

# 基于 EEMD 和 GA-BP 的列车辅助 逆变器开路故障诊断研究

蔡鹏飞<sup>1,2</sup>, 郑树彬<sup>1</sup>, 彭乐乐<sup>1</sup>

(1. 上海工程技术大学 城市轨道交通学院, 上海 201620; 2. 上海地铁电子科技有限公司, 上海 200233)

**摘要:** 地铁列车随着运营年限增加, 辅助逆变器故障频发, 严重制约轨道交通安全运营, 故障及时诊断至关重要; 针对列车辅助逆变器典型的大功率器件开路故障, 提出了一种基于集合经验模态分解 (EEMD) 和遗传算法优化的 BP 神经网络 (GA-BP) 的故障诊断方法, 该方法以辅助逆变器输出的三相半波电压值为监测信号, 通过 EEMD 分解采用能量矩的方法提取故障特征向量, 基于 GA-BP 神经网络实现故障智能诊断; 仿真实验结果表明该方法故障诊断准确率能达到 95.5%。

**关键词:** 故障诊断; EEMD; 神经网络; GA-BP; 辅助逆变器

## Research on Open-circuit Fault Diagnosis of Train Auxiliary Inverter Based on EEMD and GA-BP

Cai Pengfei<sup>1,2</sup>, Zheng Shubin<sup>1</sup>, Peng Lele<sup>1</sup>

(1. Shanghai University of Engineering Science, Shanghai 201620, China;

2. Shanghai MetroIT Co., Ltd., Shanghai 200233, China)

**Abstract:** As the operation years of metro vehicles increase, the malfunction of auxiliary inverter occurs frequently, which seriously restricts the safe operation of rail transit, and timely diagnosis of faults is essential. Aiming at the typical high power device open-circuit fault for train auxiliary inverter, a fault diagnosis method based on ensemble empirical mode decomposition (EEMD) and genetic algorithm optimized BP neural network (GA-BP) is proposed. The method uses the inverter output three-phase half-wave voltage value as the monitoring signal, and extracts the fault feature vector by means of energy moments through EEMD decomposition. The fault intelligent diagnosis is realized based on GA-BP neural network. Simulation results show that the fault diagnosis accuracy of this method can reach 95.5%.

**Keywords:** fault diagnosis; EEMD; neural network; GA-BP; auxiliary inverter

## 0 引言

据统计, 在地铁列车运营过程中, 辅助逆变器的故障概率较高, 较为严重的辅助逆变器故障可能导致设备无法工作, 使车辆无法正常行驶, 需要在到达终点站后退出运营甚至清客, 这将严重阻碍地铁列车的正常、安全运营<sup>[1]</sup>。

而地铁辅助逆变器的故障类型大致可以划分为二极管短路故障, 直流母线接地故障, 电容故障, 开关设备故障等, 其中在这些故障中, 开关设备故障是最频繁的<sup>[2]</sup>。针对地铁列车辅助逆变器的故障诊断方法已有很多, 文献<sup>[3]</sup>和文献<sup>[4]</sup>分别提出了基于小波包和神经网络的故障诊断方法、基于经验模态分解方法和径向基神经网络的故障诊断方法, 但都只针对地铁列车辅助逆变器的电压波动、脉冲暂态、频率变化等故障进行了研究; 文献<sup>[2]</sup>提出了基于离散小波变换和归一化电流实现对 IGBT 的故障诊断方

法, 但该方法仅对单个 IGBT 开路故障进行诊断; 文献<sup>[5]</sup>提出了通过检测各相电流正、负半波部分对应的功率进而反应各 IGBT 的输出功率和工作状况的方法, 但该方法在辅助逆变器空载情况下故障特征不明显, 需要在带有负载的情况下发生故障才能进行诊断。

本文提出了基于集合经验模态分解 (EEMD) 法和 GA-BP 神经网络的地铁列车辅助逆变器开路故障诊断方法。该方法以辅助逆变器输出的三相半波电压值为测量信号, 采用 EEMD 算法提取故障特征向量, 以此作为故障样本对遗传算法优化的 BP 神经网络进行训练, 实现故障智能化诊断。

## 1 辅助逆变器开路故障分析

### 1.1 辅助逆变器模型建立

以上海地铁 03A01 车型辅助逆变器为研究对象, 在 MATLAB/SIMULINK 软件中搭建一个地铁列车辅助逆变器的故障仿真模型, 该模型分为逆变输出模块和逆变控制模块两部分。逆变输出模块仿真模型如图 1 所示。

构成逆变输出模块的元器件主要有直流电源、线路滤波电感 LFL、线路滤波电容 LFC、放电电阻 DZ、IGBT 逆变桥、三相滤波电感 IOFL、三相滤波电容 IOFC、变压器

