

DOI: 10.19783/j.cnki.pspc.210624

基于长短期记忆网络的继电保护测试故障诊断研究

陈桂芳¹, 董秀成¹, 郑永康², 徐洪海³

(1. 西华大学电气与电子信息学院, 四川 成都 610039; 2. 国网四川省电力公司电力科学研究院, 四川 成都 610041; 3. 江苏宏源电气有限责任公司, 江苏 南京 211103)

摘要: 为提高智能变电站继电保护测试效率, 解决数字式继电保护试验装置无法对整个测试过程中出现的故障自动进行诊断的问题, 提出基于长短期记忆(Long Short-Term Memory, LSTM)网络的继电保护测试故障诊断方法。梳理了故障断面特征信息和故障类别, 建立了多故障诊断模型, 构建了故障诊断流程。以典型 220 kV 继电保护测试为例, 通过将 LSTM 与循环神经网络、BP 网络和深度神经网络进行对比, 得到输入实际故障信息和部分不可靠信息时 LSTM 模型的三项评价标准(平均绝对误差、准确率和综合评价指标)值均最优。通过实验仿真验证了基于 LSTM 网络的继电保护测试故障诊断方法具有较高的精度与良好的容错性能。

关键词: 智能变电站; 继电保护测试; 数字式继电保护试验装置; 长短期记忆网络; 故障自动诊断

Fault diagnosis of a relay protection test based on a long short-term memory network

CHEN Guifang¹, DONG Xiucheng¹, ZHENG Yongkang², XU Honghai³

(1. School of Electrical & Electronic Information, Xihua University, Chengdu 610039, China;
2. State Grid Sichuan Electric Power Research Institute, Chengdu 610041, China;
3. Jiangsu Hongyuan Electric Co., Ltd., Nanjing 211103, China)

Abstract: The efficiency of intelligent substation relay protection test needs improvement. There is also a problem in that a digital relay protection test device cannot automatically diagnose faults during the whole test process. Thus a relay protection test fault diagnosis method based on long short-term memory (LSTM) network is proposed. In this paper, the fault section characteristic information and fault categories are first established. Then a multi-fault diagnosis model is established, and a fault diagnosis process is constructed. Taking the typical 220 kV relay protection test as an example, by comparing LSTM with cyclic neural, a BP and a deep neural networks, the three evaluation criteria (mean absolute error, accuracy and comprehensive evaluation index) of the LSTM model are found to be optimal when the actual fault information and partial unreliable information are two different inputs. Simulation results show that the relay protection test fault diagnosis method based on the LSTM network has high precision and good fault-tolerant performance.

This work is supported by the National Natural Science Foundation of China (No. 11872069).

Key words: smart substation; relay protection test; digital relay protection test device; long short-term memory (LSTM) network; automatic fault diagnosis

0 引言

继电保护装置对电力系统运行的稳定性和可靠性起着举足轻重的作用, 对保护装置的测试检验是确保其安全可靠的重要环节^[1-9]。智能变电站继电保

护装置的现场调试以及出厂联调阶段中, 最主要的调试工具是数字式继电保护试验装置(后面简称试验装置)。目前试验装置可以在使用时对自身故障进行诊断, 但无法实现对测试过程中整个系统特别是被测保护装置出现的异常或故障进行自动诊断, 人工进行故障排查需要耗费大量时间。

变电站传统故障诊断主要是技术人员依据通信报文装置辅助判别异常原因, 由于数据量太大且缺乏有效手段分析故障特征, 很难对继电保护测试过

基金项目: 国家自然科学基金项目资助(11872069); 四川省中央引导地方科技发展专项资助(2021ZYD0034); 四威高科-西华大学产学研联合实验室资助(2016-YF04-00044-JH)

程中的故障进行高效诊断^[10]。而机器学习可以快速处理大量数据,分析提取有用信息,应对数据缺失、异常以及噪声等情况,在电力系统故障分析及定位中受到了越来越多的关注^[11-15]。文献[16]将深度神经网络应用于变电站继电保护装置状态监督中;文献[17-18]将深度学习应用于电机故障诊断中;文献[19]将机器学习应用于配网线路巡检、配网设备运维和配网故障诊断中;文献[20]将机器学习应用于配电自动化开关柜故障诊断。

本文为提高智能变电站继电保护测试效率,解决数字式继电保护试验装置无法对整个测试过程中出现的故障自动进行诊断的问题,提出一种基于 LSTM 网络的继电保护测试故障诊断方法。利用平均绝对误差(Mean Absolute Error, MAE)、综合评价指标(F-Score)和准确率(Accuracy)三种评价标准对模型效果进行评价。以智能变电站 220 kV 继电保护测试为例,将 LSTM 网络模型与循环神经网络(Recurrent Neural Network, RNN)、BP 神经网络(Back Propagation, BP)和深度神经网络(Deep Neural Networks, DNN)模型进行对比,结果表明 LSTM 网络模型可有效地诊断继电保护测试过程中出现的故障且效果最优。

1 继电保护测试故障诊断建模

1.1 LSTM 神经网络

LSTM 神经网络是特殊的 RNN,它的内部存在着循环,用来保持信息的延续性,适用于较长时间间隔和较长延迟的重要时间序列处理和预测,拥有非线性特征挖掘能力^[21-24]。由于继电保护测试出现故障时的大量特征信息拥有序列性,故障特征与故障类型的关系为非线性,因此本文选取 LSTM 搭建继电保护测试故障诊断模型。

