

基于差分进化算法的电力变压器故障监测方法

李 猛

(国网安徽省电力有限公司淮北供电公司, 安徽 淮北 235000)

摘要: 为保障电力系统安全运行, 提出基于差分进化算法的电力变压器故障监测方法, 通过电力变压器故障特征的深度挖掘, 提高其监测准确度。基于卷积神经网络(CNN)的变压器故障监测原理, 将新的卷积层添加在CNN的池化层与全连接层之间, 构建改进CNN, 利用带有动量因子的随机梯度下降算法, 加速训练改进CNN电力变压器故障监测模型, 改进CNN速度, 减轻收敛时产生的振动, 获得精准分类结果; 并利用差分进化算法优化改进CNN的权值及阈值, 提高改进CNN的收敛速度, 实现电力变压器故障精准监测。实验表明, 该方法可深度挖掘电力变压器故障类型特征; 收敛速度快、收敛准确度高; 监测电力变压器故障效果好, 准确度高。

关键词: 差分进化算法; 电力变压器; 故障监测; 改进CNN; 权值阈值; 动量因子

Power transformer fault monitoring method based on differential evolution algorithm

LI Meng

(State Grid Anhui Electric Power Co., Ltd., Huaibei Power Supply Company, Huaibei 235000, China)

Abstract: In order to ensure the safe operation of power system, a power transformer fault monitoring method based on differential evolution algorithm is proposed. Through the deep mining of power transformer fault characteristics, the monitoring accuracy is improved. Based on the transformer fault monitoring principle of CNN, a new convolution layer is added between the pool layer and the full connection layer of CNN to build an improved CNN. The random gradient descent algorithm with momentum factor is used to accelerate the training and improve the power transformer fault monitoring model of CNN, improve the speed of CNN, reduce the vibration during convergence, and obtain accurate classification results; The differential evolution algorithm is used to optimize and improve the weight and threshold of CNN, improve the convergence speed of improved CNN, and realize accurate fault monitoring of power transformer. Experiments show that this method can deeply mine the fault type characteristics of power transformer; Fast convergence speed and high convergence accuracy; Monitoring power transformer fault has good effect and high accuracy.

Key words: differential evolution algorithm; power transformer; fault monitoring; improve CNN; weight threshold; momentum factor

0 引言

电力变压器是电网运行过程中最关键的静止

的电气设备^[1], 其能否平稳运行关系着整个电力系统的安全性与供电可靠性。一旦电力变压器发

生故障造成停运,不仅会导致自身毁坏,还会中断电力供应,给用户造成极大的经济损失,甚至导致重大事故^[2]。为此,高效精准地监测电力变压器,对电力系统安全运行意义重大^[3-4]。

近几年,国内外相关学者对电力变压器故障监测进行了大量研究,取得了一定的研究成果,如文献[5]提出基于主成分分析法的变压器直流偏磁声学异常监测,获取变压器声学信号并进行去噪处理,利用梅尔频率倒谱系数方法获取变压器声学信号特征,根据主成分分析法实现变压器声学异常监测,该方法对参数的辨识准确度高,监测效果好,但其在闭环控制网络中,参数辨识能力不佳;文献[6]提出基于振动信号的电力变压器监测方法,该方法运算方便、简单直观,但不能获得频域特征,易降低监测准确度。文献[7]提出一种多深度神经网络综合的电力变压器故障识别方法,获取电力变压器故障频谱特征,通过Spark构建DNN分类器,有效解决故障识别过程中的过拟合问题,通过多深度神经网络实现多识别分类器融合决策,此方法能够提升识别正确率,但是变压器故障监测效率较低。

差分进化(Differential Evolution, DE)算法是一种群体迭代算法,多维空间内的整体最优解可利用群体内个体之间的相互配合与竞争进行求解。该算法使用实数进行编码,具有收敛速度快、全局搜寻能力强等特征。因此,本文提出基于差分进化算法的电力变压器故障监测方法,提高了监测准确度,改善了监测效果。

1 电力变压器故障监测方法

1.1 基于改进CNN的变压器故障监测模型

卷积神经网络(Convolution Neural Network, CNN)是深度学习算法中的一种^[8],可利用反向传播算法和卷积操作进行联合,实现卷积核参数自主学习训练,具有优异的学习能力。为进一步优化CNN的模型泛化能力,增强收敛速度,将新的卷积层添加在CNN池化层与全连接层之间,构建改进的CNN,实现变压器故障监测。