收稿日期:2018-12-25; 修回日期:2019-01-15。

基金项目:国家自然科学基金资助(51478258), 上海市科委重点支撑项目(18030501300)。

作者简介:蔡鹏飞(1989-), 男, 湖北仙桃人, 硕士研究生, 主要从事轨道车辆关键部件检测与故障诊断技术方向的研究。




图 1 逆变输出模块仿真模型

模块 IOT 以及三相负载，电路仿真参数设置与实际电路基本一致，基本技术参数如表 1 所示。

表 1 仿真电路主要技术参数

项目	参数	
输入直流电源 UIN	1500 V DC	
线路滤波电感 LFL	6.5 mH	
线路滤波电容 LFC	900 uF	
放电电阻 DZ	68 KΩ	
逆变器输出滤波电感 IOFL	1.1 mH	
逆变器输出滤波电容 IOFC	310 uF	
隔离变压器 IOT	连接方式	Δ/Yn
	额定功率	133 kVA
	额定电压	715/400 V AC

逆变控制模块仿真模型如图 2 所示，通过将三相正弦波和三角载波进行比较运算，调制出所需的 SPWM 波形，实现对逆变模块的控制。逆变器 IGBT 开路故障通过将正常脉冲控制信号和低电平脉冲信号进行“与”运算进行模拟，其中开关 S1—S6 用于控制信号是否正常。

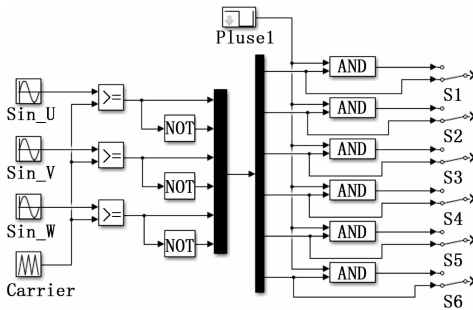


图 2 逆变控制模块仿真模型

调制波 Sin\_U、Sin\_V、Sin\_W 为相位依次相差 120 度的正弦波，频率为 50 Hz。载波 Carrier 为等腰三角波，载波比 N 通常为 3 的整数倍以使三相输出波形严格对称，设载波比 N=12，即载波频率为 600 Hz。调制比 m 与输入直流电源电压  $U_{IN}$ 、输出线电压的基波幅值  $u_{UV}$  的关系为：

$$u_{UV} = \frac{\sqrt{3}}{2} m \cdot U_{IN} \quad (1)$$

其中：输入直流电源电压为 1 500 V，输出线电压的基波幅值为 715 V，计算出调制比 m 为 0.55。

对所建立的辅助逆变器故障仿真模型进行仿真验证，得到仿真电路的输出波形，如图 3 所示。




图 3 逆变器输出三相电压和线电压

辅助逆变器启动后在 0.06 s 达到稳定状态，仿真得到的辅助逆变器输出波形与实际相符，因此本文所建立的辅助逆变器故障仿真模型是有效的。

### 1.2 辅助逆变器开路故障仿真

辅助逆变器逆变电路由 6 个 IGBT 组成，一般情况只有一个 IGBT 故障，最多同时有两个 IGBT 发生故障。因此将辅助逆变器开关器件开路故障分为以下四大类。

- 1) 单个 IGBT 发生故障，共 6 种情况；
- 2) 同一桥臂两个 IGBT 同时发生故障，共 3 种情况；
- 3) 不同桥臂同一位置两个 IGBT 同时发生故障，共 6 种情况；
- 4) 不同桥臂不同位置两个 IGBT 同时发生故障，共 6 种情况。

通过建立的辅助逆变器故障仿真模型对 4 种辅助逆变器开路故障类型进行仿真分析，考虑到仿真模型全部为理想元器件，因此在采样信号中添加均值为 0，方差为 1 的标准正态高斯白噪声，以使仿真更趋于真实。

以辅助逆变器输出三相电的正半波电压信号及其电压值作为测量信号，设置仿真时间为 0.4 s，IGBT 开路故障发生在 0.3 s 时刻，采样频率为 10 kHz。故障仿真所得到的三相半波电压信号如表 2 所示。