LSTM 结构如图 1 所示,包括遗忘门、输入门、输出门及细胞状态^[25],这些结构可以解决 RNN 的梯度消失等问题。

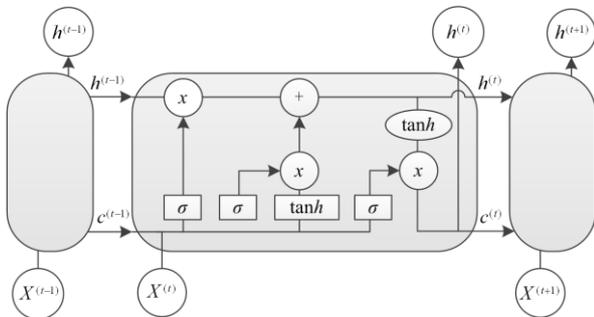


图 1 LSTM 结构图

Fig. 1 Structure of LSTM

遗忘门输入包括上一序列的隐藏状态 $h^{(t-1)}$ 和本序列数据 $x^{(t)}$,通过激活函数 Sigmoid,得到遗忘门的输出 $f^{(t)}$ 。由于 Sigmoid 的输出 $f^{(t)}$ 在 $[0,1]$ 内,因此这里的输出代表了遗忘上一层隐藏细胞状态的概率,用数学表达式即为

$$f^{(t)} = \sigma(W_f h^{(t-1)} + U_f x^{(t)} + b_f) \quad (1)$$

式中: W_f 、 U_f 和 b_f 为线性关系的系数和偏倚;激活函数 σ 为 Sigmoid。

输入门由两部分组成,第一部分使用了 Sigmoid 激活函数,输出为 $i^{(t)}$,第二部分使用了 tan h 激活函数,输出为 $a^{(t)}$,用数学表达式即为

$$i^{(t)} = \sigma(W_i h^{(t-1)} + U_i x^{(t)} + b_i) \quad (2)$$

$$a^{(t)} = \tan h(W_a h^{(t-1)} + U_a x^{(t)} + b_a) \quad (3)$$

式中: W_i 、 U_i 、 W_a 、 U_a 和 b_i 、 b_a 为线性关系的系数和偏倚;激活函数 σ 为 Sigmoid。

细胞状态 $c^{(t)}$ 由两部分组成,第一部分是 $c^{(t-1)}$ 和遗忘门输出 $f^{(t)}$ 的乘积,第二部分是输入门 $i^{(t)}$ 和 $a^{(t)}$ 的乘积,用数学表达式即为

$$c^{(t)} = c^{(t-1)} \odot f^{(t)} + i^{(t)} \odot a^{(t)} \quad (4)$$

式中, \odot 表示 Hadamard 积。

对于输出门隐藏状态 $h^{(t)}$ 的更新由两部分组成,第一部分是 $o^{(t)}$,它由上一序列的隐藏状态 $h^{(t-1)}$ 和本序列数据 $x^{(t)}$ 以及激活函数 Sigmoid 得到,第二部分由隐藏状态 $c^{(t)}$ 和 tan h 激活函数组成,数学表达式即为

$$o^{(t)} = \sigma(W_o h^{(t-1)} + U_o x^{(t)} + b_o) \quad (5)$$

$$h^{(t)} = o^{(t)} \odot \tan h(c^{(t)}) \quad (6)$$

式中: W_o 、 U_o 和 b_o 为线性关系的系数和偏倚;激活函数 σ 为 Sigmoid。

1.2 继电保护测试故障诊断模型建立

基于 LSTM 网络的智能变电站继电保护测试故障诊断模型建立过程如图 2 所示。

故障样本集是从历史故障诊断样本库中获得的;删除重复数据是用于防止相同数据重复训练;零均值是将每一维原始数据减去每一维数据的平均值,将结果代替原始数据;归一化是将不同维度的数据归一到相同的数值区间,

本文将每一维数据的最大最小值设为 1 和 0,此时认为不同维度的数据具有相同的重要性,即 min-max 法归一化。

本文样本数在万级别以内,设置训练集为故障样本集 70%、测试集为故障样本集 30%。给试验装置增加了故障诊断功能并应用于实际继电保护测试后,故障样本总数将逐渐增加并到达新的数量级,

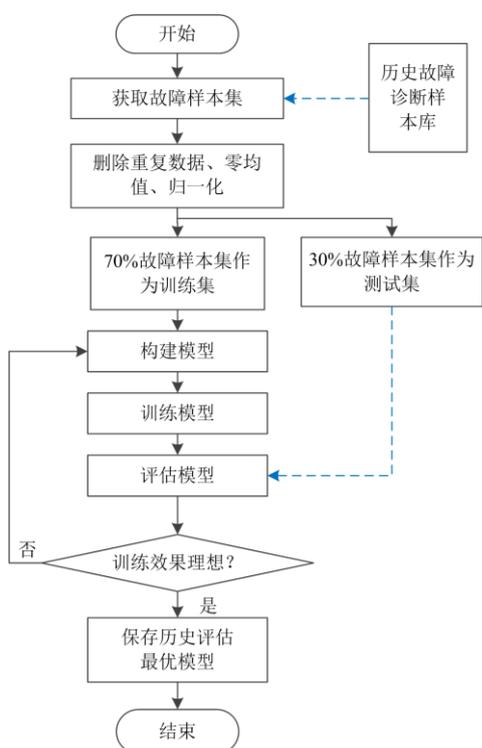


图 2 LSTM 故障诊断模型建立过程

Fig. 2 LSTM fault diagnosis model establishment process

此时再重新对训练集和测试集进行划分。

在 LSTM 网络中引入 Dropout, 神经元随机失活概率设定为 0.2, Dropout 通过使隐藏单元随机选择其他单元样本来有效避免小数据集下神经网络过拟合的发生^[26], 提高了神经网络对测试数据集的预测效果。引入 Adam(Adaptive Moment Estimation) 算法来解决传统梯度下降法在迭代过程中学习率为常数的问题。经多次实验, LSTM 模型的预测准确率并没有随 LSTM 层数的增加得到提升, 反而训练时间大幅度增加。最终确定 LSTM 层数为 2, 神经元数为 1 024, 基于 LSTM 网络的继电保护故障诊断模型结构如图 3 所示。

