

# 基于长短期记忆神经网络的光伏阵列故障诊断

张文军, 林永君, 李静, 陈颖

(华北电力大学新能源电力系统国家重点实验室, 河北保定 071003)

**[摘要]** 目前的故障诊断方法无法精确识别与定位光伏发电系统中光伏阵列的故障, 导致光伏发电运维成本增加。为此, 本文提出一种基于长短期记忆(LSTM)神经网络的光伏阵列故障诊断模型。在MATLAB/Simulink软件环境下, 搭建光伏发电系统仿真模型, 采用扰动观测的最大功率点跟踪(MPPT)算法和电网电压闭环控制策略, 分析光伏组件断路和遮挡等故障的机理, 并对光伏阵列故障状态进行仿真, 研究不同故障状态对光伏系统输出特性的影响, 进而获取故障特征参数。建立LSTM神经网络故障诊断模型, 采集光伏阵列在不同故障条件下的特征参数作为训练样本, 对模型进行训练, 并与BP神经网络模型进行比较, 发现LSTM神经网络模型的测试正确率高于BP神经网络。采用光伏实验平台模拟不同光伏阵列故障, 将故障特征参数输入LSTM神经网络故障诊断模型进行诊断, 结果表明, LSTM神经网络故障诊断模型能够精确识别和定位光伏阵列故障。

**[关键词]** 光伏阵列; 故障诊断; Simulink; 最大功率点跟踪算法; 长短期记忆神经网络; 数值模拟

**[中图分类号]** TM615 **[文献标识码]** A **[DOI编号]** 10.19666/j.rfd.202009249

**[引用本文格式]** 张文军, 林永君, 李静, 等. 基于长短期记忆神经网络的光伏阵列故障诊断[J]. 热力发电, 2021, 50(6): 60-68. ZHANG Wenjun, LIN Yongjun, LI Jing, et al. Fault identification for photovoltaic power generation system based on long short-term memory[J]. Thermal Power Generation, 2021, 50(6): 60-68.

## Fault identification for photovoltaic power generation system based on long short-term memory

ZHANG Wenjun, LIN Yongjun, LI Jing, CHEN Ying

(State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Baoding 071003, China)

**Abstract:** In view of the frequent faults of the existing photovoltaic array, simple monitoring and fault diagnosis can not accurately identify and locate the fault, resulting in an increase in operation and maintenance costs and a reduction in the economic benefits of photovoltaic power generation. To solve this problem, this paper proposes a photovoltaic system fault identification strategy based on long-short term memory (LSTM) neural network, establishes the mathematical model of photovoltaic array, and builds the photovoltaic system simulation model in MATLAB/Simulink environment, by using the maximum power point tracking (MPPT) algorithm based on disturbance observation and the closed-loop control strategy based on grid voltage. The fault causes of photovoltaic module such as open circuit and occlusion are analyzed, and the fault state of photovoltaic array is simulated in MATLAB, the influence of different fault states on the output characteristics of photovoltaic system is studied, and the fault characteristic parameters are obtained. The LSTM deep learning fault diagnosis model is established, and the characteristic parameters of photovoltaic array under different fault conditions are collected as training samples to train the model. It shows the LSTM neural network model has higher accuracy than the BP neural network. The photovoltaic experimental platform is applied to simulate different photovoltaic array faults, and the fault characteristic parameters are input into the LSTM neural network fault diagnosis model for diagnosis. The results show that, the LSTM depth learning fault diagnosis model can accurately diagnose and locate the PV array faults.

**Key words:** photovoltaic panels, fault diagnosis, Simulink, maximum power point tracking, long-short term memory neural network, numerical simulation

收稿日期: 2020-09-06

基金项目: 中央高校基本科研业务费专项资金资助(2019MS100)

Supported by: Fundamental Research Funds for the Central Universities (2019MS100)

第一作者简介: 张文军(1995), 男, 硕士研究生, 主要研究方向为光伏发电系统故障诊断, 1016343877@qq.com。

通信作者简介: 李静(1979), 女, 硕士, 工程师, 主要研究方向为光伏发电功率预测, 7536005@qq.com。

近年来,随着经济的快速发展,能源消耗越来越大。光伏发电作为一种重要的清洁可再生能源,得到迅猛发展。光伏阵列是光伏发电系统核心组件,经常裸露在室外环境中,容易受到雨水和高温的侵蚀,加之自身材料老化,导致光伏阵列中故障频发,影响光伏发电的经济效益。

国内外学者对光伏阵列故障识别开展了一系列研究。Kamran 等人<sup>[1]</sup>提出了一种基于贝叶斯分类器的光伏阵列故障识别方法,该方法只针对光伏热斑和光伏组件损坏,并需要红外热像仪采集大量的光伏阵列图像;Amit 等人<sup>[2]</sup>通过比较光伏阵列故障残差信号和预设阈值,实现故障监测与定位,该方法只针对光伏阵列串内故障和跨串故障;Mohamed 等人<sup>[3]</sup>提出一种通过计算故障特定阈值范围的方法来识别光伏系统故障,该方法能够对实验中模拟的2种接线故障和3种阴影遮挡进行识别,但并没有量化给出模型的准确度;Elyes 等人<sup>[4]</sup>提出一种基于预测模型的故障检测方法,将单二极管测量值与预测值之间的残差做为故障特征来识别故障类型,但该方法故障识别精度依赖于预测模型的训练参数,动态性能较差。

