMF，求取所有同阶 IMF 的平均值，得到原始电压值的 EMD 分解如图 6 所示。





图 6 测试点电压值 EMD 分解结果

由上图可以看出，EMD 分解共得到 5 个 IMF 分量和一个残余分量 RS_6 。除了 IMF_1 的波动频次较高，其他分量变化均较平缓，因此将 IMF_1 去除，最终得到滤波后的电压值：

$$x(t) = \sum_{i=2}^5 IMF_i(t) + RS_6(t) \tag{10}$$

滤波后的电压值波形如图 7 所示，且滤波信号与原始信号的 RMSE 值为 0.09，RMSE 值较小，表明 EMD 对于电压值的滤波效果较好。




图 7 EMD 滤波后的电压值曲线

3.2 LSTM 预测结果分析

选择滤波时间序列的后 150 个电压数据作为训练测试数据，并将 150 个数据按顺序分成 30 段，每段 5 个，抽取每段数据的第 i 个数据按顺序排列重构一组数据，共得到 5 组新数据，且每组数据有 30 个等采样间隔的电压值数据。

将前 4 组数据作为训练数据，对 LSTM 预测模型进行训练，学习率为 0.01，迭代次数为 500。将第 5 组数据作为测试数据，对训练后的 LSTM 预测模型进行测试，得到预测数据。


为更好地说明 EMD 滤波对数据预测产生的影响，采用 2 种数据预测方法对原始数据进行预测：

- 1) 利用 LSTM 预测模型对原始数据直接进行预测；
- 2) 利用本文中所述的 EMD-LSTM 预测模型，先用 EMD 对原始数据进行滤波处理，再利用 LSTM 对


滤波后的数据进行预测。

分别用以上 2 种方法对 2 种数据形式进行训练和预测：第 1 种数据形式是将每组数据中的 30 个电压值数据中的前 25 个数据作为训练模型的输入数据，后 5 个数据作为训练模型的输出数据；第 2 种数据形式是将每组数据中的 30 个电压值数据中的前 20 个数据作为训练模型的输入数据，后 10 个数据作为训练模型的输出数据。预测模型中，模型的输入和输出分别与每种数据形式的输入输出相对应，且预测模型的隐藏层个数为 1，隐藏层神经元个数为 40。

各数据预测结果如图 8 所示。



(a) 第 1 种数据形式与 2 种预测结果



(b) 第 2 种数据形式与 2 种预测结果

图 8 2 种预测方法的预测结果

2 种数据形式的 2 种预测结果 RMSE 值如表 1 所示。

表 1 2 种预测方法的 RMSE 值

数据形式	LSTM 预测 RMSE 值	EMD-LSTM 预测 RMSE 值
第一种数据形式	0.316 5	0.211 8
第二种数据形式	0.242 4	0.154 2

通过对各预测数据与原始数据之间的 RMSE 值进行对比，可以发现：由于受到所处环境、操作过程等因素的影响，采集点的电压值波动较大，若直接用 LSTM 对原始信号进行测试时，原始信号中的不确定因素将会被放大，预测值与原始数据有较大偏差；而对经过 EMD 滤波后的数据进行预测，其预测值与原始信号的拟合度更高，更能保障数据预测的准确性。

4 结论

预测分析实验结果表明：基于 EMD-LSTM 方法的预测值和原始值之间的 RMSE 值较小，验证了该方法对于火箭炮电气系统状态数据预测的有效性，且其 RMSE 值小于基于 LSTM 方法的 RMSE 值，表明了该方法的预测数据与原始数据之间的拟合度更高，能够为火箭炮电气系统的故障预测提供可靠的数据支撑。

参考文献：

- [1] 王亮, 吕卫民, 滕克难, 等. 基于数据驱动的装备故障预测技术研究[J]. 计算机测量与控制, 2013, 21(8): 2087-2089, 2105.
- [2] 任君, 王建华, 王传美, 等. 基于正则化 LSTM 模型的股票指数预测[J]. 计算机应用与软件, 2018, 35(4): 44-48, 108.
- [3] 龙奥明, 毕秀春, 张曙光, 等. 基于 LSTM 神经网络的黑色金属期货套利策略模型[J]. 中国科学技术大学学报, 2018, 48(2): 125-132.
- [4] 舒帆, 屈丹, 张文林, 等. 采用长短时记忆网络的底资源语音识别方法[J]. 西安交通大学学报, 2017, 51(10): 120-127.
- [5] 王旭东, 严珂, 路慧娟, 等. LSTM 的单变量短期家庭电力需求预测[J]. 中国计量大学学报, 2018, 29(2): 142-148.
- [6] 王海涛, 宋文, 王辉. 一种基于 LSTM 和 CNN 混合模型的文本分类方法[J]. 小型微型计算机系统, 2020, 41(6): 1163-1168.
- [7] 李相俊, 许格健. 基于长短期记忆神经网络的风力发电功率预测方法[J]. 发电技术, 2019, 40(5): 426-433.
- [8] 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.
- [9] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceeding A, 1998, 454(1971): 903-995.
- [10] 庞维建, 马海龙, 朱益军, 等. EMD 滤波在煤矿电动机故障诊断中的应用[J]. 工矿自动化, 2015, 41(3): 93-95.
- [11] 杨璐, 李醒飞, 纪越, 等. 基于 EMD-DFA-NLM 的电涡流传感器信号去噪方法[J]. 传感技术学报, 2019, 32(9): 1318-1323.
- [12] 陈强强, 戴邵武, 戴洪德, 等. 基于 IMF 特征提取的滚动轴承故障诊断[J]. 噪声与振动控制, 2020, 40(1): 46-50.
- [13] 秦俊奇. 大口径火炮故障分析与故障预测技术研究[D]. 南京: 南京理工大学, 2005: 36-37.