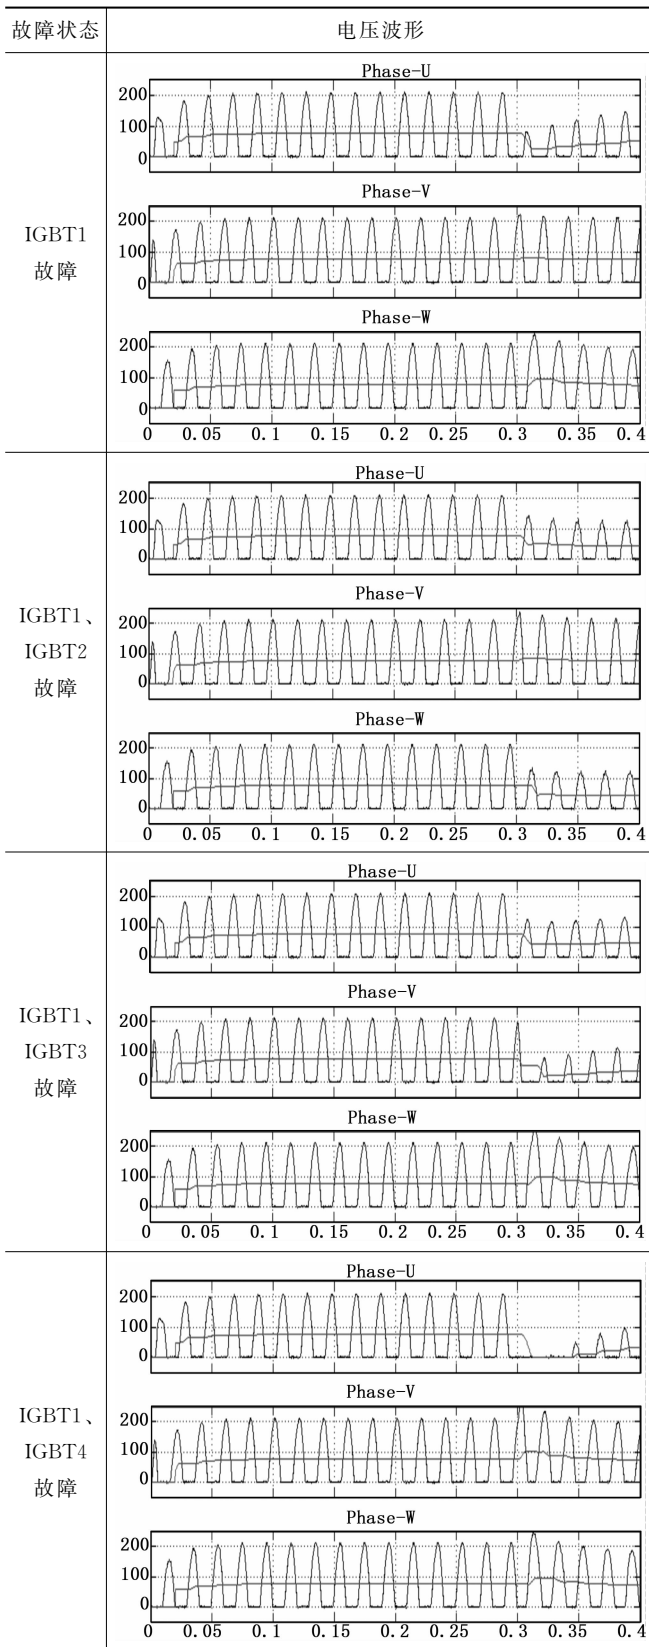
可以看出，当发生辅助逆变器 IGBT 开路故障时，逆变器输出的三相半波电压值会出现明显的异常波动，当发生不同种类的故障情况时逆变器输出的三相半波电压值波动特征不完全相同。当发生 IGBT 故障时三相半波电压信号表现为非线性非平稳特性，测量辅助逆变器输出的三相半波电压值能很好的反应出各 IGBT 的工作状况。

## 2 基于 EEMD 的特征提取

### 2.1 经验模态分解 (EMD) 法

经验模态分解 (EMD) 法是 N. E. Huang 等人在 Hilbert—Huang 变换的基础上，提出的一种非常重要的信号处理的方法<sup>[6]</sup>。该方法从根本上摆脱了傅立叶变换的约束，它是一种新型的自适应信号时频处理方法，是一种非常适用于非平稳、非线性数据序列的复杂信号处理方法。

表 2 IGBT 开路故障的三相半波电压信号



EMD 筛选的过程实际上就是将原始信号分解为不同特征波形的叠加, 将复杂信号分解为有限个具有不同特征尺

度的数据序列, 即本征模态函数 (Intrinsic Mode Function) 分量, IMF 反映了原始信号的本质和真实信息。

基于上述思想, EMD 算法分解得到 IMF 的具体步骤如下:

(1) 找出原始信号  $x(t)$  所有的局部极大值点和极小值点, 采用三次样条函数拟合出信号的上包络线  $U_n$  和下包络线  $L_n$ 。

(2) 上、下包络线的均值为:

$$m_1 = (U_n + L_n) / 2 \quad (2)$$

信号  $x(t)$  与  $m_1$  的差值为:

$$h_1 = x(t) - m_1 \quad (3)$$

如果  $h_1$  满足 IMF 的条件, 则  $h_1$  是原始信号的第一个 IMF 分量, 记为  $c_1 = h_1$ ;