国内学者毕锐等<sup>[5]</sup>提出一种基于模糊C均值聚类的在线故障诊断方法,将采集数据的特征量与聚类后的故障类型通过比较隶属度大小来识别故障,但该方法故障识别准确率较低;丛伟伦等<sup>[6]</sup>提出一种基于马尔科夫链的光伏电站阴影遮挡判别方法,该方法只针对固定遮挡和随机遮挡,故障类型单一;张晓娜等<sup>[7]</sup>提出一种全局分块逐步逼近的方法来实现光伏组件故障检测和定位,通过比较分块区域的电压平均值与区域内各数据点的相对误差进行故障诊断,但并未对光伏故障类型进行区分;吴建明等<sup>[8]</sup>设计了光伏远程监测数据采集系统,基于物联网技术进行远程数据采集,将采集回的数据量化融合处理,并进行故障分析,但并未给出具体的诊断方法。

根据上述分析可以发现,已有光伏阵列故障识别方法较为单一,识别精确性有待提升。针对光伏阵列多类型故障的识别与定位,本文提出一种基于长短期记忆(LSTM)神经网络和光伏发电系统特征参数的故障识别策略:在MATLAB/Simulink仿真环境下,搭建光伏发电系统仿真模型;在不同故障条件下,采集光伏阵列输出电压、电流、功率、逆变后的电压、电流和不均匀光照强度,提取光伏阵

列的故障特征;采用LSTM神经网络进行故障识别,并通过大量训练,提高模型的辨识度和准确性。

## 1 光伏电池板数学模型

光伏电池板原型是由众多P-N结构成,其数学模型基于电池板中的物理过程以及影响这些过程的因素。依据光伏电池板等效电路可得<sup>[9]</sup>

$$I = I_{PV} - I_D - I_{sh} \quad (1)$$

式中, $I$ 为输出电流, $I_{PV}$ 为光生电流, $I_D$ 为二极管电流, $I_{sh}$ 为光伏漏电流。

结合材料物理和电子学理论,可得光伏电池板数学模型为

$$I = I_{PV} - I_0 \left( e^{\frac{q(V+IR_s)}{nkT}} - 1 \right) - \frac{V + IR_s}{R_{sh}} \quad (2)$$

式中, $I_0$ 为反相过饱和电流值, $q$ 为电量电荷, $n$ 为P-N节理想因子, $k$ 为玻尔兹曼常数, $T$ 为太阳能电池板温度, $V$ 为输出电压, $R_{sh}$ 为等效电路并联电阻, $R_s$ 为等效电路串联电阻。

表1为光伏电池板在标准测试条件下的参数。

表1 光伏电池板参数  
Tab.1 Specifications of the photovoltaic (PV) panels

规格参数	数值
额定功率/W	50
电池板尺寸(长×宽×厚)/mm	630×540×25
电池板效率/%	13.4
最大功率点电压( $V_m$ )/V	18.1
最大功率点电流( $I_m$ )/A	2.85
开路电压( $V_{oc}$ )/V	21.7
短路电流( $I_{sc}$ )/A	3.11

依据表1和光伏电池板的数学模型,可推导出工程模型为:

$$I = I_{SC} \left( S - C_1 \left( e^{\frac{V+R_s D_1}{C_2 V_{oc}}} \right) \right) + \alpha S (T - T_{ref}) \quad (3)$$

$$D_1 = I_{SC} (S - 1) + (\beta / R_s + \alpha S) (T - T_{ref}) \quad (4)$$

$$C_1 = (1 - I_m / I_{SC}) / e^{(-V_m / C_2 / I_{SC})} \quad (5)$$

$$C_2 = (V_m / C_2 - 1) / \ln(1 - I_m / I_{SC}) \quad (6)$$

式中, $I_{SC}$ 为短路电流, $V_{oc}$ 为开路电压, $T_{ref}$ 为基准温度, $S$ 为光照强度, $D_1$ 、 $C_1$ 、 $C_2$ 分别为工程模型内部系数, $V_m$ 为最大功率点电压, $I_m$ 为最大功率点电流, $\alpha$ 、 $\beta$ 为工程模型经验常数。

## 2 光伏发电系统仿真模型

在MATLAB/Simulink环境下,搭建由光伏阵

列、最大功率点跟踪 (MPPT) 控制器、单项逆变控制器等构成的仿真模型。其中 powergui 采样时间设置为  $2 \mu\text{s}$ ，开关管频率设置为  $1 \text{ kHz}$ ，整个光伏发电系统仿真模型如图 1 所示。

光伏阵列由 4 块光伏电池板组成，在标准测试条件下，光照强度为  $1000 \text{ W/m}^2$ ，太阳能电池板温

度为  $25 \text{ }^\circ\text{C}$ ，采用 Simulink 软件建立光伏电池板仿真模型 (图 2)。MPPT 控制器采用扰动观测法，其仿真模型如图 3 所示，通过周期性地扰动光伏阵列输出电压，根据输出功率和输出电压的变化量来决定占空比的改变方向，进而使光伏阵列的输出功率趋于最大功率。

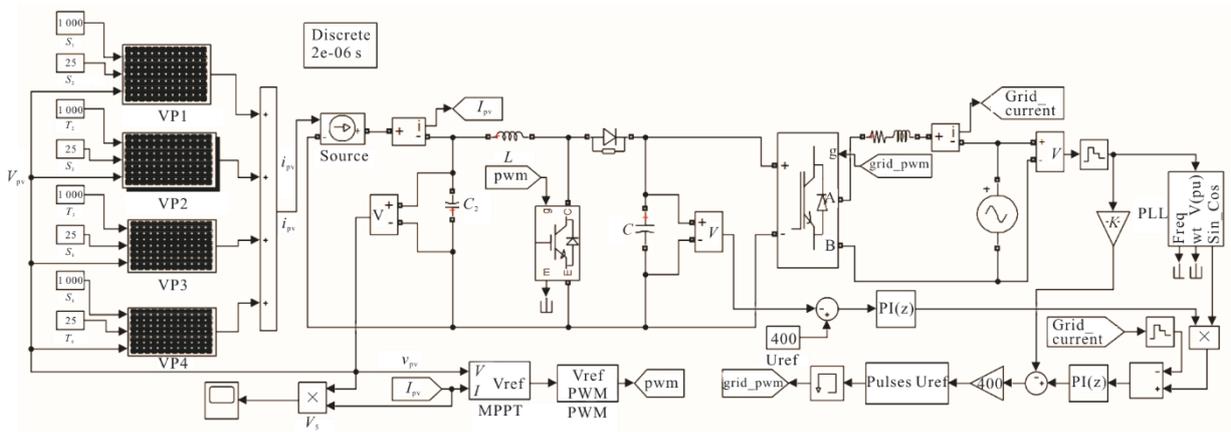


图 1 光伏发电系统仿真模型  
Fig.1 Simulation model of the photovoltaic power generation system