LSTM 网络有 95 个输入: X_{TZ1} 、 X_{TZ2} 、 \dots 、 X_{CY12} , 为继电保护测试故障断面的特征信息; 有 27 个输出: $h_1^{(999)}$ 、 \dots 、 $h_1^{(1024)}$ 、 $h_1^{(1025)}$ 。之后连接一层 Dense 全连接, 全连接层有 27 个神经元, 输出 Y_1 、 \dots 、 Y_{26} 、 Y_{27} 为对应故障类型编码, 具体编码见表 3。LSTM 网络每一个神经元的状态相互连接, $h^{(0)}$ 为上一个神经元的终态, $h^{(1025)}$ 为下一个神经元的初态。

1.3 模型评估标准

本文对模型评估主要参考 3 个标准: MAE、Accuracy、F1-Score。

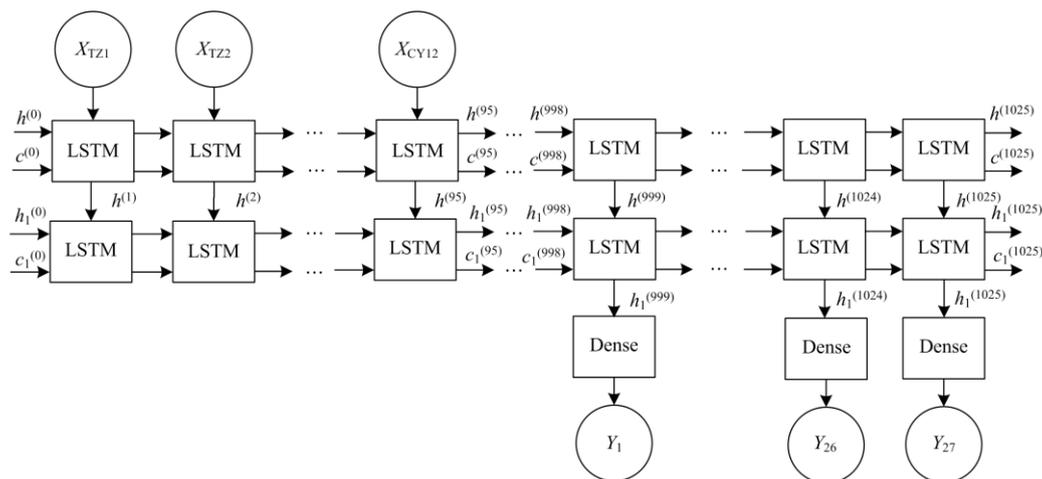


图 3 故障诊断模型拓扑

Fig. 3 Topology of fault diagnosis model

1.3.1 MAE 评价标准

M_{MAE} 表示预测值和真实值之间绝对误差的平均值, 计算公式为

$$M_{MAE} = \frac{1}{k} \sum_{i=1}^k |f_i - y_i| \quad (7)$$

式中: f_i 表示预测值; y_i 表示真实值; k 表示总样本数。

1.3.2 F-Score 和 Accuracy 评价标准

模型样本的预测结果有 4 种:

TP: 正样本被正确预测为正样本; FP: 负样本被错误预测为正样本; TN: 负样本被正确预测为负样本; FN: 正样本被错误预测为负样本。

$A_{accuracy}$ 由 TP、FP、TN、FN 组成, 计算公式如式(8)所示。

$$A_{accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

F-Score 由精确率(Precision)和召回率(Recall)组成, 其计算公式分别如下。

1) 精确率 $P_{precision}$

$$P_{precision} = \frac{TP}{TP + FN} \quad (9)$$

2) 召回率 R_{recall}

$$R_{recall} = \frac{TP}{TP + FN} \quad (10)$$

3) 综合评价指标 F_{score}

$$F_{score} = (1 + \beta^2) \cdot \frac{P_{precision} \cdot R_{recall}}{\beta^2 \cdot P_{precision} + R_{recall}} \quad (11)$$

式中, $\begin{cases} \beta = 1, \text{ 精确率和召回率同样重要;} \\ \beta < 1, \text{ 精确率更重要;} \\ \beta > 1, \text{ 召回率更重要。} \end{cases}$

当取 $\beta = 1$ 时为 F_{score} , 本文用 F_{score} 作为评价标准。

2 继电保护测试故障诊断

2.1 继电保护测试简介

智能变电站继电保护可以分为单间隔保护(线路保护和母联保护等)、跨间隔保护(母线保护和主变压器)^[27-28]。数字式继电保护试验装置替代智能终端、合并单元等装置, 对保护装置进行单体试验。测试过程中将试验装置与保护装置相连接, 保护装置可直接获取站控层和过程层信号。智能变电站继电保护测试拓扑图如图 4 所示。

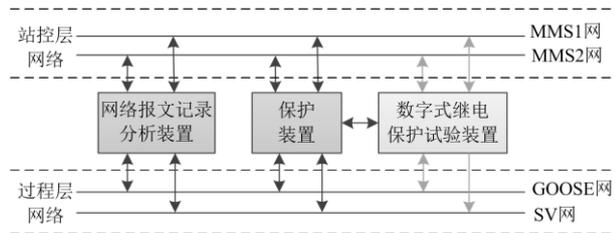


图 4 继电保护测试拓扑

Fig. 4 Topology of relay protection test

本文提出可以在智能变电站继电保护试验装置上增加从网上直接获取站控层信号的功能, 使信号获取更全面、便捷, 且能提高智能变电站继电保护试验装置自动测试的智能化水平。