(3) 如果  $h_1$  不满足 IMF 的条件, 则将  $h_1$  作为原始信号, 进行步骤 (1)、(2), 得到:

$$h_{11} = h_1 - m_{11} \quad (4)$$

式中,  $m_{11}$  是  $h_1$  的上、下包络线的均值。

反复筛选  $k$  次, 如果  $h_{1k}$  满足 IMF 的条件, 则  $h_{1k}$  就是原始信号的第一个 IMF 分量, 为:

$$c_1 = h_{1k} = h_{1(k-1)} - m_{1k} \quad (5)$$

(4) 从信号  $x(t)$  中分离出  $c_1$ , 得到:

$$r_1 = x(t) - c_1 \quad (6)$$

$r_1$  作为原始信号重复上述步骤, 得到第二个 IMF 分量  $c_2$ ;

(5) 重复  $n$  次, 就得到  $n$  个 IMF 分量:

$$r_n = r_{n-1} - c_n \quad (7)$$

当  $r_n$  为单调函数或是一个极小的常量时, 停止分解过程, 得到如下式子:

$$x(t) = \sum_{i=1}^n c_i + r_n \quad (8)$$

式中,  $c_i$  为从高频到低频不同频率的各 IMF 分量的集合;  $r_n$  为最终残余分量, 是原始信号  $x(t)$  的集中趋势。

一般认为, 一个本征模态函数 IMF 必须满足以下两个条件<sup>[7]</sup>:

(1) 在整个信号上, 极值点的个数和过零点的个数相等或至多相差一个;

(2) 在任意时刻, 由局部极大值点和局部极小值点分别形成的上、下包络线的均值  $m_i$  为零, 即上、下包络线相对于时间轴是局部对称的。

在实际情况中, 上下包络的均值无法为零, 通常当满足下面式子 (标准偏差系数) 时, 就认为包络的均值满足 IMF 的均值为零的条件:

$$SD = \frac{\sum_{t=0}^T [h_{1(k-1)}(t) - h_{1k}(t)]^2}{\sum_{t=0}^T h_{1(k-1)}^2(t)} \quad (9)$$

式中,  $\epsilon$  称为筛分门限, 一般取值在 0.2~0.3 之间。

## 2.2 集合经验模态分解 (EEMD) 法

对于本征模态函数, 仅仅只能通过窄带信号的过零点

与过极值点的关系以及非常有限的可用例子的经验中获得 IMF 定义,其效果很难令人满意。尽管大部分的例子都表明了 EMD 结果的直观合理性,但是其理论框尚待改善。

针对 EMD 中出现的模态混叠问题,吴朝华和黄锬等人提出了集合经验模态分解<sup>[8]</sup>(Ensemble Empirical Mode Decomposition, EEMD),EEMD 的基本思路是对原始信号多次加入不同的白噪声进行 EMD 分解,将多次分解的结果进行平均即得到最终的 IMF。

EEMD 算法的具体步骤如下:

- 1) 通过给原始信号  $x(t)$  添加白噪声信号  $\omega(t)$  获得目标信号  $X(t)$ ;
- 2) 对  $X(t)$  进行 EMD 分解,得到各阶 IMF 分量;
- 3) 给原始信号添加不同的白噪声  $\omega_i(t)$ ,重复以上步骤得到:

$$x_i(t) = \sum_{j=1}^n c_{ij} + r_m \quad (10)$$

式中,  $c_{ij}$  为加入白噪声  $\omega_i(t)$  后的第  $j$  个 IMF 分量;

- 4) 将上述分解结果进行总体平均运算,消除多次加入白噪声对真的 IMF 的影响,即得到分解结果:

$$c_j = \frac{1}{N} \sum_{i=1}^N c_{ij} \quad (11)$$

EEMD 添加噪声后总体个数满足以下统计公式:

$$\epsilon_n = \frac{\epsilon}{\sqrt{n}} \quad (12)$$

式中,  $n$  是总体个数,  $\epsilon$  是加入白噪声的百分比,  $\epsilon_n$  是最终误差的标准差。当总体个数固定,误差随着添加噪声百分比增加而增加。经过分析对比,  $n$  在几百次时效果较好,推荐添加噪声比例满足最终误差的标准差  $\epsilon_n = 0.2$ 。

为了将添加白噪声后所分解的 IMF 平均,使得相同数据长度的资料每次运算产生的 IMF 具有相近的频率性质,且数目一致利于平均,EEMD 算法固定了筛选的数目。

### 2.3 特征提取

当地铁列车辅助逆变器发生故障时,针对故障信号非平稳非线性特性,采用 EEMD 方法分解故障原始信号得到个 IMF 分量,计算每个包含故障特征信息的 IMF 分量能量,采用能量矩的方法提取故障特征向量,其步骤如下:

- (1) 采样信号为辅助逆变器隔离变压器输出端三相半波电压值,针对每一相电压信号采用 EEMD 方法分解得到若干 IMF 分量,每一相选取前  $m$  个包含有故障信号的 IMF 分量;