将多级分类神经网络用于输出层,图1为改进的CNN结构。




图1 改进的CNN结构

Fig. 1 Improved CNN structure

(1) 结构A: 卷积层与池化层

CNN中的卷积层由若干个卷积核组成,卷积核可产生输入变压器故障图像的映射,卷积核参数可通过反向传播参数的训练获取,卷积核可针对输入变压器故障图像的各种特征进行有效提取^[9]。

设CNN里的第 l 层是卷积层,其输出公式为

$$Q_j^l = \sum_{i \in R_j} b_j^l + \sum_{i \in R_j} X_i^{l-1} N_{ij}^l \quad (1)$$

式中, Q_j^l 为第 j 个特征映射,且该映射位于第 l 层, $j \in [1, n]$; X_i^{l-1} 为第 i 个输入特征,且该特征可在 $l-1$ 层得到; R_j 为第 j 个卷积范围,且 R_j 为上一层的第 $l-1$ 层内; N_{ij}^l 为第 i 个输入特征上的卷积核,且 N_{ij}^l 为在生成 Q_j^l 的过程中使用在第 $l-1$ 层的卷积核; b_j^l 为第 j 个特征映射时的偏置,且其输出在第 l 层。

将批量归一化层加在卷积层后,归一化处置处理模型使网络原始化的灵敏度下降,同时使网络训练速度获得提高。添加归一化层后的输出结果为

$$x_j^l = Q_j^l - \mu_\beta / \sqrt{\sigma_\beta^2 + \varepsilon} \quad (2)$$

$$Y_j^l = (\gamma + \beta)x_j^l \quad (3)$$

式中, x_j^l 与 Y_j^l 分别为经归一化处理后的结果与第 l 层的重构结果; μ_β 与 σ_β 分别为第 $l-1$ 层输出数据的平均值与标准差; ε 与 γ 、 β 分别为极小值与学习参数。

在非线性激活函数中, 输入归一化处置后的结果, 线性整流激活函数公式为

$$y_j^l = f(Y_j^l) = \max(0, Y_j^l) \quad (4)$$

局部神经元通过线性整流激活函数输出数值等于0, 使参数间的依赖关系得到有效降低。

将卷积层输出提取到的变压器故障特征输入到池化层, 并在该层切割这些变压器故障特征, 为获得单个代表值^[10], 可通过合并图像范围里的邻近像素实现, 对变压器故障特征图进行收缩, 并去除无用信息, 降低变压器故障特征图片的维度与过拟合造成的危险, 同时使输入变压器故障图像能够保持稳定平移。池化层采用的最大池化公式为

$$X_{j_0}^{l+3} X_{j_0} = \max_{r \in [j_0 S - S, j_0 S]} \{y_j^l(r)\} \quad (5)$$

式中, S 为池化层大小; $X_{j_0}^{l+3}$ 为第 j_0 个变压器故障特征映射, 且该映射由第 $l+3$ 层输出, $1 \leq j_0 \leq n/s$; $y_j^l(r)$ 为第 r 个神经元在第 j 个变压器故障特征映射, 且其属于第 l 层, $r \in [j_0 S - S + 1, j_0 S]$ 。

(2) 结构B: 新增卷积层

经多个结构A对变压器故障特征提取后获得压缩后的变压器故障特征向量, 将结构B加在全连接层的前面, 对结构A获取的特征进行深度挖掘。

(3) 全连接层

卷积层与池化层提取输入变压器故障图像的全部故障特征后, 通过全连接层将这些变压器故障特征进行融合^[11], 对于每一个输入变压器故障图像利用逻辑回归模型计算其回归几率, 将学习目标设定成最低损失, 对参数进行迭代。用 E 描述交叉损失熵函数, 其公式为

$$E = \sum_{a=1}^A \sum_{b=1}^B t_{ab} \ln y_{ab} \quad (6)$$

式中, A 与 B 分别为样本个数与类型数; t_{ab} 为第 b 个类型里包含第 a 个样本; y_{ab} 为第 b 个类型里的第 a 个样本的输出, 即逻辑回归模型的输出。逻辑回归模型输出即为采用改进CNN模型获取的变压器故障监测结果。

