

4-16-2020

Fault Diagnosis Method of Vehicle Power Supply Based on Deep Learning and Sequential Test

Li Wei

1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;;2. Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou University of Technology, Lanzhou 730050, China;;3. National Demonstration Center for Experimental Electrical and Control Engineering Education, Lanzhou University of Technology, Lanzhou 730050, China;

Bingxiang Zhou

1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;;2. Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou University of Technology, Lanzhou 730050, China;;3. National Demonstration Center for Experimental Electrical and Control Engineering Education, Lanzhou University of Technology, Lanzhou 730050, China;

Dongnian Jiang

1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;;2. Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou University of Technology, Lanzhou 730050, China;;3. National Demonstration Center for Experimental Electrical and Control Engineering Education, Lanzhou University of Technology, Lanzhou 730050, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Fault Diagnosis Method of Vehicle Power Supply Based on Deep Learning and Sequential Test

Abstract

Abstract: Focus on the health maintenance of vehicle power supply, a *fault diagnosis method of vehicle power supply is proposed, which is based on the long and short time memory LSTM(Long Short Time Memory) network and the sequential probability ratio test SPRT(Sequential Probability Ratio Test). Based on the LSTM network, the multivariate time series model of vehicle power supply is established, and the SPRT method is used to perform the adaptive multi-sample fault diagnosis.* The experiment on the vehicle power supply simulation system shows that the LSTM diagnosis model has stronger learning and mapping capabilities, and the fault diagnosis method based on the LSTM-SPRT fusion significantly improves the accuracy and reliability of the vehicle power supply fault diagnosis.

Keywords

long short-time memory network, sequential probability ratio test, vehicle power supply simulation system, fault diagnosis

Recommended Citation

Li Wei, Zhou Bingxiang, Jiang Dongnian. Fault Diagnosis Method of Vehicle Power Supply Based on Deep Learning and Sequential Test[J]. Journal of System Simulation, 2020, 32(4): 638-648.

基于深度学习序贯检验的电源车故障诊断方法

李炜^{1,2,3}, 周丙相^{1,2,3}, 蒋栋年^{1,2,3}

(1. 兰州理工大学电气工程与信息工程学院, 甘肃 兰州 730050; 2. 甘肃省工业过程先进控制重点实验室, 甘肃 兰州 730050;
3. 兰州理工大学电气与控制工程国家级实验教学示范中心, 甘肃 兰州 730050)

摘要: 针对电源车健康维护存在的问题, 提出了一种基于长短时间记忆 LSTM (Long Short Time Memory) 网络与序贯概率比检验 SPRT (Sequential Probability Ratio Test) 融合的电源车故障诊断方法。该方法基于 LSTM 网络建立电源车的多变量时间序列模型, 并引入 SPRT 方法进行自适应多样本故障诊断。经在电源车仿真系统上进行对比实验, 结果表明 LSTM 诊断模型有更强的学习和映射能力, LSTM-SPRT 融合的故障诊断方法, 显著提高了电源车故障诊断的准确率和可靠性。

关键词: 长短时间记忆网络; 序贯概率比检验; 电源车仿真系统; 故障诊断

中图分类号: TP391.9; TP277 文献标识码: A 文章编号: 1004-731X (2020) 04-0638-11

DOI: 10.16182/j.issn1004731x.joss.18-0288

Fault Diagnosis Method of Vehicle Power Supply Based on Deep Learning and Sequential Test

Li Wei^{1,2,3}, Zhou Bingxiang^{1,2,3}, Jiang Dongnian^{1,2,3}

(1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China; 2. Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou University of Technology, Lanzhou 730050, China; 3. National Demonstration Center for Experimental Electrical and Control Engineering Education, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: Focus on the health maintenance of vehicle power supply, a fault diagnosis method of vehicle power supply is proposed, which is based on the long and short time memory LSTM (Long Short Time Memory) network and the sequential probability ratio test SPRT (Sequential Probability Ratio Test). Based on the LSTM network, the multivariate time series model of vehicle power supply is established, and the SPRT method is used to perform the adaptive multi-sample fault diagnosis. The experiment on the vehicle power supply simulation system shows that the LSTM diagnosis model has stronger learning and mapping capabilities, and the fault diagnosis method based on the LSTM-SPRT fusion significantly improves the accuracy and reliability of the vehicle power supply fault diagnosis.

Keywords: long short-time memory network; sequential probability ratio test; vehicle power supply simulation system; fault diagnosis

引言

复杂装备有 3 点突出特征: 一是整个系统由众



收稿日期: 2018-05-15 修回日期: 2018-09-05;
基金项目: 国家自然科学基金(61763027), 甘肃省自然科学基金(1610RJTA022);
作者简介: 李炜(1963-), 女, 陕西西安, 硕士, 教授, 博导, 研究方向为动态系统故障诊断与容错控制; 周丙相(1992-), 男, 贵州盘州, 硕士生, 研究方向为动态系统故障诊断与可靠性评估。

多相互关联、相互耦合的复杂设备组成, 这些设备往往兼备机械和电气双重特性, 具有明显的不确定性和非线性特征; 二是设备之间的退化规律、故障机理也不尽相同, 难以建立精确的物理模型; 三是多设备集成的系统难以获取必要的故障先验知识。这都使复杂装备系统的故障检测、定位、隔离变得极为困难^[1]。

<http://www.china-simulation.com>

然而, 得益于信息技术的快速发展, 目前, 伴随着生产设备的升级和管理模式的转变, 多数企业每天都产生和存储较多运行设备及过程的状态数据, 使得数据驱动的故障诊断方法犹如雨后春笋般成长迅猛。传统的数据驱动故障诊断一般包括基于信号处理的方法、基于多变量统计的方法以及基于知识的方法^[2]。上述故障诊断方法不需要建立精确的机理模型, 但对已知的设备故障机理和低数据维度依赖性较高, 对于结构单一的设备, 此类方法通常较为有效, 当系统耦合度高、故障机理复杂、且数据量大时往往显得力不从心^[3]。