- (2) 计算每一相各 IMF 分量的能量  $E_{ui}$ 、 $E_{vi}$ 、 $E_{wi}$ , 其中:

$$E_{wi} = \sum_{k=1}^N |d_{wk}|^2, (i = 1, 2, \dots, m) \quad (13)$$

式中,  $N$  为采样点总数,  $d_{wk}$  为 U 相 IMF 分量的振幅重建信号;

- (3) 计算每相各 IMF 分量能量之和  $E_u$ 、 $E_v$ 、 $E_w$ , 其中:

$$E_u = \sum_{i=1}^m E_{ui} \quad (14)$$

- (4) 计算三相 IMF 分量能量之和  $E$ :

$$E = E_u + E_v + E_w \quad (15)$$

- (5) 计算特征向量  $T$ :

$$T = [E_{ui}/E, E_{vi}/E, E_{wi}/E], (i = 1, 2, \dots, m) \quad (16)$$

### 3 GA-BP 神经网络及其算法

BP 神经网络是一种按误差逆传播算法训练的多层前馈人工神经网络,通过反向传播来不断调整网络的权值和阈值,使网络的误差平方和最小。BP 神经网络模型拓扑结构包括输入层、隐含层和输出层,如图 4 所示。




图 4 BP 神经网络模型拓扑结构图

由于 BP 神经网络采用的算法是基于误差函数梯度下降的方法,该算法实质上是单点搜索算法,不具有全局搜索能力。因此存在学习过程收敛速度慢、容易陷入局部极小点、鲁棒性不好以及网络性能差等缺点<sup>[9]</sup>。针对如何加速网络的收敛速度和避免陷入局部极小值的问题,许多智能算法应用于 BP 神经网络的优化。

遗传算法 (Genetic Algorithms, GA)<sup>[10]</sup>是由密歇根大学 J. Holland 教授在 1975 年首先提出的,是一种模拟生物进化论的自然选择和遗传学理论来搜索问题最优解的自适应全局优化算法。它不依赖于问题的具体模型,具有随机优化和自适应全局搜索的特点。

GA-BP 神经网络模型将遗传算法引入 BP 神经网络训练过程,以网络权值和阈值作为种群个体仿照基因编码,使用样本预测值和观测值的绝对误差值之和作为个体适应度函数,通过选择、交叉、变异操作不断迭代进化,最终得到种群最优个体,解码后得到 BP 神经网络全局最优权值和阈值,从而建立遗传算法优化的 BP 神经网络模型<sup>[12]</sup>。

遗传算法计算过程基本流程如图 5 所示。

遗传算法具体步骤如下:

- (1) 编码。根据所需解决问题选择合适的编码方式,二进制编码是最常用的编码算法。

- (2) 初始化。随机生成  $N$  个个体的初始种群,设置相应的最大进化代数,遗传算法从初始种群开始迭代进化。

- (3) 计算适应度。适应度函数是用来判断群体中个体的优劣程度的指标,即个体接近最优解的程度,一般选取测试集数据误差平方和的倒数作为适应度函数,计算公式如下:

$$f(X) = \frac{1}{SE} = \frac{1}{sse(\hat{T} - T)} = \frac{1}{\sum_{i=1}^n (\hat{t}_i - t_i)^2} \quad (17)$$

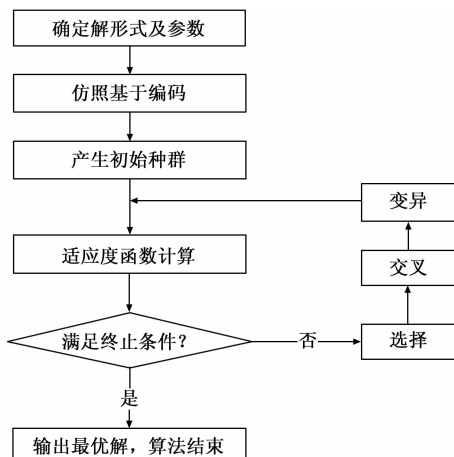


图 5 遗传算法计算流程

式中,  $\hat{T} = \{\hat{t}_1, \hat{t}_2, \dots, \hat{t}_n\}$  为测试集的预测值;  $T = \{t_1, t_2, \dots, t_n\}$  为测试集的真实值;  $n$  为测试集的样本数。

(4) 选择运算。选择运算是按照进化论“适者生存”的原则实现个体筛选的过程, 从当前群体中选择适应度值较高的优良个体, 淘汰适应度值低的劣质个体, 选择运算采用模拟轮盘赌法选择遗传到下一代的个体。

模拟轮盘赌法个体相对适应度计算公式如下:

$$F = \sum_{k=1}^n f(X_k) \quad (18)$$

$$p_k = \frac{f(X_k)}{F}, (k = 1, 2, \dots, n_r) \quad (19)$$

(5) 交叉运算。交叉运算是模拟生物基因重组, 选择同一种群中的两个个体, 随机交换部分基因, 形成两个新的个体的过程。若交叉运算采用实数交叉法, 第  $k$  个染色体  $a_k$  和第  $l$  个染色体  $a_l$  在  $j$  位的交叉运算方法如下:

$$\begin{cases} a_{kj} = a_{lj}(1-b) + a_{kj}b \\ a_{lj} = a_{kj}(1-b) + a_{lj}b \end{cases} \quad (20)$$