2.2 继电保护测试故障诊断样本集构成

继电保护测试故障诊断样本集由故障断面特征量、故障断面采样值(双通道三相电压电流)与故障

类型标签 3 部分组成, 其中故障断面特征量和故障断面采样值构成故障断面特征信息。

2.2.1 故障断面特征信息表征

将智能变电站继电保护测试的故障断面特征信息归纳为 95 个, 包括 83 个特征量和 12 个采样值, 部分故障断面特征信息见表 1。

表 1 部分故障断面特征信息

Table 1 Characteristic information of partial fault section

故障断面特征量	故障断面采样值
试验装置 SV 总报警	I_1A
保护装置 EEPROM 错误	I_1B
保护装置 FLASH 错误	I_1C
保护装置 RAM 自检出错	U_1A
保护装置 SRAM 错误	U_1B
保护装置 CPU 插件错误	U_1C
保护装置故障	I_2A
保护装置自检告警	I_2B
保护装置运行异常	I_2C
⋮	⋮

任一继电保护测试故障断面的特征信息集可表征为 X , 如式(12)所示。

$$X = \{X_{TZ1}, X_{TZ2}, \dots, X_{TZ83}, X_{CY1}, X_{CY2}, \dots, X_{CY12}\} \quad (12)$$

式中: X_{TZ} 为继电保护测试故障断面特征量; X_{CY} 为继电保护测试故障断面采样值。

2.2.2 故障类型分类

本文智能变电站继电保护测试故障诊断对象主要包括试验装置、保护装置、通信网络以及通信设备。根据故障诊断对象可以将故障分为 35 类, 部分故障类型可通过现有知识库简单推理得到, 例如保护装置失电时测控装置会发出失电告警提示, 可直接推理出故障为保护装置失电故障。因此为提高模型的收敛速度, 后续诊断研究中不涉及该类型故障, 其余需用神经网络模型诊断的有 27 种故障类型, 部分故障类型见表 2。

表 2 部分故障类型

Table 2 Partial fault types

故障编号	故障类型
1	试验装置双采样模块故障
2	试验装置 SV 板故障
3	试验装置 GOOSE 板故障
4	试验装置输出光口故障
5	试验装置采样失步
6	试验装置输入光口故障(试-交换机)
7	试验装置输入光口故障(试-母合)
8	试验装置输出端口异常
⋮	⋮
27	三相断路器异常

继电保护测试中发生的故障可编码为 Y , 如式 (13) 所示。

$$Y = \{Y_1, Y_2, \dots, Y_j\} \quad (13)$$

式中: $j = 27$; Y_1, Y_2, \dots, Y_j 分别对应继电保护测试 27 种故障类型, 编码为 1 表示发生该故障, 编码为 0 表示未发生该故障。例如某一次继电保护测试故障编码为: 11000000000000000000000000, 结合表 2 可知本次故障为双故障, 分别是试验装置双采样模块故障和试验装置 SV 板故障。

2.3 继电保护测试故障诊断实现流程

将样本集用于 LSTM 网络模型训练与测试, 得到理想模型后应用于试验装置, 实现继电保护测试故障诊断, 诊断流程如图 5 所示。具体步骤如下。

1) 智能变电站进行继电保护测试, 启动试验装置, 同时故障诊断模块开始工作。

2) 收集测试过程中出现的相关特征信号, 并提取出相关特征信号中故障断面特征量和采样值, 构成故障断面特征信息集。

3) 判断能否利用现有知识库进行推理找到故障类型。能则用专家系统进行推理, 输出故障原因, 诊断结束; 不能则将故障断面特征信息集输入历史评估最优 LSTM 网络故障诊断模型中进行诊断, 输出故障类型后将新的故障样本存入历史故障诊断样本库中用于模型更新, 诊断结束。

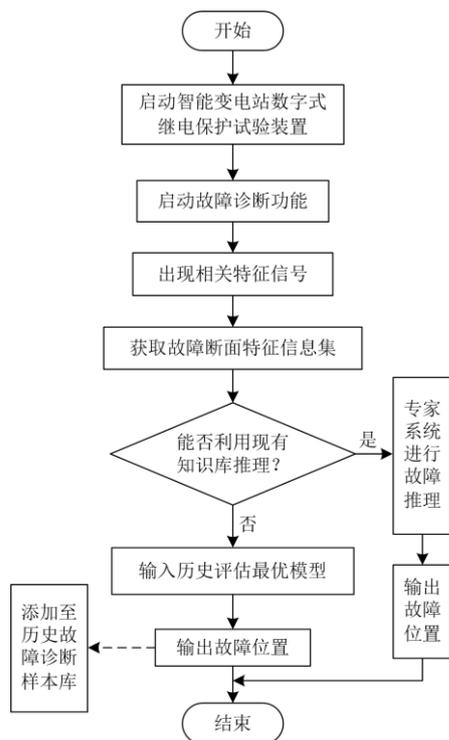


图 5 故障诊断流程

Fig. 5 Fault diagnosis process

3 实验验证与分析

3.1 实验环境与数据

实验建模环境为 python3.5, tensorflow1.2.1 框架。由图 2 可知智能变电站的继电保护测试故障诊断模型用于训练的样本集是从历史故障诊断样本库中获得, 样本库中原始数据是试验装置在 220 kV 继电保护测试 27 类故障情况下多次重复测试得到。由图 5 可知当试验装置添加实时故障诊断模块并在测试过程中遇到故障时, 将会把得到的故障断面特征信息和对应故障类型扩充进历史故障诊断样本库中, 用于之后模型优化。