基于知识的经典神经网络因其具有较强的非线性映射能力, 被广泛应用于故障诊断领域^[4], 而且与其它技术结合的改进方法层出不穷^[5-6]。但浅层神经网络难以有效地表征被测信号与装备运行状况之间复杂的映射关系^[7]。自 2006 年 Hinton 等提出了“深度信念网络”的概念以来, 深度学习已经在图像处理、语音识别、自然语言处理等领域得到了广泛的应用, 并取得了丰硕的研究成果^[8-10]。可见, 深度学习模型具备显著的复杂问题处理能力。

深度学习在故障诊断领域的应用也如雨后春笋, 学者们利用深度神经网络强大的特征提取能力自动提取故障特征, 从而进行故障诊断, 克服了人工提取故障特征的困难。典型的深度学习模型框架包括深度信念网络(DBN)、卷积神经网络(CNN)、堆叠自编码器(SAE)、递归神经网络(RNN)^[11], 基于上述模型的故障诊断方法被陆续提出^[12-16]。

从目前的研究成果来看, 基于典型深度学习模型的故障诊断方法大多只考虑样本数据在空间域上的依赖, 而忽略了时间域或样本数据前后的关联性, 这种做法显然不符合故障演变的实际规律。复杂系统的故障往往具有潜在性和连带性, 因此应从时间和空间双重域上充分提取故障特征进行故障诊断^[17]; RNN 模型虽考虑了样本在时域的关联性, 但其记忆能力非常有限, 难以提取数据之间的长期依赖特征。LSTM 网络是 RNN 的一种变种, 其通过在网络结构中引入记忆细胞单元, 可学习样本

长期的时序依赖特性, 该模型常见于自然语言处理、动作识别与预测等相关领域的研究中^[18]。基于 LSTM 网络的故障诊断方法研究虽已初见端倪^[19-22], 但研究成果仍采用单样本进行故障分类, 其诊断可靠性有待提高。

基于此, 考虑电源车系统的强耦合性、故障机理的复杂性以及先验知识的匮乏性, 本文提出了一种基于 LSTM 多变量时间序列模型与序贯概率比检验结合的电源车故障诊断方法。

1 电源车故障诊断方法提出

由于电源车模块之间存在较强的耦合性, 其故障具有继发性和连带性等特点, 经典的深度学习模型如 DBN 等难以表征此类特性; 同时, 电源车的状态数据采集和存储具备时间序列的特征, 应用具有长期记忆能力的 LSTM 网络建立电源车多变量时间序列模型更符合实际情形。此外, 电源车工作环境复杂多变, 状态数据测量和传输易受到噪声干扰, 基于单样本的深度学习故障诊断方法往往由于噪声或随机扰动, 令误诊或漏诊率高, 针对上述问题, 本文提出 LSTM-SPRT 融合的故障诊断方法, 其整体框架如图 1 所示。

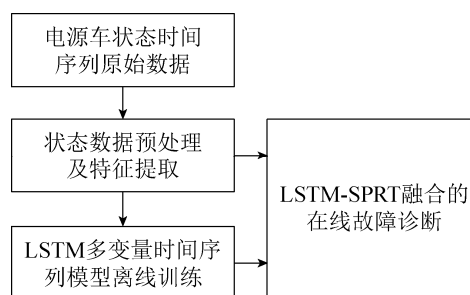


图 1 LSTM-SPRT 融合的故障诊断框图

Fig. 1 Diagram of LSTM-SPRT fusion fault diagnosis

图 1 中, 首先针对电源车状态时间序列原始数据, 采用滑动平均等信号分析方法提取初级特征; 其次利用样本集对 LSTM 多变量时间序列模型进行离线训练, 自主提取深层次的故障特征; 最后, 将训练好的 LSTM 网络模型与 SPRT 方法融合进行电源车在线故障诊断。

2 LSTM-SPRT 融合电源车故障诊断

2.1 基于 LSTM 电源车多变量时间序列建模

电源车主要由柴油机、电子调速器、发电机和励磁系统等 4 个模块组成。考虑电源车各模块之间的强耦合性及其故障机理的复杂性,对电源车运行状态进行实时监测,需获取电源车包括电气、机械及热工类的电压、电流、功率、转速、温度、油压等多个状态的时间序列数据。由于电源车状态序列数据具有空间域和时间域上的依赖性,特别是故障的潜在性与连带行,采用 LSTM 网络模型对其进行建模,提取序列空间和时间双重域的故障特征,进而进行故障诊断。

2.1.1 LSTM 网络

LSTM 网络通过引入特殊的 cell 结构使其能够学习时间序列数据长期依赖的特征,其基础结构如图 2 所示^[23]。图 2 中 a 和 b 分别表示输入和输出单元。 M 是记忆单元,通过与自身的循环连接,获得记忆能力。图 2 中被标记为 f 的神经元称为门控单元,包括输入门(Input Gate)、输出门(Output Gate)和遗忘门(Forget Gate)。

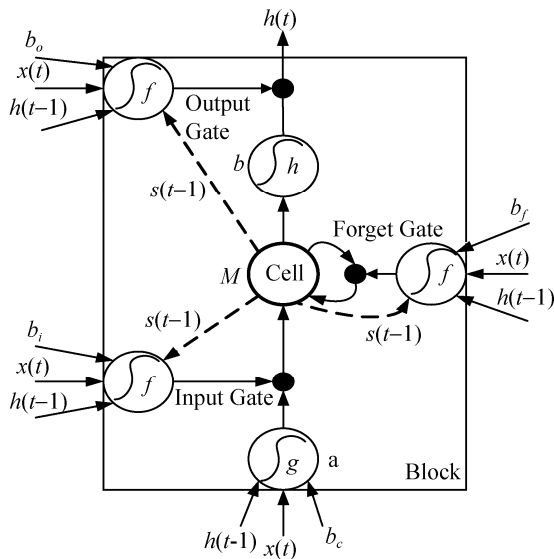


图 2 LSTM 基础结构
Fig. 2 Basic structure of LSTM

门控单元接受 4 个输入,分别是当前时刻的输入向量 $x(t)$ 、前一时刻 Block 的输出以及邻接 Block

的输出 $h(t-1)$ 、前一时刻 cell 的状态 $s(t-1)$ 及自身的偏置向量 $b_k(k=f, o, i)$ 。因此,每一部分对应的输入输出关系为:

Input Gate:

$$a_i^t = \sum_{m=1}^M w_{mi} x_m^t + \sum_{n=1}^N w_{ni} s_n^{t-1} + \sum_{q=1}^Q w_{qi} h_q^{t-1} + b_i \quad (1)$$

$$b_i^t = f(a_i^t) \quad (2)$$

Forget Gate:

$$a_\phi^t = \sum_{m=1}^M w_{m\phi} x_m^t + \sum_{n=1}^N w_{n\phi} s_n^{t-1} + \sum_{q=1}^Q w_{q\phi} h_q^{t-1} + b_\phi \quad (3)$$

$$b_\phi^t = f(a_\phi^t) \quad (4)$$

Output Gate:

$$a_w^t = \sum_{m=1}^M w_{mw} x_m^t + \sum_{n=1}^N w_{nw} s_n^t + \sum_{q=1}^Q w_{qw} h_q^{t-1} + b_o \quad (5)$$

$$b_w^t = f(a_w^t) \quad (6)$$

记忆单元 M 的输入分别来自输入门的输出与当前时刻输入部分的乘积及遗忘门的输出与上一时刻对应的 cell 状态的乘积;最后,输出门的输出与记忆单元的输出相乘作为整个 Block 的输出。其输入输出对应关系为:

Cell:

$$a_c^t = \sum_{m=1}^M w_{mc} x_m^t + \sum_{q=1}^Q w_{qc} h_q^{t-1} + b_c \quad (7)$$

$$s_c^t = b_\phi^t s_c^{t-1} + b_i^t g(a_c^t) \quad (8)$$

Block Output:

$$h_c^t = b_w^t h(s_c^t) \quad (9)$$

由最基本的 LSTM 单元连接起来形成的 4 层网络结构如图 3 所示。

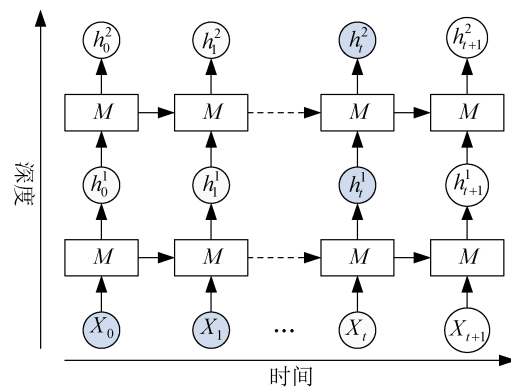


图 3 4 层 LSTM 结构图
Fig. 3 Structure diagram of four-layer LSTM

从图 3 中可以看出, 对于一个输入序列 X_i 来说, 某一个 X 值可能会影响另一个在时间上或者空间上相距比较远的 h_j 的输出(如 3 图中 X_0 和 X_1 共同影响 h_1^j 的输出), 训练过程就是要学习到这种影响的量化关系。

2.1.2 电源车 LSTM 多变量时间序列模型的建立

对电源车进行多变量时间序列建模, 首先需要确定较为完备的状态变量集合, 综合考虑电源车具有机械和电气双重特征及其故障机理的耦合性, 并结合领域专家的经验知识, 选取电源车的相电压(u)、相电流(i)、有功功率(p)、无功功率(q)、功率因数(pf)、转速(s)、定子电流(sc)、定子电压(sv)等 8 个量作为状态变量集合。假设 t 时刻的状态变量集合表示为:

$$X(t)=[u(t) i(t) p(t) q(t) pf(t) s(t) sc(t) sv(t)] \quad (10)$$

于是, 将时序化的状态变量作为 LSTM 网络的输入, 可以得到电源车多变量时间序列模型如图 4 所示。

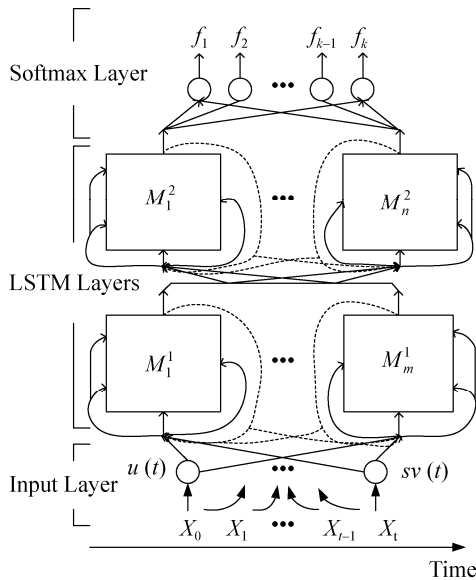


图 4 基于 LSTM 的电源车多变量时间序列模型
Fig. 4 Multivariate time series model of vehicle power supply based on LSTM network

图 4 中, 多变量时间序列模型包括输入层 (Input Layer)、LSTM 网络层 (LSTM Layers) 及 softmax 分类层 (Softmax Layer) 3 部分。其中, 输

入层接受电源车状态变量序列 X_i 作为输入, 其节点数为状态变量的维数; LSTM 网络层由两组分别包含 m 和 n 个 LSTM 基础单元的结构组成; 分类层以 LSTM 网络层提取的特征作为输入, 其节点数为故障种类数。