式中,  $b$  为  $[0, 1]$  区间内的随机数。

(6) 变异运算。变异运算是模拟基因突变, 随机选择种群个体, 按照一定的变异概率, 改变个体一个或多个基因值, 以产生新个体的过程。变异运算可维持生物个体的多样性, 防止未成熟收敛。选取第  $i$  个个体的第  $j$  个基因  $a_{ij}$  进行变异, 变异运算方法如下:

$$a'_{ij} = \begin{cases} a_{ij} + (a_{ij} - a_{\max}) f(g), & (r > 0.5) \\ a_{ij} + (a_{\max} - a_{ij}) f(g), & (r \leq 0.5) \end{cases} \quad (21)$$

$$f(g) = r_2(1 - g/G_{\max})^2 \quad (22)$$

式中,  $a_{\max}$  和  $a_{\min}$  分别为基因  $a_{ij}$  的上界和下界; 式 (21-22) 中,  $r_2$  为随机数,  $g$  为当前迭代次数,  $G_{\max}$  为最大进化次数,  $r$  为  $[0, 1]$  间随机数。

(7) 停止条件判断。若满足停止条件, 则将进化过程中所得最优个体作为最优解输出, 终止计算。若不满足停止条件, 则重复步骤 (3) ~ (6)。

### 4 试验与分析

通过 MATLAB 环境对地铁列车辅助逆变器开路故障诊

断进行仿真试验, 故障诊断流程图如图 6 所示。




图 6 故障诊断流程图

通过仿真实验得到的辅助逆变器 IGBT 开路故障原始信号, 应用 EEMD 算法进行信号分析, 取  $0.2s \sim 0.4s$  之间辅助逆变器输出的三相半波电压信号作为原始信号。其中 EEMD 算法的高斯白噪声的标准差为 0.2, 添加噪声的次数为 100, IMF 分量的个数为 8。以 IGBT1 故障为例, 故障信号的 EEMD 分解结果如图 7 所示。




图 7 IGBT1 故障信号的 EEMD 分解结果

由图 7 可以看出, 在分解得到的各 IMF 分量中, 故障信号主要集中在前 5 个 IMF 分量中。选取前 5 个 IMF 分量, 采用能量矩的方法提取故障特征向量。如表 3 所示列出部分故障特征向量。

为了方便对 21 种辅助逆变器 IGBT 开路故障进行识别, 需对所有故障进行编码。本文拟采用 6 位二进制编码方式:  $G_1G_2G_3G_4G_5G_6$ , 每一位编码对应一个 IGBT 的状态, 编码为 0 表示该 IGBT 正常, 编码为 1 表示该 IGBT 故障, 即 000000 表示无故障, 001000 表示 IGBT3 故障, 010010 表示 IGBT2、IGBT5 同时故障。

利用 MATLAB 软件创建三层 BP 神经网络, 则输出层神经元个数为 6、根据提取的故障特征向量确定输入层神经元个数为 15、隐含层神经元个数需要根据经验公式  $p = \sqrt{m+n+a}$ , ( $a = 1, 2, \dots, 10$ ) 以及对网络模型进行反复测试来确定。为了达到良好的学习效果, 设置 BP 神经网络模型学习速率为 0.01, 最大迭代次数为 1000, 误差目标值为 0.001。

为了更好的提取出辅助逆变器的故障特征, 本文通过改变辅助逆变器故障仿真模型的输入电压, 以及改变发生开路故障的时间点, 共得到 10 组数据, 每组数据包含 21 种故障数据和 1 种正常数据。将得到的 10 组数据选择前 8 组

表 3 部分故障特征向量

故障类型	故障特征向量				
无故障	0.006	0.009	0.031	0.071	0.238
	0.007	0.011	0.026	0.051	0.229
	0.007	0.010	0.022	0.061	0.222
IGBT1 故障	0.126	0.043	0.020	0.016	0.571
	0.000	0.000	0.000	0.003	0.010
	0.010	0.003	0.002	0.015	0.181
IGBT2 故障	0.012	0.004	0.002	0.014	0.130
	0.000	0.000	0.000	0.007	0.012
	0.098	0.033	0.015	0.015	0.658
IGBT1、2 故障	0.058	0.020	0.010	0.007	0.365
	0.001	0.000	0.000	0.010	0.032
	0.065	0.022	0.010	0.013	0.385
IGBT2、4 故障	0.035	0.012	0.005	0.004	0.127
	0.009	0.003	0.001	0.028	0.254
	0.077	0.026	0.012	0.011	0.394
IGBT1、4 故障	0.139	0.047	0.022	0.015	0.445
	0.008	0.003	0.001	0.009	0.163
	0.005	0.002	0.001	0.010	0.130
IGBT1、6 故障	0.006	0.002	0.001	0.001	0.122
	0.005	0.002	0.001	0.004	0.135
	0.002	0.001	0.000	0.022	0.696