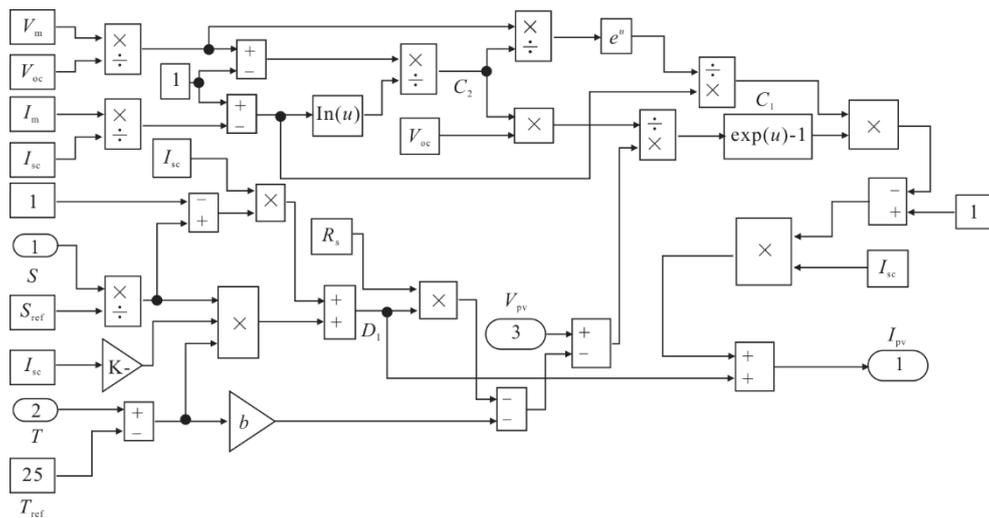


图 2 光伏电池板仿真模型  
Fig.2 Simulation model of the photovoltaic panel

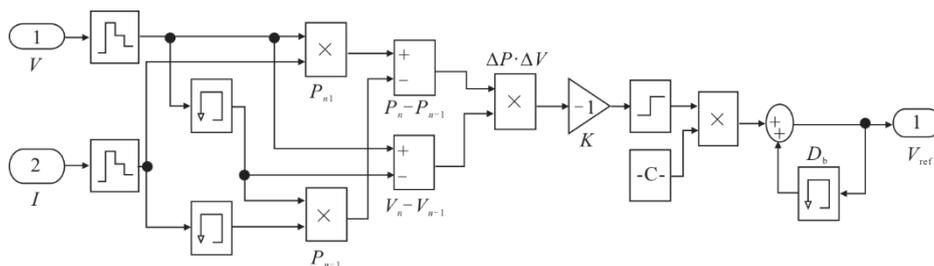


图 3 基于扰动观测的 MPPT 控制器仿真模型  
Fig.3 The MPPT controller simulation model based on disturbance observation

单项逆变控制器通过图 1 中锁相环 (PLL) 计算出电网电压  $V_{grid}$  的相位, 其输出的正弦信号乘以比例增益得到正弦参考电流  $I_{grid}$ , 并与逆变电流进行比较。经 PI 控制器调节后, 输出结果与电网前馈求和, 计算出调制脉宽。最后将该调制波与三角载波进行比较, 输出最终的正弦脉宽调制波, 从而控制双极性晶体管 (IGBT) 的导通与关断。

### 3 光伏阵列故障分析与特征提取

本文选取光伏阵列中常见的断路故障、局部遮挡、阴影遮挡以及光伏阵列热斑等故障进行分析, 研究不同故障对光伏发电系统输出特性的影响, 进而获取故障特征。

采用第 2 节搭建好的光伏发电系统, 在标准状况下, 将其中 1 块电池板光照强度置为 0, 使其输出电流为 0, 来模拟光伏阵列断路故障。阴影遮挡主要通过改变光伏阵列区域光照强度来实现, 产生阴影遮挡的因素很多, 不同阴影其遮挡系数不同。经仿真测试, 发现遮挡系数小于 0.9 时模型可以正确区分, 于是不同程度降低光伏阵列中 2 个光伏模块的光照强度, 来模拟局部遮挡和阴影遮挡故障 (分别选正常光照强度 0.85 倍和 0.3 倍)。同样的情况下, 将 2 个光伏模块遮挡系数调整为 0.9, 且将电池板的温度调高, 来模拟光伏热斑<sup>[10]</sup>。然后分别采集 4 种不同故障和正常情况下的光伏阵列输出电压和电流, 绘制伏安特性曲线, 结果如图 4 所示。

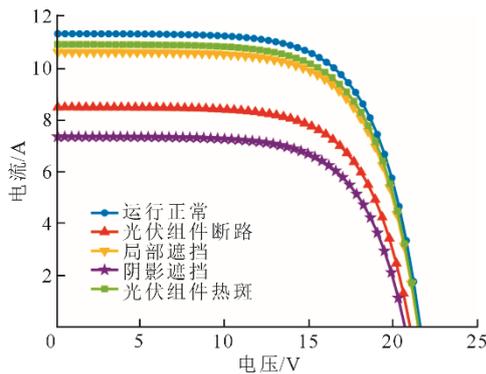


图 4 不同故障情况下光伏阵列的伏安特性曲线  
Fig.4 The volt-ampere characteristic curves of photovoltaic arrays under different fault conditions