实际继电保护测试过程中主要发生单故障和双故障, 于是实验中采集 27 种单故障类型和 214 种主要双故障类型数据, 每种故障训练样本数和测试样本数都分别为 21 和 9, 总故障样本数为 7 230。对应部分故障样本数据情况如表 3 所示。

表 3 部分样本数据统计

Table 3 Partial sample data statistics

故障编号	故障类型编码	训练样本数	测试样本数
1	00000000000000000000000000000001	21	9
2	00000000000000000000000000000010	21	9
3	00000000000000000000000000000100	21	9
4	000000000000000000000000000001000	21	9
5	0000000000000000000000000000010000	21	9
6	00000000000000000000000000000100000	21	9
7	000000000000000000000000000001000000	21	9
8	0000000000000000000000000000010000000	21	9
9	00000000000000000000000000000100000000	21	9
10	000000000000000000000000000001000000000	21	9
⋮	⋮	⋮	⋮
239	10010000000000000000000000000000	21	9
240	10100000000000000000000000000000	21	9
241	11000000000000000000000000000000	21	9

3.2 设置不同超参数时网络优化状况

利用故障样本集训练 LSTM 模型过程中, 通过调整 LSTM 层数、设置 Dropout 优化网络, 以测试样本集的 F1-Score 作为网络参数的优化指标。网络输出层的阈值设置为 0.6, 即输出层的神经元大于 0.6 时对应位置元素为 1, 否则为 0, batch_size 设置为 300, 测试结果如图 6 所示。

由图 6 可知, 经过 5 000 次迭代后, LSTM 层数为 2 时网络优化效果均最佳, LSTM 层数为 1 时神经网络拟合性能欠佳, LSTM 层数为 3 时整个神经网络训练难度反而增加, 且引入 Dropout 后测试集效果略有提升, 由此确定基于 LSTM 网络的故障诊断模型结构如图 3 所示。

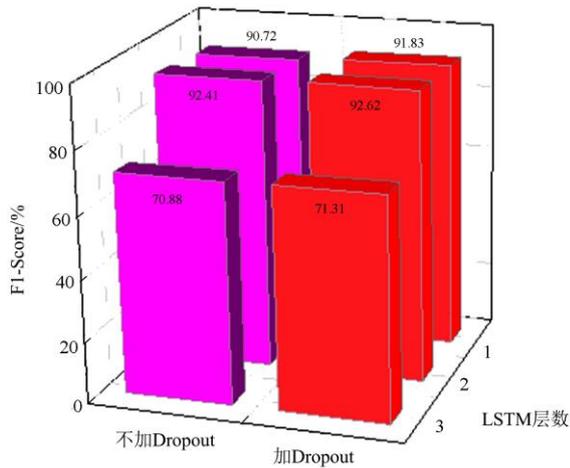


图 6 迭代 5 000 次后的 LSTM 网络优化情况

Fig. 6 Optimization of LSTM network after 5 000 iterations

3.3 实验结果分析

为研究基于 LSTM 网络故障诊断模型的有效性, 将本文所提方法与基于 RNN 网络、BP 网络和 DNN 网络的故障诊断模型进行对比。

为比较文中所提 LSTM 网络模型的性能, 对 RNN、BP 和 DNN 网络模型采用相同的样本集进行训练和测试, 同时网络结构相同。模型评估标准为 1.3 节所述的 3 个标准: MAE、Accuracy 和 F1-Score。

3.3.1 实际故障情况下模型的诊断效果分析

基于上述内容, 将 5 061 组训练样本分别用于 4 种神经网络模型训练, 统一迭代 10 000 次, 将 2 169 组测试样本用以验证模型在实际故障情况下的诊断效果。

迭代前 10 000 次 4 种神经网络的 F1-Score 变化曲线如图 7 所示, 迭代前 10 000 次 4 种神经网络的 MAE 变化曲线如图 8 所示, 迭代前 10 000 次 4 种神经网络的训练用时如表 4 所示。

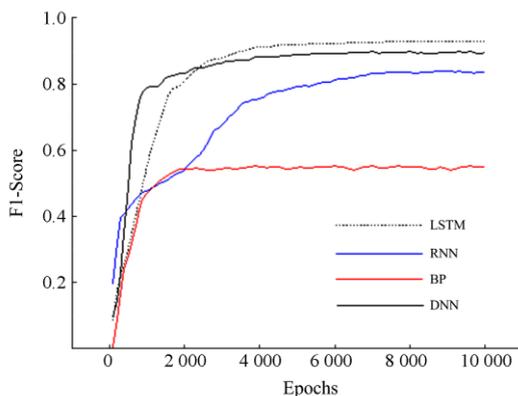


图 7 4 种神经网络 F1-Score 曲线

Fig. 7 Four kinds of neural network F1-Score curves

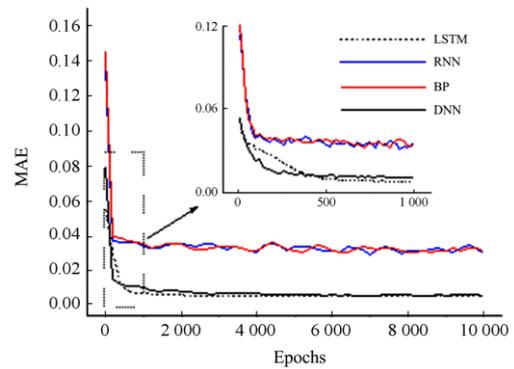


图 8 4 种神经网络 MAE 曲线

Fig. 8 Four kinds of neural network MAE curves

表 4 4 种神经网络训练用时

Table 4 Four kinds of neural network training time

神经网络	LSTM	RNN	BP	DNN
训练用时/h	18.9	5.35	1.45	1.46

从图 7 中可以看出, LSTM 网络的 F1-Score 曲线波动最小且稳定后值最高, 前期收敛速度略低于 DNN, 最后都在迭代次数为 4 000 左右趋于稳定。而 RNN 和 BP 的 F1-Score 值稳定后明显低于 LSTM, 且曲线波动较大。