1.2 电力变压器故障监测模型训练

利用随机梯度下降算法 (SGD with Momentum, SGDM) 训练改进CNN电力变压器故障监测模型, 训练完成后利用模型完成电力变压器的故障监测。学习样本可在由电力变压器故障特征组成的训练集内随机选取, 对梯度指数加权平均数进行运算, 所取训练样本的 N_{ij} 与 b_j 可采用梯度进行迭代, 即

$$N_{ij} = N_{ij} - \eta v_N(t) \partial E / \partial N_{ij} \quad (7)$$

$$b_j = b_j - \eta v_b(t) \partial E / \partial b_j \quad (8)$$

式中, η 为CNN的学习率; $v_N(t)$ 与 $v_b(t)$ 为学习过程中的参数动量, 且属于第 t 次学习时的动量, 其迭代公式为

$$v_N(t) = v_N(t-1) \times \text{Momentum} - \eta \partial E / \partial N_{ij} \quad (9)$$

$$v_b(t) = v_b(t-1) \times \text{Momentum} - \eta \partial E / \partial b_j \quad (10)$$

式中, 动量因子用Momentum描述, 且 $0 \leq \text{Momentum} \leq 1$ 。

为加速 $v_N(t)$ 与 $v_b(t)$, 须使 t 与 $t-1$ 时分别迭代的 $v(t)$ 与 $v(t-1)$ 方向一致, 反之则降速。若无Momentum加入, 随机下降方向可利用参数进行确定, 参数能通过选取样本进行求导, 样本越接近极值, 收敛速度越慢^[12], 且样本在迭代过程中容易受到噪声的影响, 无法向全局最优化方向靠拢。为减轻收敛时产生的振荡, 须提前确保样本以最优方向下降, 可通过在样本中加入Momentum实现, 原因是Momentum能加速收敛, 改善准确度。

1.3 DE算法优化电力变压器故障监测模型

训练完成的改进CNN的变压器故障监测模型在对电力变压器故障进行监测的过程中, 电力变压器故障速度与监测准确度会受模型权值及阈值的原始值影响。为使基于改进CNN变压器故障监测模型的收敛速度与故障监测准确度得到提

高,该模型的权值及阈值可利用DE算法实现优化,以优化结果为原始值赋值电力变压器故障监测效果。

DE算法属于启发式并行搜寻技术中的一种,该算法的优点是寻优能力强^[13],利用DE算法优化电力变压器故障监测模型的具体步骤为:

1) 创建电力变压器故障监测模型的原始种群,用NP与D分别描述种群领域与可行解空间的维数,演化至第t代时的种群用 $H(t)$ 描述。用 $H(0)=\{h_1^0, h_2^0, \dots, h_{NP}^0\}$ 描述故障监测问题的可行解空间里的原始种群,且该种群可任意生成,其中第i个个体解用 $h_i^0=[h_{i,1}^0, h_{i,2}^0, \dots, h_{i,D}^0]$ 描述。生成个体的不同分量的公式为

$$h_{i,j}^0 = h_{j,\min} (1 - \text{rand}) + \text{rand} h_{j,\max} \quad (11)$$

式中, $h_{j,\max}$ 为第j维在解空间里的上界; $h_{j,\min}$ 为其下界; 用rand描述随机算子, 且 $\text{rand} \in [0,1]$ 的独立任意数。

2) 变异。用 h_i^G 描述目标向量, 且其属于第G代种群, 变异向量可通过下式产生, 即

$$v_i^{G+1} = h_{r_1}^G + h_{r_2}^G M - h_{r_3}^G M \quad i=1,2,\dots, NP \quad (12)$$

式中, 在第G代种群内的三个差异个体用 $\{h_{r_1}^G, h_{r_2}^G, h_{r_3}^G\}$ 描述, 这些个体可任意选取, 且 $r_1 \neq r_2 \neq r_3 \neq i$; 缩放因子用M描述, 且 $M \in [0,2]$ 的常量, 可对 $(h_{r_2}^G - h_{r_3}^G)$ 的影响进行管控, 为差分向量。

3) 交叉。提高种群个体的多样化是交叉操纵的目标^[14], 用 u_i^{G+1} 描述新的交叉向量, 产生 u_i^{G+1} 的公式为

$$\begin{cases} \text{randb} \leq CR \text{ 或 } j = \text{rand}_j & u_{i,j}^{G+1} = v_{i,j}^{G+1} \\ \text{randb} > CR \text{ 或 } j \neq \text{rand}_j & u_{i,j}^{G+1} = h_{i,j}^G \end{cases} \quad (13)$$

式中, $i=1, \dots, NP; j=1, \dots, D$, 0~1之间的任意数用randb描述; 交叉因子用CR描述, 且 $CR \in [0,1]$, 交叉产生的几率随着CR值的增大而增大^[15]。1~D之间的整数用randb描述, 且该整数可任意选取, 用 u_i^{G+1} 与 v_i^{G+1} 描述交叉向量与变异向量, randb_j保证 u_i^{G+1} 在 v_i^{G+1} 内最少得到一个元素。