由图 4 可见, 光伏阵列 4 种故障不同程度地偏离正常运行工况, 且短路电流明显下降, 其中阴影遮挡工况下短路电流最小。在此基础上, 计算光伏阵列输出功率, 绘制电压功率曲线, 结果如图 5 所

示。由图 5 可见, 随着电压增加, 功率先增大后减小, 不同故障下光伏最大功率区分明显。因此选取光伏阵列输出电压、输出电流以及输出功率来识别光伏故障类型。

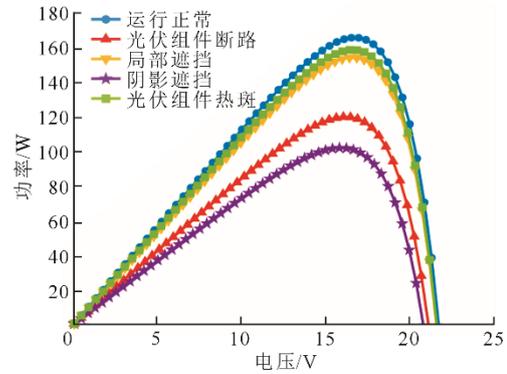


图 5 不同故障情况下光伏阵列的电压功率特性曲线  
Fig.5 The voltage and power characteristic curves of photovoltaic arrays under different fault conditions

运行光伏发电系统, 验证上述所选参数能否满足光伏阵列故障的识别。绘制经 MPPT 控制器输出的最大功率跟踪曲线, 结果如图 6 所示。由图 6 可见, MPPT 控制器能够较好地跟踪光伏阵列输出功率, 并维持在最大功率点附近。不同故障下的输出功率区分明显, 故所选参数满足要求。

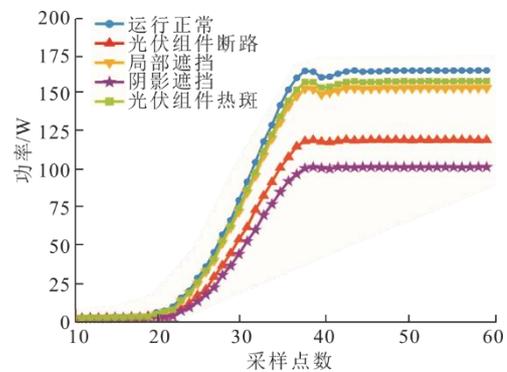


图 6 不同故障情况下光伏阵列的 MPPT 跟踪曲线  
Fig.6 The MPPT tracking curves of photovoltaic array under different fault conditions

当光伏阵列发生故障时, 不仅光伏阵列内部参数与正常状况下不同, 其输出参数及逆变器输出参数也会发生变化<sup>[11-21]</sup>。为了能够进一步精确地识别光伏故障类型, 引入逆变器的输出电压与电流。随着输出功率的减小, 逆变电压与电流也会相应减少。

综上所述, 选用光伏阵列输出电压  $V_{PV}$ 、输出电流  $I_{PV}$ 、输出功率  $P_{PV}$ 、逆变器输出电压  $V_{IN}$ 、输出电流  $I_{IN}$  以及光照强度  $G$  作为识别光伏阵列故障

的特征参数，不同故障情况下的光伏阵列特征参数见表 2。采集光照强度从 400~1 000 W/m<sup>2</sup> 对应的光

伏阵列特征参数，每种故障分别采集 600 组数据样本，构建 3 000 组数据样本集。

表 2 不同故障情况下的光伏阵列特征参数  
Tab.2 The characteristic parameters of photovoltaic array under different fault conditions

故障类型	V <sub>PV</sub> /V	I <sub>PV</sub> /A	P <sub>PV</sub> /W	V <sub>IN</sub> /V	I <sub>IN</sub> /A	G/(W m <sup>-2</sup> )
正常	17.1	9.89	169	220.0	0.716	1 000
	16.3	9.02	148	207.4	0.675	889
	16.2	7.62	123	187.1	0.615	760
开路	15.9	7.67	119	185.2	0.607	1 000
	16.4	6.37	105	173.4	0.568	880
	15.8	5.53	88	157.9	0.518	750
局部遮挡	16.8	9.18	154	210.5	0.691	1 000
	16.2	8.38	136	197.4	0.647	888
	15.5	7.20	112	178.3	0.585	758
阴影遮挡	15.8	5.89	93	162.4	0.532	1 000
	15.7	5.22	83	152.5	0.500	868
	15.6	4.62	73	143.6	0.471	766
光伏电池板热斑	16.9	9.39	159	214.4	0.703	1 000
	16.1	8.51	138	198.2	0.649	870
	15.8	7.24	115	180.4	0.591	750

### 4 光伏阵列故障诊断模型

光伏阵列故障诊断流程如图 7 所示，将采集的光伏阵列数据输入 LSTM 神经网络中进行训练，比较加权残差值 S<sub>i</sub> 与损失值 L 的大小，得出权重和偏置的最优解，最后通过光伏发电系统验证模型的准确性和有效性。