从图 8 中可以看出, LSTM 网络的 MAE 收敛速度相对较慢, 但曲线波动最小, 稳定后值低于另外 3 种网络。RNN 和 BP 的 MAE 值稳定后明显高于 LSTM 和 RNN, 且曲线波动较大。

从表 4 中可以看出, LSTM 网络结构最复杂导致训练用时也最长。

通过对各个网络训练过程中的 F1-Score 和 MAE 曲线分析, 可以得出 LSTM 网络优化效果最佳。

最后将训练好的 4 种模型用同样的测试集进行多次测试后, 各项评价标准平均值对比情况如图 9 所示。

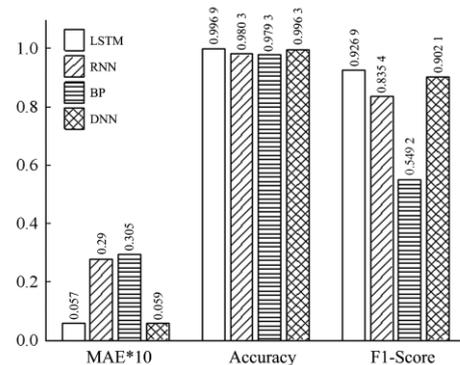


图 9 实际故障下不同神经网络故障诊断效果

Fig. 9 Fault diagnosis results of different neural networks under actual failure

从图 9 可以看出:测试集上 LSTM 网络的 MAE 值明显低于 BP 和 RNN 网络, 略低于 DNN 网络, 达到 0.005 7; F1-Score 值和 Accuracy 值也明显高于 BP 和 RNN 网络, 高于 DNN 网络, 达到 92.69% 和 99.69%。

由此可知, LSTM 神经网络模型的长时记忆和解决梯度消失等能力在智能变电站继电保护测试实际故障情况的诊断中得到很好发挥。

表 5 特殊故障下不同神经网络故障诊断效果

Table 5 Fault diagnosis results of different neural networks under special failure

神经网络	MAE	MAE 上升率/%	Accuracy/%	Accuracy 下降率/%	F1-score/%	F1-score 下降率/%
LSTM	0.006 9	21.05	99.51	0.181	88.92	4.07
RNN	0.040 2	38.62	97.73	0.306	79.50	4.84
BP	0.040 3	32.13	96.96	0.990	49.79	8.86
DNN	0.007 3	23.73	99.41	0.221	87.75	2.79

对表 5 分析可以得到以下结论:

1) 不可靠信息对所有神经网络都有影响, 其中影响最大的是 MAE 值。

2) 在所有评价标准值变差后 LSTM 网络模型的 MAE、Accuracy 和 F1-Score 值依旧很好且明显优于 RNN 和 BP。

3) LSTM 评价标准值平均变化率最低, 其次是 DNN、RNN 和 BP。

根据以上结论得出在信息不可靠情况下基于 LSTM 的模型依旧具备很好的故障诊断能力, 且受不可靠信息的影响最小, 容错性能良好, 满足工程要求。表明 LSTM 网络通过其内部的遗忘门、输入门、输出门和自身循环结构可对前面的信息进行选择性记忆并应用于当前输出, 对历史信息有更好的选择性^[30], 可以明显降低不可靠数据对诊断效果的影响, 拥有良好的容错性。

4 结论

本文建立了基于 LSTM 网络的多故障诊断模型。以典型的智能变电站 220 kV 继电保护测试为例, 将 LSTM 与 RNN、BP 和 DNN 网络模型对比, 经过 10 000 次迭代后:实际故障情况下, LSTM 模型的准确率可达到 99.69%, 同时平均误差下降到 0.005 7; 在特征信息丢失或误报的情况下, LSTM 模型的准确率仍可达到 99.51%, 智能变电站运行环境日趋复杂, 此故障诊断模型可以降低信息本身不可信程度对故障诊断的影响。通过实验仿真验证了基于 LSTM 网络的继电保护测试故障诊断方法具有较高的精度与良好的容错性能。

3.3.2 信息不可靠情况下模型容错性分析

信息不可靠指的是故障特征集中出现特征信息畸变或丢失的情况^[29], 将 2 169 组测试样本集中 217 组样本集换为不可靠样本集, 用之前训练好的 4 种模型重新进行测试。通过观察输入部分不可靠数据情况下 4 种模型的 MAE 上升率、Accuracy 和 F1-Score 下降率来分析各个模型的容错性, 诊断效果如表 5 所示。