图 9 GA-BP 神经网络适应度曲线

表 4 GA-BP 神经网络测试结果

预期输出	神经网络输出					
0 0 0 0 0 0	0.293	0.142	-0.064	-0.342	0.083	0.357
1 0 0 0 0 0	1.154	-0.002	0.015	0.352	-0.014	-0.110
0 1 0 0 0 0	0.046	0.650	-0.071	0.234	0.030	0.106
1 1 0 0 0 0	1.099	0.596	-0.122	0.071	0.284	0.098
0 0 1 1 0 0	0.057	-0.127	0.797	1.119	0.125	0.048
1 0 1 0 0 0	0.944	0.201	0.898	0.037	-0.104	0.046
1 0 0 0 1 0	0.788	0.042	-0.065	0.185	0.792	0.226
1 0 0 1 0 0	0.770	0.069	0.016	0.868	-0.104	0.067
1 0 0 0 0 1	0.924	0.027	-0.092	-0.118	0.296	0.875
0 0 0 1 1 0	-0.109	0.155	-0.122	0.769	0.432	0.195

表 5 GA-BP 算法诊断结果

无故障	单个 IGBT 故障	同一桥臂 2 个 IGBT 故障	不同桥臂同一位置 2 个 IGBT 故障	不同桥臂不同位置 2 个 IGBT 故障	诊断精度
2/2	12/12	6/6	12/12	10/12	95.5%

数据作为 BP 神经网络的训练样本，后 2 组数据作为测试样本。经过多次试验，当隐含层神经元个数为 12 时，BP 神经网络的训练结果最为理想，平均误差为 0.0427，得到的训练结果如图 8 所示。




图 8 BP 神经网络训练图

将遗传算法引入 BP 神经网络模型的训练过程，对 BP 神经网络的权值和阈值进行优化，取遗传算法初始种群大小为 20，最大遗传代数为 100。图 9 为 GA-BP 神经网络适应度曲线，从图中可以看出，遗传算法在迭代了约 30 次后，适应度达到 0.004 并保持稳定。

选择剩下的 2 组数据作为测试样本对训练的 GA-BP 神经网络进行测试，测试结果如表 4 所示。根据测试结果可知，经 GA-BP 神经网络算法模型的诊断精度达到 95.5%，算法诊断结果如表 5 所示。

### 5 结论

针对地铁列车辅助逆变器发生故障时，故障信号非平

稳非线性的特性，本文提出了基于集合经验模态分解 (EEMD) 和遗传算法优化的 BP 神经网络 (GA-BP) 的故障诊断方法，该方法以辅助逆变器的输出三相半波电压值为监测信号，通过 EEMD 分解每一相电压信号得到若干个本征模函数 (IMF) 分量，采用能量矩方法提取故障特征向量，基于 GA-BP 神经网络实现故障智能诊断。通过建立辅助逆变器仿真模型，针对辅助逆变器中常见的开路故障进行模拟仿真，结果表明，该方法可有效识别出地铁辅助逆变器开路故障，对于提高故障排除效率，具有重要的研究意义和实用价值。

### 参考文献:

[1] 李旭, 李捷. 便携式地铁列车辅助逆变器故障诊断系统设计 [J]. 机械工程与自动化, 2014, (1): 138-140.  
 [2] 秦文, 李小波. 城轨列车辅助逆变器大功率器件开路故障诊断 [J]. 计算机测量与控制, 2015, 23 (11): 3610-3612.  
 [3] 姚德臣, 贾利民, 秦勇, 等. 基于小波 BP 神经网络的城轨列车辅助逆变系统故障诊断 [J]. 中国工程机械学报, 2013, 11 (6): 542-546.  
 [4] 成亮, 高军伟, 张彬, 等. 基于 EMD 和 RBFNN 的地铁

辅助逆变器故障检测 [J]. 青岛大学学报 (工程技术版), 2014, 29 (2): 43-48.

- [5] 赏吴俊, 何正友, 胡海涛, 等. 基于 IGBT 输出功率的逆变器开路故障诊断方法 [J]. 电网技术, 2013, (4): 1140-1145.
- [6] 黄诚惕. 希尔伯特-黄变换及其应用研究 [D]. 成都: 西南交通大学, 2006.
- [7] 张梅军, 唐建, 何晓晖. EEMD 方法及其在机械故障诊断中的应用 [M]. 北京: 国防工业出版社, 2015.
- [8] 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]. Proceedings Mathematical Physical & Engineering Sciences, 1998, 454 (1971): 903-995.