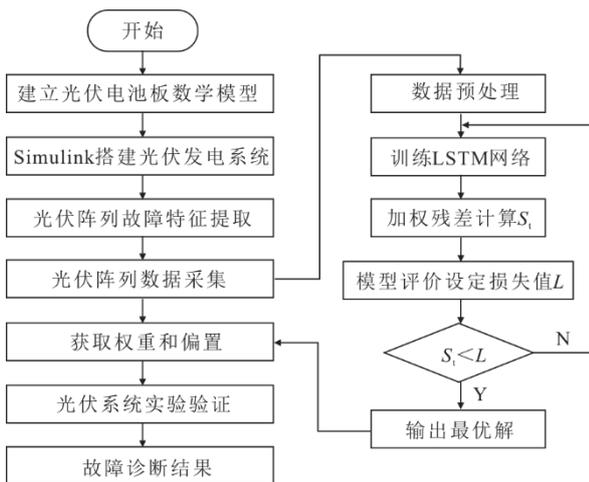


图 7 光伏故障诊断模型  
Fig.7 The PV fault diagnosis model

#### 4.1 LSTM 神经网络深度学习算法

LSTM 神经网络在 1997 年由 Hochreiter 和 Schmidhuber 提出，是循环神经网络 (recurrent neural

network, RNN) 的一种优化算法<sup>[22]</sup>。LSTM 神经网络模型能够有效提高时间序列信息的预测精度，目前已经广泛应用于图像、文档、手写字等领域的识别与分类。LSTM 神经网络原理如图 8 所示。

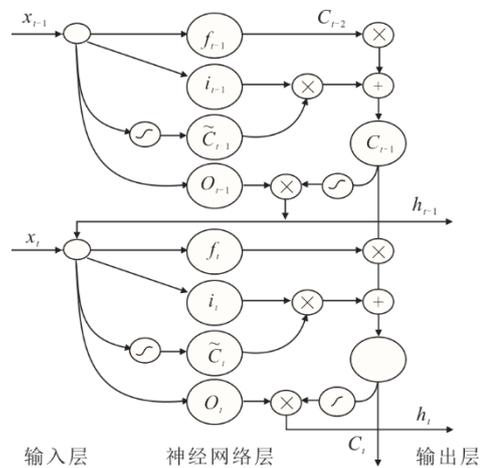


图 8 LSTM 神经网络原理  
Fig.8 Principle diagram of the LSTM neural network

由图 8 可见，LSTM 神经网络中输入层沿网络正向传播，其中包括 f<sub>t</sub> (遗忘门)、i<sub>t</sub> (输入门)、c<sub>t</sub> (当前时刻状态单元)、c̃<sub>t</sub> (当前输入状态单元)、o<sub>t</sub> (输出门)、h<sub>t</sub> (当前时刻输出状态) 6 个向量，各向量计算公式为<sup>[23]</sup>：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (7)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (8)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (9)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (10)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (11)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (12)$$

式中,  $\sigma$  为 sigmoid 激励函数,  $W_f$ 、 $W_i$ 、 $W_c$ 、 $W_o$  分别为遗忘门权重、输入门权重、当前输入状态单元权重和输出门权重,  $h_{t-1}$ 、 $x_t$  分别为上一时刻输出和当前时刻输入,  $b_f$ 、 $b_i$ 、 $b_c$ 、 $b_o$  分别为遗忘门偏置、输入门偏置、当前输入状态单元偏置和输出门偏置。

#### 4.2 数据预处理与模型评估

基于对光伏阵列故障特征的分析,分别采集 4 种不同故障和正常情况下光伏阵列的 3 000 组样本集。为确保模型能够有效地进行分类训练,对采样数据进行降噪和归一化处理。为了比较不同故障类型特征参数,通过设置不同故障特征归一化后的盒形图来直观地显示归一化的性能,结果如图 9 所示。

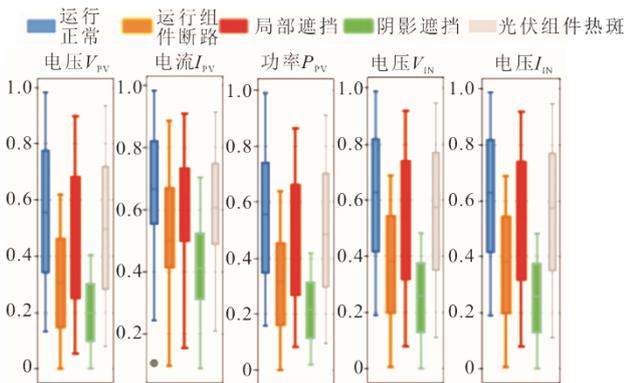


图 9 不同故障特征参数归一化后的盒形图  
Fig.9 The boxplot diagram of different fault characteristic parameters after normalization

从采集样本中选取 2 400 组作为训练样本, 600 组作为测试样本。本文采用模型训练的正确率以及交叉熵损失函数 (Loss), 做为 2 个评估指标, 对光伏故障分类效果进行评估。其中 Loss 是真实值与预测值对数乘积的累加和, 当模型输出与期望输出越接近时, Loss 函数值越小, 模型分类效果越好。其计算公式为

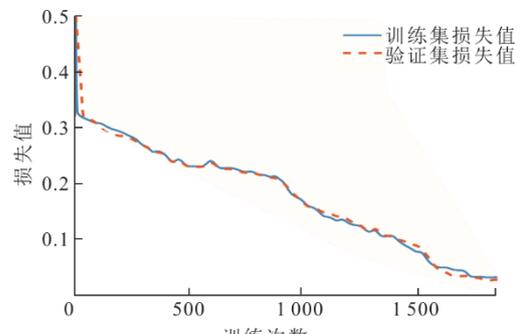
$$L = -\frac{1}{n} \sum_{i=1}^n (y_i \ln p_i + (1 - y_i) \ln(1 - p_i)) \quad (13)$$