参考文献

- [1] 李保恩. 智能变电站继电保护装置自动测试平台的研究和应用[J]. 电力系统保护与控制, 2017, 45(7): 131-135.
LI Baoen. Research and application of automatic test platform for intelligent substation relay protection device[J]. Power System Protection and Control, 2017, 45(7): 131-135.
- [2] 杨帅, 王开科, 南东亮, 等. 继电保护装置自动化检测系统的研究及应用[J]. 电气技术, 2020, 21(4): 116-121.
YANG Shuai, WANG Kaike, NAN Dongliang, et al. Research and application of automatic detection system for relay protection devices[J]. Electrical Technology, 2020, 21(4): 116-121.
- [3] 申洪明, 宋璇坤, 姚玉海, 等. 规模化电力电子装置接入对换流变保护策略的影响分析及对策研究[J]. 高压电器, 2020, 56(3): 230-233, 252.
SHEN Hongming, SONG Xuankun, YAO Yuhai, et al. Effect of large-scale power electronic equipment on converter transformer protection strategy and countermeasure[J]. High Voltage Apparatus, 2020, 56(3): 230-233, 252.
- [4] 张羲海, 张葛祥, 王健, 等. 计及继电保护与油气信息的变压器故障推理[J]. 高压电器, 2020, 56(9): 136-143.
ZHANG Xihai, ZHANG Gexiang, WANG Jian, et al. Transformer fault reasoning under relay protection and gas dissolved in oil information[J]. High Voltage Apparatus, 2020, 56(9): 136-143.
- [5] 陈鹤冲, 陈轩恕, 刘波, 等. 一种发电机保护用断路器布置方案的动稳定校核及仿真分析[J]. 高压电器, 2020, 56(7): 86-93.

- CHEN Hechong, CHEN Xuanshu, LIU Bo, et al. Dynamic stability check and simulation analysis of a circuit breaker layout scheme for generator protection[J]. High Voltage Apparatus, 2020, 56(7): 86-93.
- [6] 陈海涛, 张学敏, 戴伟康, 等. 基于GA优化SVM参数与云模型的继电保护装置状态评估方法[J]. 智慧电力, 2020, 48(7): 88-92, 117.
- CHEN Haitao, ZHANG Xuemin, DAI Weikang, et al. State assessment method of relay protection device based on GA optimization SVM parameters and cloud model[J]. Smart Power, 2020, 48(7): 88-92, 117.
- [7] 李静, 汤大海, 陈永明, 等. 基于改进当地故障信息的220 kV变压器死区故障保护装置的研制[J]. 广东电力, 2021, 34(9): 87-97.
- LI Jing, TANG Dahai, CHEN Yongming, et al. Development of dead zone fault protection device for 220 kV transformer based on improved local fault information[J]. Guangdong Electric Power, 2021, 34(9): 87-97.
- [8] 薛钟, 董贝, 张云, 等. 继电保护装置研发的资源配置技术研究[J]. 电力系统保护与控制, 2018, 46(4): 144-149.
- XUE Zhong, DONG Bei, ZHANG Yun, et al. Resource configuration technical research for relay protection device[J]. Power System Protection and Control, 2018, 46(4): 144-149.
- [9] 黄鸣宇, 祁升龙, 芦翔, 等. 面向配网保护的集分联合馈线自动化控制方法[J]. 河南师范大学学报(自然科学版), 2020, 48(5): 49-54.
- HUANG Mingyu, QI Shenglong, LU Xiang, et al. Combined centralized and distributed control method for distribution network protection[J]. Journal of Henan Normal University (Natural Science Edition), 2020, 48(5): 49-54.
- [10] 翟嘉琪, 杨希祥, 程玉强, 等. 机器学习在故障检测与诊断领域应用综述[J]. 计算机测量与控制, 2021, 29(3): 1-9.
- ZHAI Jiaqi, YANG Xixiang, CHENG Yuqiang, et al. Overview of application of fault detection and diagnosis based on machine learning[J]. Computer Measurement and Control, 2021, 29(3): 1-9.
- [11] 王文焕, 郭鹏, 祝洁, 等. 基于故障树及贝叶斯网络的继电保护系统风险评估及故障定位方法[J]. 电力科学与技术学报, 2021, 36(4): 81-90.
- WANG Wenhuan, GUO Peng, ZHU Jie, et al. Fault positioning and risk assessment method of relay protection based on fault tree and Bayesian network[J]. Journal of Electric Power Science and Technology, 2021, 36(4): 81-90.
- [12] 袁文海, 刘彪, 徐浩, 等. 基于复合神经网络的GIS局放故障类型识别[J]. 电力科学与技术学报, 2021, 36(4): 157-164.
- YUAN Wenhai, LIU Biao, XU Hao, et al. Partial discharge fault type identification of GIS based on composite neural network[J]. Journal of Electric Power Science and Technology, 2021, 36(4): 157-164.
- [13] 任守纲, 张景旭, 顾兴健, 等. 时间序列特征提取方法研究综述[J]. 小型微型计算机系统, 2021, 42(2): 271-278.
- REN Shougang, ZHANG Jingxu, GU Xingjian, et al. Overview of feature extraction algorithms for time series[J]. Small Microcomputer System, 2021, 42(2): 271-278.
- [14] 李春林, 熊建斌, 苏乃权, 等. 深度学习在故障诊断中的应用综述[J]. 机床与液压, 2020, 48(13): 174-184.
- LI Chunlin, XIONG Jianbin, SU Naiquan, et al. Application review of deep learning in fault diagnosis[J]. Machine Tool & Hydraulics, 2020, 48(13): 174-184.
- [15] HAMDI H, REDAYA C B, ZAAFOURI A. A sliding-neural network control of induction-motor-pump supplied by photovoltaic generator[J]. Protection and Control of Modern Power Systems, 2019, 4(4): 306-322.
- [16] 吴迪, 汤小兵, 李鹏, 等. 基于深度神经网络的变电站继电保护装置状态监测技术[J]. 电力系统保护与控制, 2020, 48(5): 81-85.
- WU Di, TANG Xiaobing, LI Peng, et al. State monitoring technology of substation relay protection device based on deep neural network[J]. Power System Protection and Control, 2020, 48(5): 81-85.
- [17] 丁石川, 厉雪衣, 杭俊, 等. 深度学习理论及其在电机故障诊断中的研究现状与展望[J]. 电力系统保护与控制, 2020, 48(8): 172-187.
- DING Shichuan, LI Xueyi, HANG Jun, et al. Deep learning theory and its application to fault diagnosis of an electric machine[J]. Power System Protection and Control, 2020, 48(8): 172-187.
- [18] 马立玲, 刘潇然, 沈伟, 等. 基于一种改进的一维卷积神经网络电机故障诊断方法[J]. 北京理工大学学报, 2020, 40(10): 1088-1093.
- MA Liling, LIU Xiaoran, SHEN Wei, et al. Motor fault diagnosis method based on an improved one-dimensional convolutional neural network[J]. Transactions of Beijing Institute of Technology, 2020, 40(10): 1088-1093.
- [19] 安灵旭, 唐其筠, 李中成, 等. 人工智能在配电网运维中的应用研究[J]. 电气技术, 2019, 20(10): 103-106.
- AN Lingxu, TANG Qiyun, LI Zhongcheng, et al. Research on the application of artificial intelligence in operation maintenance of distribution system[J]. Electrical Technology, 2019, 20(10): 103-106.