2.2 电源车 LSTM 多变量时间序列模型的训练

经过 LSTM 网络提取电源车故障在时间和空间上的特征后, 再采用 softmax 函数作故障的分类器, 将 LSTM 的输出作为 softmax 分类器的输入, softmax 分类层接受提取到的特征数据, 计算每个故障的概率以完成多分类任务。分类层的输出为:

$$h_{\theta}(x^i) = \frac{1}{\sum_{j=1}^k e^{\theta_j^T x^i}} \begin{bmatrix} e^{\theta_1^T x^i} \\ e^{\theta_2^T x^i} \\ \vdots \\ e^{\theta_k^T x^i} \end{bmatrix} \quad (11)$$

式中: k 为故障种类; x^i 为 t 时刻第 i 层网络的输出; $y(t)$ 为 t 时刻对应的故障类型; θ 为 softmax 层权值参数。

对于 $j=1, 2, \dots, k$, 网络输出的类别为 k 的概率为 y_k , 对应的真实值是 z_k , 考虑到样本数据的标签是位矢量, 使用交叉熵作为损失函数更为合适, 于是多分类问题的损失函数定义为:

$$L(x, z) = -\frac{1}{m} \sum_x [z_k \ln y_k + (1 - z_k) \ln(1 - y_k)] \quad (12)$$

式中: x 为当前网络的输入样本; m 为样本数。

网络的训练过程就是最小化损失函数的过程, 本文采用梯度下降法对网络参数进行更新(为了方便, 本文仅考虑上一时刻的 cell 和当前时刻的 cell 及 3 个 gate 相连接), 损失函数对各部分权值的偏导数计算如下。

损失函数对 softmax 层输入 a_k^t 的偏导数:

$$\delta_k^t = \frac{\partial L(x, z)}{\partial a_k^t} = \frac{\partial L(x, z)}{\partial y_k} \frac{\partial y_k}{\partial a_k^t} = \frac{1}{m} \sum_x (y_k - z_k) \quad (13)$$

从式(13)可以看出, 每个类别的梯度仅与其预测值和真实值相关, 此时, 由链式法则可以求出

cell output 的梯度。

$$\varepsilon_c^t = \frac{\partial L(x, z)}{\partial b_c^t} = \sum_{k=1}^K \frac{\partial L(x, z)}{\partial a_k^t} \frac{\partial a_k^t}{\partial b_c^t} = \sum_{k=1}^K w_{ck} \delta_k^t \quad (14)$$

同样, 根据链式法则可求出 output gate 的梯度。

$$\delta_w^t = \frac{\partial L(x, z)}{\partial a_w^t} = \frac{\partial L(x, z)}{\partial b_c^t} \frac{\partial b_c^t}{\partial b_w^t} \frac{\partial b_w^t}{\partial a_w^t} = \varepsilon_c^t h(s_c^t) f'(a_w^t) \quad (15)$$

由于 Cell 的梯度可以由当前时刻的 cell output、下一时刻的 cell、下一时刻的 input gate、下一时刻的 output gate 几个单元传递回来, 于是 cell 的 states 梯度可以计算为:

$$\varepsilon_s^t = \frac{\partial L(x, z)}{\partial s_c^t} = \delta_w^t w_{cw} + \varepsilon_c^t b_w^t h'(s_c^t) + b_\varphi^{t+1} \varepsilon_s^{t+1} + w_{cl} \delta_l^{t+1} + w_{c\varphi} \delta_\varphi^{t+1} \quad (16)$$

那么 cell 的梯度为:

$$\delta_c^t = \frac{\partial L(x, z)}{\partial a_c^t} = \frac{\partial L(x, z)}{\partial s_c^t} b_l^t g'(a_c^t) = \varepsilon_s^t b_l^t g'(a_c^t) \quad (17)$$

接下来, 由链式法则可得 forget gate 的梯度为:

$$\delta_\varphi^t = \frac{\partial L(x, z)}{\partial a_\varphi^t} = \frac{\partial L(x, z)}{\partial s_c^t} \frac{\partial s_c^t}{\partial b_\varphi^t} \frac{\partial b_\varphi^t}{\partial a_\varphi^t} = \varepsilon_s^t s_c^{t-1} f'(a_\varphi^t) \quad (18)$$

最终, input gate 的梯度计算如下:

$$\delta_l^t = \frac{\partial L(x, z)}{\partial a_l^t} = \frac{\partial L(x, z)}{\partial s_c^t} \frac{\partial s_c^t}{\partial b_l^t} \frac{\partial b_l^t}{\partial a_l^t} = \varepsilon_s^t g(a_c^t) f'(a_l^t) \quad (19)$$

至此, 各部分梯度求解完毕, 权重的更新过程表述为:

$$\Delta w^n = m \Delta w^{n-1} - \alpha \frac{\partial L}{\partial w^n} \quad (20)$$

式中: $m \Delta w^{n-1}$ 为上一次权重的更新值, 且 $m \in [0, 1]$; 而 $\frac{\partial L}{\partial w^n}$ 即以上所求的每一个梯度。

2.3 基于 SPRT 的故障诊断

现有的深度学习故障诊断方法多是基于单样本, 而且没有考虑样本之间的前后关联性。类似的网络在对复杂装备进行在线故障诊断时, 往往会由于测量噪声或随机扰动导致诊断可靠性不尽人意, 即漏诊率或误诊率过高。滑动数据窗假设检验虽为多样本, 诊断可靠性高, 但观测样本数固定, 存在

较大的时延。

因此, 本文在 LSTM 诊断网络的基础上, 引入 SPRT 方法进行在线自适应多样本故障诊断, 此方法不预先设定观测样本集的数目, 而是在检验过程中不断增加数据, 直到预定的漏报率和误报率都达到要求时停止检验。在确保故障诊断可靠性的前提下, 尽量减少诊断时延^[24]。LSTM 诊断模型与 SPRT 判决机制融合的结构图如图 5 所示。