式中,  $y_i$  为实际故障类型值,  $p_i$  为预测故障类型值,  $n$  为预测序列长度。

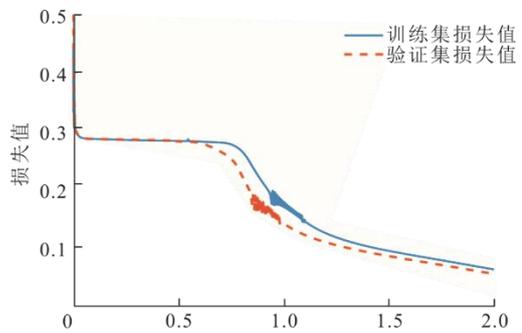
#### 4.3 模型训练

将训练样本集输入 LSTM 神经网络中进行仿真

训练, 并与反向传播 (BP) 神经网络的训练结果进行对比。根据第 3 节提取的故障特征, 将 LSTM 神经网络模型输入层设置为 6 维, 即输入 6 个光伏阵列故障特征参数, 建立全链接层来连接隐藏状态和输出状态信息, 隐藏层节点数设置为 128, 输出层设置为 5 维, 即输出 5 种故障类型 (对应故障类型 1—5)。LSTM 神经网络存储单位采用 sigmoid 激活函数, 对网络训练 2 000 次, 其训练过程模型损失值如图 10 所示。由图 10 可见, 随着迭代次数增加, 损失函数值逐渐减小, LSTM 神经网络在迭代 1 600 次训练后, 实际训练损失值为 0.026 4, 故障分类结果已达到精度要求, BP 神经网络在迭代 20 000 次训练后, 实际训练损失值才达到 0.046 7。



a) LSTM网络



b) BP神经网络

图 10 LSTM 神经网络与 BP 神经网络模型训练过程  
Fig.10 The training process of BP neural network and LSTM network

为进一步验证 LSTM 神经网络深度学习训练结果的准确性, 将 600 组测试样本数据输入训练完成的 LSTM 神经网络和 BP 神经网络模型中, 测试算法故障分类的正确率, 结果见表 3。由表 3 可见, LSTM 神经网络模型的测试集正确率为 99.67%, 相对 BP 神经网络测试结果更为精确。

将 LSTM 神经网络模型测试集的训练结果进行

反归一化处理，输出故障分类结果（图 11）。由图 11 可见，LSTM 神经网络模型只有 2 次将局部遮挡故障误认为阴影遮挡，其余测试数据的故障类型都能准确识别，验证了 LSTM 神经网络故障诊断的可行性和准确性。

表 3 BP 神经网络与 LSTM 神经网络模型训练结果  
Tab.3 The training results of BP and LSTM network model

模型	训练损失	训练正确率/%	测试正确率/%	训练时间/s
BP	0.046 7	95.54	98.96	120
LSTM	0.026 4	99.00	99.67	800

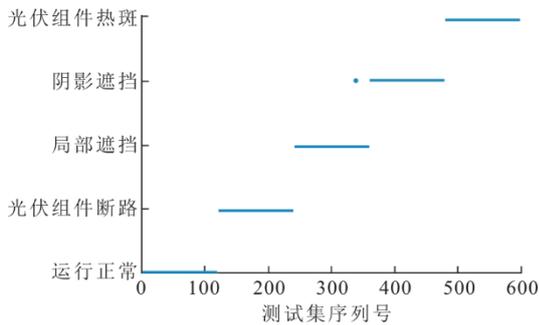


图 11 LSTM 神经网络故障类型识别结果  
Fig.11 The fault type identification result of the LSTM neural network

### 5 实验验证

在华北电力大学光伏实验平台进行实验验证，其中光伏阵列由 32 个光伏电池板构成，倾角 48°，选用 4 块输出特征高度一致的电池板，设置编号为 PV1—PV4。其连接方式如图 12 所示，电池板的工作参数见表 1。

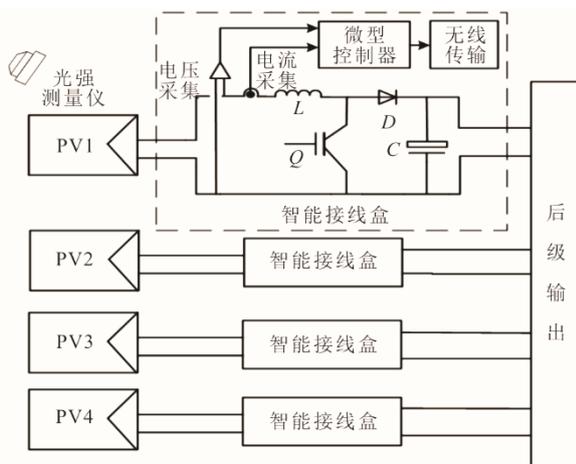
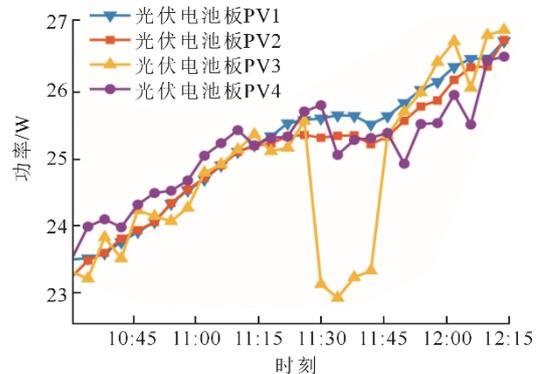


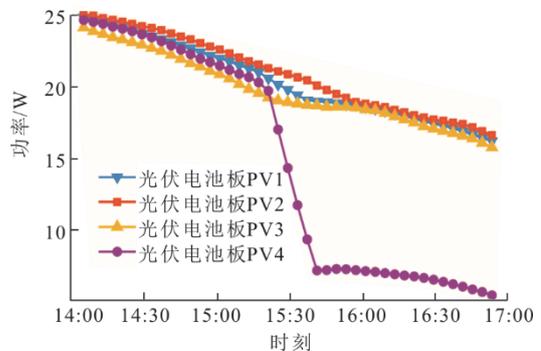
图 12 光伏系统电池板连接示意  
Fig.12 The PV panel connection diagram