- 2019, 20(10): 103-106.
- [20] 韩学森, 刘博文, 李永杰, 等. 基于模糊和灰色关联的配电自动化开关柜故障诊断方法[J]. 电力科学与技术学报, 2021, 36(2): 107-115.
HAN Xuesen, LIU Bowen, LI Yongjie, et al. A fault diagnosis method for distribution automation switch cabinet based on fuzzy and gray correlation[J]. Journal of Electric Power Science and Technology, 2021, 36(2): 107-115.
- [21] SHI, XU H, LI M, et al. Deep learning for household load forecasting — a novel pooling deep RNN[J]. IEEE Transactions on Smart Grid, 2018, 9(5): 5271-5280.
- [22] HOU B, ZHOU Z. Learning with interpretable structure from gated RNN[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(7): 2267-2279.
- [23] MA J, LIU H, PENG C, et al. Unauthorized broadcasting identification: a deep LSTM recurrent learning approach[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(9): 5981-5983.
- [24] 李鹏, 何帅, 韩鹏飞, 等. 基于长短期记忆的实时电价条件下智能电网短期负荷预测[J]. 电网技术, 2018, 42(12): 4045-4052.
LI Peng, HE Shuai, HAN Pengfei, et al. Short-term load forecasting of smart grid based on long-short-time memory recurrent neural networks in condition of real-time electricity price[J]. Power System Technology, 2018, 42(12): 4045-4052.
- [25] 王子馨, 胡俊杰, 刘宝柱. 基于长短期记忆网络的电力系统量测缺失数据恢复方法[J]. 电力建设, 2021, 42(5): 1-8.
WANG Zixin, HU Junjie, LIU Baozhu. Recovery method for missing measurement data of power systems based on long short-term memory networks[J]. Electric Power Construction, 2021, 42(5): 1-8.
- [26] 刘皓琪, 高飞, 王耀力, 等. 基于 Dropout-ILSTM 网络的短期电力负荷预测[J]. 电测与仪表, 2021, 58(5): 105-111.
LIU Haoqi, GAO Fei, WANG Yaoli, et al. Short-term power load forecasting based on dropout-ILSTM network[J]. Electrical Measurement & Instrumentation, 2021, 58(5): 105-111.
- [27] 李亮玉, 唐宝锋, 赵贤龙, 等. 智能变电站就地化保护研究现状及应用展望[J]. 华电技术, 2018, 40(5): 17-24.
LI Liangyu, TANG Baofeng, ZHAO Xianlong, et al. Research on status and application prospect of locally installed protection of intelligent substation[J]. Huadian Technology, 2018, 40(5): 17-24.
- [28] 王德林, 裘愉涛, 凌光, 等. 变电站即插即用就地化保护的应用方案和经济性比较[J]. 电力系统自动化, 2017, 41(16): 12-19.
WANG Delin, QIU Yutao, LING Guang, et al. Application scheme and economical comparison of plug & play and outdoor installation protection in substation[J]. Automation of Electric Power Systems, 2017, 41(16): 12-19.
- [29] 陈家超, 张勇军, 黄国权, 等. 计及保护和断路器告警信息可信度的电网故障诊断优化模型[J]. 电力系统保护与控制, 2021, 49(4): 28-36.
CHEN Jiachao, ZHANG Yongjun, HUANG Guoquan, et al. Optimal model of power grid fault diagnosis considering reliability of protection and circuit breaker alarm information[J]. Power System Protection and Control, 2021, 49(4): 28-36.
- [30] 杨智伟, 刘灏, 毕天姝, 等. 基于长短期记忆网络的 PMU 不良数据检测方法[J]. 电力系统保护与控制, 2020, 48(7): 1-9.
YANG Zhiwei, LIU Hao, BI Tianshu, et al. PMU bad data detection method based on long short-term memory network[J]. Power System Protection and Control, 2020, 48(7): 1-9.

收稿日期: 2021-05-24; 修回日期: 2021-10-10

作者简介:

陈桂芳(1996—), 女, 硕士研究生, 研究方向为电力系统及其自动化; E-mail: 1181075814@qq.com

董秀成(1963—), 男, 通信作者, 教授, 硕士研究生导师, 研究方向为数字化智能测控与装置; E-mail: dxc136@163.com

郑永康(1977—), 男, 博士, 教授级高工, 研究方向为继电保护、智能变电站二次技术、智能优化算法。E-mail: zyk555@163.com

(编辑 葛艳娜)