4) 最优个体选取。通过式(14)可描述最优个体选取步骤, 该公式为

$$\begin{cases} f(u_i^{G+1}) < f(h_i^G) & h_i^{G+1} = u_i^{G+1} \\ f(u_i^{G+1}) \geq f(h_i^G) & h_i^{G+1} = h_i^G \end{cases} \quad (14)$$

式中, u_i^{G+1} 的适应度函数用 $f(u_i^{G+1})$ 描述; h_i^G 的适应度函数用 $f(h_i^G)$ 描述。

为使电力变压器故障监测模型种群一直朝着最优解的方向演化, 须将子代个体的优秀程度不低于父代个体作为选取结果。最终实现DE算法电力变压器故障监测模型的优化。

电力变压器故障主要分为过热故障与放电故障。利用本文方法提出基于DE优化改进CNN的电力变压器故障监测模型, 获取电力变压器的6种故障状态, 并输出故障对应的故障编码, 结果见表1。

表1 故障编码

Tab. 1 Fault codes

故障类型	故障简称	输出编码
低温过热	LT	0001
中温过热	MT	0010
高温过热	HT	0100
低能放电	LE	0011
高能放电	HE	0101
局部放电	PE	1100

2 实验分析

为验证本文方法对电力变压器故障的监测效果, 以某发电厂为例进行电力变压器故障监测仿真实验, 该发电厂包括8种不同电力变压器。

为验证改进CNN的电力变压器的故障特征提取有效性, 实验将该发电厂内电力变压器的原始数据集的高维数据映射至二维空间, 给出改进CNN在不同卷积层情况下获取的电力变压器的故障特征分布结果, 如图2~图5所示。其中不同电力变压器故障类型数据均采用不同形状代替。

由图2可看出, 电力变压器振动信号的故障特征彼此重叠, 区分难度高。由图3~图5可看出, 通过采用改进的CNN中的卷积层, 对电力变压器故障类型特征进行挖掘, 其叠加率呈逐步下降趋势, 故障类型的区分难度明显降低, 实验表明, 改进CNN具有极强的深度挖掘电力变压器故障特征的能力。




图2 原始数据集特征分布

Fig. 2 Characteristic distribution of original data set




图5 卷积层3输出特征结果

Fig. 5 Output characteristic results of convolution layer 3




图3 卷积层1输出特征结果

Fig. 3 Output characteristic results of convolution layer 1




图4 卷积层2输出特征结果

Fig. 4 Output characteristic results of convolution layer 2

实验选取40 dB、80 dB和120 dB三种信噪比，统计不同信噪比下，应用本文方法进行电力变压器故障监测的误差二次方和结果变化情况，如图6所示。




图6 电力变压器故障监测误差二次方和比较

Fig. 6 Comparison of square sum of error in power transformer fault monitoring

由图6可看出，应用DE算法改进CNN的电力变压器故障监测误差二次方和随着信噪比的增大呈缓慢增长趋势。当信噪比分别为40 dB与120 dB时，网络误差二次方和的最大值分别为10与15，两者相差不超过5；在训练过程中，应用DE算法改进CNN进行电力变压器故障监测的误差二次方和整体波动均比较小，在网络训练次数为1 200次时，三种信噪比下的电力变压器监测误

差二次方和均达到稳定状态,且稳定时最小误差二次方和最终收敛到5.987 2。实验表明,本文方法采用DE算法改进CNN进行电力变压器故障监测的误差二次方和受信噪比的影响较小,且电力变压器故障监测误差二次方和下降速度快,具有较快的收敛速度及较高的收敛准确度。

采用本文方法对以下8种电力变压器设备进行故障监测,验证这些电力变压器设备的故障监测结果与实际故障结果是否保持一致,结果见表2。

表2 不同电力变压器设备的故障监测结果

Tab. 2 Fault monitoring of different power transformer equipment

电力变压器设备	故障监测结果	实际故障结果	故障结果是否一致
设备1	低温过热	低温过热	是
设备2	高能放电	局部放电	否
设备3	高温过热	高温过热	是
设备4	局部放电	局部放电	是
设备5	中温过热	中温过热	是
设备6	低能放电	低能放电	是
设备7	高温过热	高温过热	是
设备8	局部放电	局部放电	是