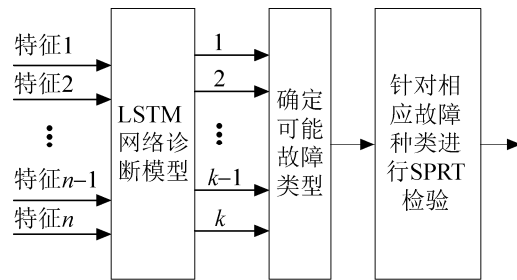


图 5 多样本故障诊断框图

Fig. 5 Diagram of multi-sample fault diagnosis

由上述可知, LSTM 网络诊断模型的 softmax 分类层的输出分别对应着不同故障类型的概率, 数值最大则说明可能出现了相应的故障。鉴于此, 取故障类型为离散型随机变量 X , 取值范围表述为式(21):

$$X = \{1, 2, \dots, k-1, k\} \quad (21)$$

式中各取值分别对应系统 k 类故障状况。可见, 诊断网络的输出即为随机变量 X 的一种概率分布。

考虑到各类故障采用 SPRT 算法诊断的原理相同, 为了描述方便, 以一类故障 f^k 为例。在 t 时刻考虑如下假设检验模型:

$$H_0: X_t \text{ 服从 } P_0(X_t), \text{ 系统正常};$$

$$H_1: X_t \text{ 服从 } P_k(X_t), \text{ 系统发生了 } k \text{ 类故障}.$$

建立 $t+l$ 时刻的对数似然概率比统计量

$$LR_{t+l}(X_t, \dots, X_{t+l}) = \sum_t^{t+l} \ln \frac{P_k(X_t)}{P_0(X_t)} \quad (22)$$

设定检验停止法则为

$$\gamma = \inf \{l | l \geq 1, LR_{t+l} \notin (\ln T(H_0), \ln T(H_1))\} \quad (23)$$

由式(22)可得 LR 的递推公式为

$$LR_{t+l} = LR_{t+l-1} + \ln \frac{P_k(X_{t+l})}{P_0(X_{t+l})} \quad (24)$$

式中: P_F 为允许的误报警概率, 即 H_0 成立反而被否定的概率; P_M 为允许的漏报警概率, 即 H_1 成立反而接受 H_0 的概率。SPRT 检验门限为

$$T(H_0) = P_M / (1 - P_F), T(H_1) = (1 - P_M) / P_F \quad (25)$$

依据式(22)逐次检验观测数据计算 LR_{t+l} , 一旦 $LR_{t+l} \notin (\ln T(H_0), \ln T(H_1))$ 时停止检验, 否则继续。检验停止时, 判决法则为: $LR_{t+l} \leq \ln T(H_0)$, 接受 H_0 , t 时刻系统正常; $LR_{t+l} \geq \ln T(H_1)$, 接受 H_1 , t 时刻系统发生 k 类故障。否则, 增加样本继续检验。

由于对数似然比统计量 LR_{t+l} 在递推过程中可能为负, 当故障发生时, 必须积累一段正值项, 才能满足判决条件, 造成检测延迟。因此, 需对式(24)所表示的统计量做如下修正, 以消除由于抵消负值引起的检测延迟。

$$LR_{t+l}^* = \begin{cases} LR_{t+l} & LR_{t+l} \geq 0 \\ 0 & LR_{t+l} < 0 \end{cases} \quad (26)$$

3 基于电源车仿真系统的故障诊断实验研究

3.1 电源车仿真系统

基于深度学习与序贯检验融合的故障诊断方法, 需以大量的电源车故障数据集为基础。然而, 实际中受历史监测数据的贫乏、破坏性试验的高成本等因素限制, 使其异常状态数据的获取仍有屏障。前期受军方用户需求的驱动, 借助于虚拟仿真技术, 根据电源车各模块的运行机理及相互之间的连接关系, 结合国标 GJB235A-1997 规定的电源车出厂检验负载要求及军方提供的实际带载运行数据, 在理论分析的基础上, 以分块建模的方法建立起电源车及各类负载的数学与仿真模型; 接着利用仿真实验与实体实验数据比对的方法, 通过参数整定和引入边界约束等, 最终在 MATLAB/Simulink 环境下建立了多功率等级的电源车仿真系统, 其功能主界面如图 6 所示。