首先模拟光伏阵列开路故障，人为断开 PV1 电池板输出端，记录光伏发电系统的特征参数。其次

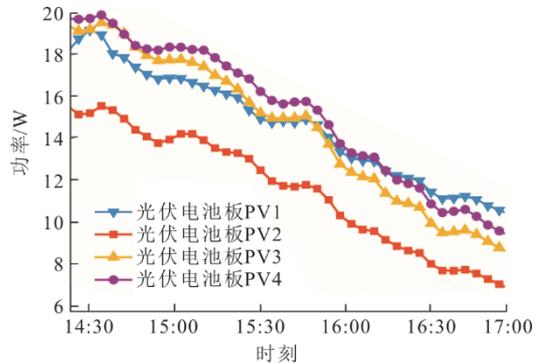
模拟光伏电池板表面附着一些纸片或树叶等遮挡物而产生局部遮挡故障。本文于 2019 年 8 月 31 日采集 10:30—12:30 晴天工况下光伏电池板的输出特性，并于 11:25 人为在 PV3 电池板表面放一小块遮挡物，测量 15 min，观测其输出功率变化情况。并于 2019 年 9 月 24 日 14:00—17:00 晴天工况下及电池板 PV4 在 15:33 时被建筑物遮挡形成阴影遮挡故障时，测量电池板输出功率变化曲线。将 PV2 电池板暴露在室外 7 天，其他电池板用清水清洗干净。于 2019 年 7 月 26 日 14:30—17:00 晴天工况下，测量光伏电池板输出功率。不同故障情况下输出功率曲线如图 13 所示。



a) 光伏电池板局部遮挡故障



b) 光伏电池板阴影遮挡故障



c) 光伏电池板积灰故障

图 13 不同故障情况下输出功率曲线  
Fig.13 The output power curves of photovoltaic panel under different faults

由图13可见, 光伏电池板输出功率在有遮挡物时有一段明显下降, 当拿走遮挡物功率恢复正常。类似于阴影遮挡, 当光伏电池板表面覆盖一层积灰时, 会影响光伏电池板的发电效率, 长期不清洗会

影响光伏电池板的使用寿命。积灰后的PV2电池板输出功率明显下降。将采集的不同故障下的特征参数输入训练好的LSTM神经网络模型中, 其输出结果见表4。

表4 4×1阵列中不同辐照度的故障检测、识别及定位实验结果  
Tab.4 Experimental results of fault detection, identification and location at different irradiance levels in 4×1 arrays

光照强度/(W m <sup>-2</sup> )	光伏特征参数					故障识别	故障定位	准确率
	V <sub>PV</sub> /V	I <sub>PV</sub> /A	P <sub>PV</sub> /W	V <sub>IN</sub> /V	I <sub>IN</sub> /A			
1 003.0	13.70	1.950	26.72	42.10	0.670	正常	-	√
759.0	12.63	1.800	22.77	38.43	0.612	正常	-	√
554.7	14.68	1.050	15.39	30.62	0.503	正常	-	√
1 000.0	0	0	0	0	0	开路	PV1	√
880.0	13.82	1.660	23.04	38.59	0.612	局部遮挡	PV3	√
750.0	13.96	1.688	23.58	39.06	0.628	局部遮挡	PV3	√
1 000	13.52	1.770	23.91	39.84	0.628	局部遮挡	PV3	√
857.2	15.73	0.971	15.28	32.89	0.432	积灰	PV2	√
644.7	15.5	0.792	12.32	29.45	0.385	积灰	PV2	√
429.6	14.85	0.596	8.80	25.15	0.332	积灰	PV2	√
566.5	15.24	0.438	6.67	17.26	0.327	阴影遮挡	PV4	√
554.7	15.30	0.449	6.87	16.72	0.327	阴影遮挡	PV4	√
463.8	15.74	0.444	6.99	14.78	0.327	阴影遮挡	PV4	√
故障诊断准确率/%								100

由表4可见, 本文LSTM神经网络模型的故障诊断准确率为100%, 能准确识别和定位故障。验证了本文基于LSTM神经网络的光伏发电系统故障识别的有效性和可行性。

## 6 结 论

1) 将LSTM神经网络应用于光伏阵列故障诊断中, 在MATLAB/Simulink环境下, 搭建光伏发电系统仿真模型, 模拟光伏阵列故障, 将采集样本数据输入LSTM神经网络进行故障类型识别与定位。

2) LSTM神经网络光伏阵列故障诊断方法可以准确识别与定位光伏阵列开路、局部遮挡、阴影遮挡和积灰等故障, 对光伏热斑故障可以进行提前预判, 避免对电池板造成不可逆转的损失, 提高光伏阵列的发电效率。

3) 通过仿真和实验, 证明LSTM神经网络故障诊断模型具有较高的可行性和应用潜力, 其故障诊断方法的正确率比BP神经网络提高了3.46%, 且测试集准确率为100%。

### [参 考 文 献]

[1] KAMRAN A K N, WAJAHAT A, HASSAN A, et al. Hotspot diagnosis for solar photovoltaic modules using a Naive Bayes classifier[J]. Solar Energy, 2019, 190: 34-43.

[2] AMIT D, RAHUL S, TAPAN K S. A technique for fault detection, identification and location in solar photovoltaic systems[J]. Solar Energy, 2020, 206: 864-874.

[3] MOHAMED H A, ABDELHAMID R, AHMED E H, et al. Real time fault detection in photovoltaic systems[J]. Energy Procedia, 2017, 111: 914-923.

[4] ELYES G, FOUZI H, YING S, et al. Statistical fault detection in photovoltaic systems[J]. Solar Energy, 2017, 150: 485-499.

[5] 毕锐, 丁明, 徐志成, 等. 基于模糊C均值聚类的光伏阵列故障诊断方法[J]. 太阳能学报, 2016, 37(3): 730-736.