由表2可得,采用本文方法监测的不同电力变压器设备故障结果和实际故障结果基本一致,实验表明,本文方法能够实现对不同电力变压器设备故障的监测。

为验证本文方法在低温、中温与高温过热及局部、低能与高能放电6种电力变压器故障类型状况下的监测效果,实验以平均判正率与平均错误预警率结果作为电力变压器故障监测判断依据,结果如图7所示。

由图7可看出,在该6种电力变压器故障类型状况下,采用本文方法监测电力变压器故障后的平均判正率均在90%以上,其中,判断高温过热的准确率高达98%,且其平均错误预警率不超过0.80%,平均错误预警率最高的低能放电的平均错误预警率仅为0.73%。实验表明,本文方法监测电力变压器故障类型具有极高的准确度,监测效果好。




图7 不同故障状况下本文方法的监测效果

Fig. 7 Monitoring effect of this method under different fault conditions

3 结束语

本文引入差分进化算法,提出基于差分进化算法的电力变压器故障监测方法。将新的卷积层添加在CNN的池化层与全连接层之间,通过差分进化算法对CNN的权值及阈值进行优化,有效提升CNN的收敛速度。经实验表明:

1) 网络训练次数为1 200次时,信噪比分别为40 dB、80 dB和120 dB时,电力变压器故障监测误差二次方和分别为6、10和12。

2) 本文方法监测电力变压器故障后的平均判正率均在90%以上,判断高温过热的准确率高达98%;且其平均错误预警率不超过0.80%。

以上结果表明,本文方法监测电力变压器故障类型具有极高的准确度,监测效果好。

参考文献

- [1] 邓军, 孟杰, 潘志城, 等. 基于振动检测技术的电力变压器故障概率预测模型[J]. 变压器, 2020, 57(11): 37-40, 48.
- [2] 张朝龙, 何怡刚, 杜博伦, 等. 基于深度学习的电力变压器智能故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(1): 81-89.
- [3] 刘航, 王有元, 陈伟根, 等. 基于无监督概念漂移识别和动态图嵌入的变压器故障检测方法[J].

- 中国电机工程学报, 2020, 40(13): 4358-4371.
- [4] 谢佩军, 高婷婷, 叶宏武. 量子粒子群优化核极限学习机的船舶变压器故障诊断[J]. 系统科学与数学, 2021, 41(7): 1807-1816.
- [5] 曹浩, 黄韬, 周舟, 等. 基于主成分分析法的变压器直流偏磁声学异常检测[J]. 湖南电力, 2021, 41(5): 1-6.
- [6] 蔚超. 基于振动信号的电力变压器铁心状态监测方法研究[J]. 电子器件, 2020, 43(1): 152-156.
- [7] 曲岳晗, 赵洪山, 马利波, 等. 多深度神经网络综合的电力变压器故障识别方法[J]. 中国电机工程学报, 2021, 41(23): 8223-8231.
- [8] 廉小亲, 陈彦铭, 刘钰, 等. 基于差分进化算法的ICP-AES谱线重叠干扰校正方法研究[J]. 电子测量与仪器学报, 2020, 34(11): 72-83.
- [9] 刘仲民, 翟玉晓, 张鑫, 等. 基于DBN-IFCM的变压器故障诊断方法[J]. 高电压技术, 2020, 46(12): 4258-4265.
- [10] 王本广, 何山, 陈小丹, 等. 基于灰色滚动预测方法的变压器智能监测研究[J]. 计算机仿真, 2020, 37(12): 72-77, 152.
- [11] 张育杰, 李典阳, 冯健, 等. 基于多模型选择性融合的变压器在线故障诊断[J]. 电力系统自动化, 2021, 45(13): 95-101.
- [12] 苏静. 基于DSP的变压器差动保护装置的设计[J]. 电气应用, 2021, 40(1): 91-97.
- [13] 董方旭, 咸日常, 咸日明, 等. 基于细菌觅食算法优化的电力变压器故障诊断技术[J]. 电测与仪表, 2018, 55(19): 34-40.
- [14] 张育杰, 冯健, 李典阳, 等. 基于油色谱数据的变压器故障征兆新优选策略[J]. 电网技术, 2021, 45(8): 3324-3332.
- [15] 李斌, 廖兴万, 马留军, 等. 有载调压配电变压器节能应用研究[J]. 电气应用, 2021, 40(6): 72-76.

作者简介

李猛 (1989—), 男, 硕士, 工程师, 研究方向为配电自动化。

(收稿日期: 2021-12-28)