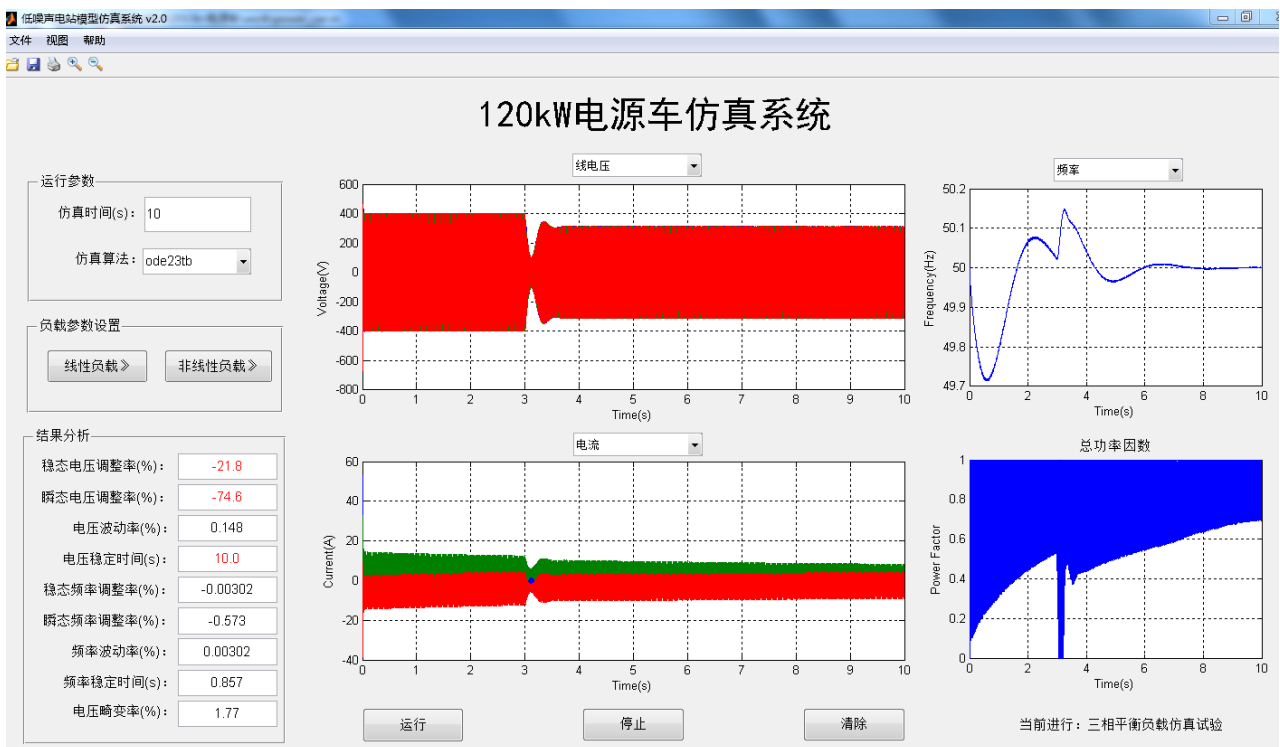


图 6 电源车仿真系统功能主界面

Fig. 6 Main function interface of vehicle power supply simulation system

该仿真系统已在某军方用户使用 3 年,其各模块及参数设置与实际电源车有较高契合度,建模误差均在允许的范围内,具有较高水平的实体电源仿真能力。因此,该仿真系统无疑可为电源车故障诊断提供可用的异常数据支撑。

3.2 数据准备

根据理论分析和电源车实际状况,本文以 120KW 的某军用电源车为对象,在已开发的电源车仿真系统上,结合相关领域专家经验,在 12 种随机的故障时序条件下,分别模拟了电源车系统的电子调速器调节失灵(f_1)、发电机失磁(f_2)、励磁模块故障(f_3)、喷油嘴故障(f_4)等 4 类较为常见的故障,并针对相应的故障模式分别采集电压、电流、有功功率、无功功率、功率因素、转速、定子电压及定子电流等状态的时序数据。然后将时序数据分为 3 部分,分别用于模型的训练、验证和测试。具体数据集描述如表 1~3 所示。其中相邻两类故障之间均为系统正常状态 f_0 ,且样本数分别为 100, 85, 85。

表 1 电源车故障数据训练集描述
Tab. 1 Description of vehicle power supply fault data training set

故障时序	对应样本数			
$[J_3, J_1, J_2, J_4]$	250	234	240	250
$[J_1, J_4, J_2, J_3]$	234	250	240	250
$[J_1, J_2, J_4, J_3]$	234	240	250	250
$[J_4, J_1, J_2, J_3]$	250	234	240	250
$[J_4, J_3, J_1, J_2]$	250	240	234	250
$[J_2, J_4, J_1, J_3]$	250	250	234	240
$[J_2, J_1, J_3, J_4]$	250	234	240	250
$[J_3, J_4, J_2, J_1]$	240	250	250	234
$[J_3, J_1, J_4, J_2]$	240	234	250	250
$[J_1, J_3, J_4, J_2]$	234	240	250	250

表 2 电源车故障数据验证集描述
Tab. 2 Description of vehicle power supply fault data validating set

故障时序	对应样本数			
$[J_1, J_3, J_2, J_4]$	234	250	240	250

表 3 电源车故障数据测试集描述

Tab. 3 Description of vehicle power supply fault data testing set

故障时序	对应样本数			
$[J_4, J_2, J_1, J_3]$	250	240	234	250

3.3 LSTM 网络的离线训练

为了说明 LSTM 网络具有更好的诊断性能,使用训练数据集分别对 LSTM 网络及 DBN 进行训练,两类网络的结构分别为: $[9, 128, 5]$ 和 $[9, 200, 100, 5]$ 。同时,将验证数据集用于两类模型动态性能的验证,并分别对比两种模型的损失函数和准确率,其结果如图 7~8 所示。

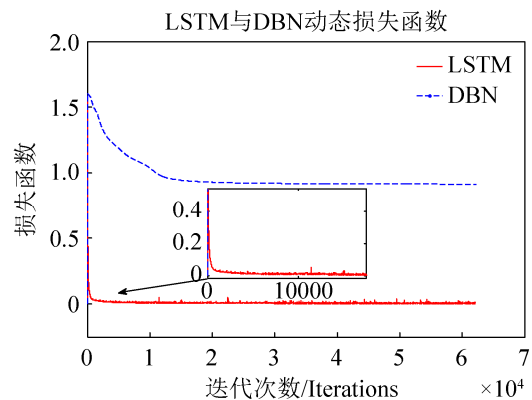


图 7 两类模型的动态损失函数

Fig. 7 Dynamic loss function of two types of models

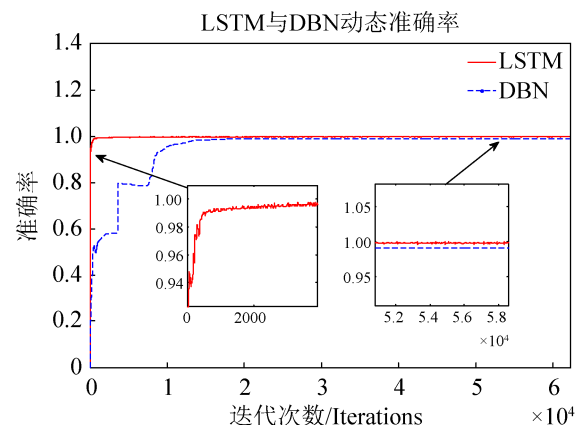


图 8 两类模型的动态准确率

Fig. 8 Dynamic accuracy of two types of models

由图 7~8 可知, LSTM 与 DBN 模型训练稳定后,其损失函数值分别为 0.009 4 和 0.915 9、准确率分别为 99.84%和 99.12%、迭代收敛次数分别为

3 600 和 16 000。显而易见, LSTM 不仅损失函数更低、准确率更高、而且收敛速度也更快。这充分表明, LSTM 模型由于具备独特的记忆能力, 具有更强的学习能力和更好的映射能力, 以其建立的电源车故障诊断模型性能明显优于 DBN 模型。