BI Rui, DING Ming, XU Zhicheng, et al. Fault diagnosis method of photovoltaic array based on fuzzy C-means clustering[J]. Journal of Solar Energy, 2016, 37(3): 730-736.

[6] 丛伟伦, 张博, 夏亚东, 等. 基于马尔可夫链的光伏电站遮挡实时诊断算法[J]. 太阳能学报, 2020, 41(4): 67-72.

CONG Weilun, ZHANG Bo, XIA Yadong, et al. Real time diagnosis algorithm for PV power Station occlusion based on Markov chain[J]. Journal of the Solar Energy, 2020, 41(4): 67-72.

[7] 张晓娜, 高德东, 刘海雄, 等. 一种新型光伏阵列多传感器故障检测定位方法[J]. 可再生能源, 2016, 34(2): 166-172.

ZHANG Xiaona, GAO Dedong, LIU Haixiong, et al. A novel multi-sensor fault detection and location method for photovoltaic array[J]. Renewable Energy, 2016, 34(2): 166-172.

[8] 吴建明, 杨培宏, 张继红. 基于物联网的光伏发电系统故障诊断设计[J]. 可再生能源, 2019, 37(1): 65-70.

WU Jianming, YANG Peihong, ZHANG Jihong. Design of diagnosis system for PV power generation based on

- wireless network[J]. *Renewable Energy*, 2019, 37(1): 65-70.
- [9] 吴红斌, 何叶, 金炜, 等. 基于光伏特性和潮流交替迭代的光伏电站稳态等值建模[J]. *太阳能学报*, 2020, 41(2): 333-338.  
WU Hongbin, HE Ye, JIN Wei, et al. Steady state equivalent modeling of photovoltaic plants based on alternating iteration of photovoltaic characteristics and power flow[J]. *Journal of the Solar Energy*, 2020, 41(2): 333-338.
- [10] 李栋军, 李清坤, 郑重. 基于 Simulink 的光伏发电阵列的故障诊断与仿真[J]. *电子制作*, 2016(23): 75-76.  
LI Dongjun, LI Qingkun, ZHENG Zhong. Fault diagnosis and simulation of photovoltaic array based on Simulink[J]. *Practical Electronics*, 2016(23): 75-76.
- [11] 陈静, 刘建忠, 沈望俊, 等. 太阳能热发电系统的研究现状综述[J]. *热力发电*, 2012, 41(4): 17-22.  
CHEN Jing, LIU Jianzhong, SHEN Wangjun, et al. Overview of the research status of solar thermal power generation system[J]. *Thermal Power Generation*, 2012, 41(4): 17-22.
- [12] COLLADO F J, GÓMEZ A, TURÉGANO J A. An analytic function for the flux density due to sunlight reflected from a heliostat[J]. *Solar Energy*, 1986, 37(3): 215-234.
- [13] CRUZ N C, ÁLVAREZ J D, REDONDO J L, et al. A two-layered solution for automatic heliostat aiming[J]. *Engineering Applications of Artificial Intelligence*, 2018, 72: 253-266.
- [14] RIAZ M R. A theory of concentrators of solar energy on a central receiver for electric power generation[J]. *Journal of Engineering for Power*, 1976, 98(3): 375.
- [15] FARINA M, AMATO P. A fuzzy definition of "optimality" for many-criteria optimization problems[J]. *IEEE Transactions on Systems Man & Cybernetics Part A Systems & Humans*, 2004, 34(3): 315-326.
- [16] 杜尔顺, 张宁, 康重庆, 等. 太阳能光热发电并网运行及优化规划研究综述与展望[J]. *中国电机工程学报*, 2016, 36(21): 5765-5775.
- DU Ershun, ZHANG Ning, KANG Chongqing. Reviews and prospects of the operation and planning optimization for grid integrated concentrating solar power[J]. *Proceedings of the CSEE*, 2016, 36(21): 5765-5775.
- [17] 王晓锋, 李睿. 关于我国光热发电发展的思考[J]. *华北电力技术*, 2016(6): 67-70.  
WANG Xiaofeng, LI Rui. Reflections on the development of concentrating solar power in China[J]. *Huadian Technology*, 2016(6): 67-70.
- [18] KEARNEY D. Development of performance acceptance test guidelines for large commercial parabolic trough solar fields[R]. Perpignan: Solar PACES 2010, 2010: 1-2.
- [19] Solar energy - solar thermal collectors - test methods: ISO 9806[S]. Switzerland: International Organization for Standardization, 2017: 36-41.
- [20] STOFFEL T, RENNÉ D, MYERS D, et al. Best practices handbook for the collection and use of solar resource data[R]. Technical Report NREL/TP-550-47465, 2010: 17-42.
- [21] SENGUPTA M, HABTE A, KURTZ S, et al. Best practices handbook for the collection and use of solar resource data for solar energy applications[R]. Technical Report NREL/TP-5D00-63112, 2015: 19-58.
- [22] 刘启斌, 尹温硕, 胡卫华, 等. 基于 LSTM 算法的电力谐波监测数据预测[J]. *电力电容器与无功补偿*, 2019, 40(5): 139-145.  
LIU Qibin, YIN Wenshuo, HU Weihua, et al. Prediction of power harmonic monitoring data based on LSTM algorithm[J]. *Power Capacitors and Reactive Power Compensation*, 2019, 40(5): 139-145.
- [23] 赵勇, 苏丹, 邹丽, 等. 基于 LSTM 神经网络的畸形波预测[J]. *华中科技大学学报(自然科学版)*, 2020, 48(7): 47-51.  
ZHAO Yong, SU Dan, ZOU Li, et al. Rogue wave prediction based on LSTM neural network[J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2020, 48(7): 47-51.

(责任编辑 杜亚勤)