- [9] 李 峥. 基于计算机视觉的蔬菜颜色检测系统研究 [D]. 吉林: 吉林大学, 2004.
- [10] 龙 泉, 刘永前, 杨勇平. 基于粒子群优化 BP 神经网络的风电机齿箱齿轮箱故障诊断方法 [J]. 太阳能学报, 2012, 33 (1): 120-125.
- [11] 韩 丽. 基于改进 GA 的 RBFNN 在二级倒立摆系统中的控制研究 [D]. 沈林: 东北大学, 2009.

(上接第 14 页)

表 2 图像关键目标点序列匹配

以往方法					
图像匹配序列	关键目标点数量	匹配个数	特征线段	真实距离/cm	测量距离/cm
1-2	8	4	/	290	250
2-3	10	6	/	208	200
3-4	10	6	1	200	140
4-5	9	4	/	195	100
基于无人机航拍图像测距方法					
图像匹配序列	关键目标点数量	匹配个数	特征线段	真实距离/cm	测量距离/cm
1-2	8	8	6	290	285
2-3	10	9	6	208	208
3-4	10	10	8	200	199
4-5	9	9	6	195	195

基于无人机航拍图像测距方法进行间距测量: 根据关键目标点数量进行图像匹配, 匹配个数与原来数量基本一致, 且特征线段获取较多, 由此获得的测量值与真实距离基本一致。图像匹配序列 1-2、2-3、3-4、4-5 对应的测量差值为 5 cm、0 cm、1 cm、0cm。

通过对比结果再一次证实基于无人机航拍图像测距更加精准的论点, 也由此说明基于无人机航拍图像的关键目标点间距测量研究方法是具有有效性的。

## 5 总结与展望

关键目标点间距测量研究可应用在工业、生物、航空航天等领域之中, 设计高效精准间距测量方法显得十分重要。结合无人机图像特性, 对关键目标点间距测量进行研究, 并在 MATLAB 编程环境中得到应用。

### 5.1 总结

针对关键目标点间距测量这一关键问题, 提出了基于无人机航拍图像的关键目标点间距测量研究方法。根据无人机中各个传感器图像相关性, 缩小搜索目标范围, 加速关键目标点识别速度。由于该方法是在复杂多径环境下进行距离测量的, 所以实际测距结果与理论测距结果存在一

定偏差, 但偏差大小满足理想测距误差设计值。利用 VC++ 环境完成测距精准性能验证, 并由实验结果证实该方法研究的有效性。

### 5.2 未来展望

由于实验环境受到限制, 对于关键目标点间距测量研究仍存在许多不足之处, 需要进一步完善, 以下为该方法需要改进的方面:

- 1) 在实验过程中, 应使用不同无人机型号, 并设置相关参数, 使验证结果更为全面;
- 2) 实验添加受到限制, 应设置相对复杂场景进行实验对比分析;
- 3) 实验选取的图像都为规则性图像, 应将非规则性图像作为实验对象, 展开对比分析。

### 参考文献:

- [1] 魏溯明, 全吉成, 侯宇青阳. 基于 YOLOv2 的无人机航拍图像定位研究 [J]. 激光与光电子学进展, 2017, 20 (11): 95-104.
- [2] 曾海长, 马银平. 基于改进 ORB 的无人机航拍图像拼接算法 [J]. 工业控制计算机, 2018, 31 (5): 93-95.
- [3] 孙刘羊子, 陈锋军. 基于 SIFT 特征点的无人机航拍苗圃图像拼接 [J]. 机械工程与自动化, 2017, 15 (6): 23-24.
- [4] 宋建辉, 闫蓓蕾. 基于 SIFT 的无人机航拍图像快速拼接技术研究 [J]. 计算机应用与软件, 2018, 14 (2): 230-234.
- [5] 张一茗, 付慧. 基于间隙度的无人机林地航拍图像序列拼接方法 [J]. 北京林业大学学报, 2017, 39 (6): 107-115.
- [6] 凌云, 凌毅力. 无人机航拍图像锐度评价方法 [J]. 测绘通报, 2017, 12 (s1): 90-94.
- [7] 魏溯明, 全吉成, 侯宇青阳. 基于 CNN 及 Bi-LSTM 的无人机时序图像定位研究 [J]. 电光与控制, 2017, 11 (12): 51-55.
- [8] 孙 钰, 韩京冶, 陈志泊, 等. 基于深度学习的大棚及地膜农田无人机航拍监测方法 [J]. 农业机械学报, 2018, 49 (2): 22-25.
- [9] 青志明, 张宏艳, 龙漪澜, 等. 基于图像处理和无人机的反窃电精准取证系统的设计与实现 [J]. 电子设计工程, 2018, 6 (19): 189-193.
- [10] 范巧艳. 基于卡尔曼滤波的无人机离地高度估计算法 [J]. 电子设计工程, 2018, 26 (21): 135-138.