将训练好的 2 类模型用于测试, 测试结果分别如表 4~5 所示。

表 4 LSTM 诊断模型测试结果

Tab. 4 Test results of LSTM diagnostic model

状态类型	f_0	f_1	f_2	f_3	f_4
确诊样本	270	234	240	250	247
误诊样本	0	0	0	0	0
漏诊样本	3	0	0	0	0

表 5 DBN 诊断模型测试结果

Tab. 5 Test results of DBN diagnostic model

状态类型	f_0	f_1	f_2	f_3	f_4
确诊样本	270	232	240	244	247
误诊样本	0	2	0	0	0
漏诊样本	0	0	0	6	3

由表 4~5 可知, LSTM 诊断模型共有 3 次漏诊行为, 而 DBN 诊断模型出现 2 次误诊及 9 次漏诊行为。测试结果表明, 基于 LSTM 网络的多变量时间序列模型, 由于能够挖掘时序特征数据更深层次的故障知识, 具有更好的故障特征提取能力, 因而具有更高的诊断准确率。

3.4 LSTM-SPRT 融合的实时故障诊断

针对电源车的 4 类常见故障, 将训练好的 LSTM 网络诊断模型与 SPRT 算法融合进行在线实时故障诊断。取误报率 $P_F=0.1$ 、漏报率 $P_M=0.1$, 则统计量 LR_{t+1} 的 k 类故障检测阈值为 $\ln T(H_1)=2.197$ 。电源车启动到稳定运行需要一段时间, 假设在此期间电源车无故障, 且运行过程中只发生单一故障。设置系统仿真时间为 100 s, 故障时序为 $[f_3, f_1, f_4, f_2]$, 并分别在系统正常期间模拟电源车调速器模块的执行器输入及励磁模块的电压调节器输入受到外部干扰, 持续时间为 0.05 s。此外, 假设速度和电压受到测量噪声的影响, 且信噪比分别

为 50 db, 55 db。电源车部分状态特征的动态过程如图 9~10 所示。




图 9 电源车相电压、相电流动态过程

Fig. 9 Dynamic process of vehicle power supply phase voltage, phase current




图 10 电源车发电机转速、有功功率动态过程

Fig. 10 Dynamic process of vehicle power supply generator speed, active power

将训练好的诊断模型用于上述过程的故障诊断, 并对单样本判决和 SPRT 的效果进行对比, 其结果如图 11~12 所示。图中类型 1 表示系统正常, 其余分别与 4 类常见故障对应; 同时, 为了显示更加清晰, 图中故障真实值与诊断值之间虚拟了 0.15 的差异。此外, 为凸显本文方法的优势, 分别将传统的浅层 BP 神经网络(BPNN)模型和 DBN 模型用于上述过程的故障诊断, 并依次对诊断结果进行统计, 以对比不同方法的识别性能, 其统计结果如表 6 所示。




图 11 单样本检验的诊断结果

Fig. 11 Diagnostic result of single-sample test




图 12 SPRT 下的诊断结果

Fig. 12 Diagnostic result under SPRT

表 6 不同诊断方法下各类故障预测准确率

Tab. 6 All kinds of fault prediction accuracy under different diagnostic methods

故障类别	f_0	f_1	f_2	f_3	f_4	/%
BPNN 准确率	72.2	89.5	80	87.0	88.8	
DBN 准确率	80.5	100	98.7	100	93.6	
LSTM 准确率	76.3	100	99.5	100	99.6	
LSTM-SPRT 准确率	96	100	100	100	100	

由图 11 可知, 由于电源车正常运行期间受到随机噪声与扰动而引起的疑似故障, 导致单样本检验出现多次误诊行为; 本文采用的 SPRT 判决方法可以有效地规避此类疑似故障, 表现出较强的鲁棒性。同时 SPRT 也会带来一定的时延, 如图 12 中空白间隙所示, 但此延时会随故障的大小自动调整, 即小故障延时略大、大故障延时很少, 通过

SPRT 中参数的优化折衷, 不会殃及系统的安全。

由表 6 可知, 在系统存在测量噪声和随机扰动的情形下, LSTM 模型的平均诊断准确率为 95.08%, 高于 DBN 模型的 94.56%, 且远远高于 BPNN 模型的 83.5%。此外, 就 LSTM 模型而言, 由于测量噪声和随机扰动的影响, 单样本检验条件下在 f_0 (正常), f_2 , f_4 中均出现了误诊, 尤其是正常情形受随机噪声和扰动影响最大, 误诊率高达 23.7%; 而 SPRT 判决方法明显改善了基于 LSTM 网络下单样本检验的误诊缺陷, 提高了电源车故障诊断的准确率和可靠性。

4 结论

本文针对电源车这一复杂装备, 提出了基于长短记忆网络的多变量时间序列模型同序贯概率比检验结合的故障诊断方法。该方法充分挖掘电源车故障特征在空间和时间双重域上的关联性, 弥补大多深度学习诊断模型仅考虑故障特征在空间域上有联系的不足; 将深度学习模型与序贯概率比检验相结合, 克服基于单样本深度学习诊断模型可靠性低的缺陷。在电源车仿真平台上实验验证, 结果表明, 基于 LSTM 多变量时间序列的电源车故障诊断模型, 对于挖掘电源车时序数据中的故障特征, 较浅层模型 BPNN 和非时序的深度学习模型 DBN 更具优势; 深度学习模型同多样本检验结合的故障诊断方法, 能够有效提高电源车在线故障诊断的准确率和可靠性。此诊断方法对故障先验知识依赖小, 且诊断准确率和可靠性高, 在工业大数据背景下, 对于复杂工况环境下的设备及系统的状态监测和自主维护平台的开发, 具有理论参考和应用价值。

参考文献:

- [1] 任浩, 屈剑锋, 柴毅, 等. 深度学习在故障诊断领域中的研究现状与挑战[J]. 控制与决策, 2017, 32(8): 1345-1358.
Ren Hao, Qu Jianfeng, Chai Yi, et al. Deep learning for fault diagnosis: The state of the art and challenge[J].

- Control and Decision, 2017, 32(8): 1345-1358.
- [2] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1): 1-9.
Li Han, Xiao Deyun. Survey on data driven fault diagnosis methods[J]. Control and Decision, 2011, 26(1): 1-9.
- [3] Gao Z, Cecati C, Ding S X. A Survey of Fault Diagnosis and Fault-Tolerant Techniques-Part II: Fault Diagnosis With Knowledge-Based and Hybrid/Active Approaches[J]. IEEE Transactions on Industrial Electronics (S0278-0046), 2015, 62(6): 3768-3774.
- [4] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报, 2015, 51(21): 49-56.
Lei Yaguo, Jia Feng, Zhou Xin, et al. A Deep Learning-based Method for Machinery Health Monitoring with Big Data[J]. Journal of Mechanical Engineering, 2015, 51(21): 49-56.
- [5] Xia F, Zhang H, Liu W, et al. Fault Analysis of Condenser Based on RBF Network and D-S Evidence Theory[C]. International Conference on Artificial Intelligence and Computational Intelligence. Berlin, Heidelberg: Springer-Verlag, 2012: 506-513.
- [6] Chen J, Li Y, Ye F. Uncertain information fusion for gearbox fault diagnosis based on BP neural network and DS evidence theory[C]. Intelligent Control and Automation. Guilin, China: IEEE, 2016: 1372-1376.
- [7] 赵光权, 葛强强, 刘小勇, 等. 基于 DBN 的故障特征提取及诊断方法研究[J]. 仪器仪表学报, 2016, 37(9): 1946-1953.
Zhao Guangquan, Ge Qiangqiang, Liu Xiaoyong, et al. Fault feature extraction and diagnosis method based on deep belief network[J]. Journal of Instrumentation and Measurement, 2016, 37(9): 1946-1953.
- [8] He K, Zhang X, Ren S, et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence (S0162-8828), 2015, 37(9): 1904-1916.
- [9] Kim J, El-Khany M, Lee J. Residual LSTM: Design of a Deep Recurrent Architecture for Distant Speech Recognition[C]. Interspeech(S2308-457X), 2017: 1591-1595. DOI:10.21437/Interspeech.2017-477.
- [10] Hassan A, Mahmood A. Deep Learning approach for sentiment analysis of short texts[C]. International Conference on Control, Automation and Robotics. Nagoya, Japan: IEEE, 2017: 705-710.
- [11] 段艳杰, 吕宜生, 张杰, 等. 深度学习在控制领域的研究现状与展望[J]. 自动化学报, 2016, 42(5): 643-654.
Duan Yanjie, Lü Yisheng, Zhang Jie, et al. Deep Learning for Control: The State of the Art and Prospects. Acta Automatica Sinica, 2016, 42(5): 643-654.
- [12] Zhang Z, Zhao J. A deep belief network based fault diagnosis model for complex chemical processes[J]. Computers & Chemical Engineering (S0098-1354), 2017, 107: 395-407.
- [13] Shao H, Jiang H, Wang F, et al. Rolling bearing fault diagnosis using adaptive deep belief network with dual-tree complex wavelet packet[J]. Isa Trans (S0019-0578), 2017, 69: 187-201.
- [14] Jing L, Zhao M, Li P, et al. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox[J]. Measurement Journal of the International Measurement Confederation (S0263-2241), 2017, 111: 1-10.
- [15] Sun W, Shao S, Zhao R, et al. A sparse auto-encoder-based deep neural network approach for induction motor faults classification[J]. Measurement (S0263-2241), 2016, 89: 171-178.
- [16] Liu H, Zhou J, Zheng Y, et al. fault diagnosis of rolling bearing with recurrent neural network-based autoencoders, ISA Transactions (S0019-0578), 2018, 77: 167-178. <https://doi.org/10.1016/j.isatra.2018.04.005>.
- [17] De B T, Verbert K, Babuska R. Railway Track Circuit Fault Diagnosis Using Recurrent Neural Networks[J]. IEEE Transactions on Neural Networks & Learning Systems (S2162-237X), 2017, 28(3): 523-533.
- [18] Lee I, Kim D, Kang S, et al. Ensemble Deep Learning for Skeleton-Based Action Recognition Using Temporal Sliding LSTM Networks[C]. IEEE International Conference on Computer Vision. Venice, Italy: IEEE Computer Society, 2017: 1012-1020.
- [19] Zhao H, Sun S, Jin B. Sequential Fault Diagnosis based on LSTM Neural Network[J]. IEEE Access (S2169-3536), 2018, 6: 12929-12939.
- [20] De B T, Verbert K, Babuska R. Railway Track Circuit Fault Diagnosis Using Recurrent Neural Networks[J]. IEEE Transactions on Neural Networks & Learning Systems (S2162-237X), 2017, 28(3): 522-533.
- [21] Zhang J, Song Y, Li G, et al. A Method of Fault Diagnosis for Rolling Bearing of Wind Turbines Based on Long Short-term Memory Neural Network[J]. Computer Measurement & Control (S1671-4598), 2017, 25(1): 16-19.

- [22] Yuan M, Wu Y, Lin L. Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network[C]. IEEE International Conference on Aircraft Utility Systems. Beijing China: IEEE, 2016: 135-140.
- [23] Graves A. Supervised Sequence Labelling with Recurrent Neural Networks[M]. Berlin Heidelberg: Springer-Verlag, 2012.
- [24] 李炜, 张婧瑜. 多模型传感器故障软闭环容错控制研究[J]. 计算机应用研究, 2015(2): 447-450.
- Li Wei, Zhang Jingyu. Study of multi-model soft close-loop fault-tolerant control with sensor faults[J]. Application Research of Computers, 2015(2): 447-450.