

机器学习算法下通信电子线路微损伤检测

王膺钦¹, 赵春^{2†}

(1. 南昌大学 信息工程学院, 江西 南昌 330000; 2. 成都锦城学院, 四川 成都 611731)

摘要:在通信电子线路损伤检测过程中,由于一些微损伤特征较难察觉,从而导致损伤检测准确率较低。为此,提出了机器学习算法下的通信电子线路微损伤检测方法,实现对电子线路微损伤的精准、高效检测。引入小波包特征分析,提取小波讯号动能特征,计算损伤敏感度,构建基于一维卷积神经网络的通信电子线路微损伤检测模型,将提取到的动能特征作为模型输入,经特征样本区别标明、训练数据集有效放回抽样,实现模型参量更新,最终在最佳训练模型中输入待测线路样本以实现电子线路微损伤检测。实验表明:所提算法有效检测出通信电子线路的微损伤,对微损伤检测应用性和可行性较高,且抗噪声干扰能力强。

关键词:机器学习算法;通信电子线路;微损伤检测;小波包;小波讯号;卷积神经网络

中图分类号:V448

文献标识码:A

Microdamage Detection of Communication Electronic Lines Based on Machine Learning Algorithm

WANG Yingqin¹, ZHAO Chun^{2†}

(1. School of Information Engineering, Nanchang University, Nanchang, Jiangxi 330000, China;

2. Chengdu Jincheng University, Chengdu, Sichuan 611731, China)

Abstract: In the process of damage detection in communication electronic circuits, the accuracy of damage detection is low due to some microdamage features that are difficult to detect. Therefore, a machine learning algorithm based microdamage detection method for communication electronic circuits is proposed to achieve accurate and efficient detection of microdamage in electronic circuits. Introducing wavelet packet feature analysis, extracting the kinetic energy features of wavelet signals, calculating damage sensitivity, and constructing a communication electronic circuit microdamage detection model based on one-dimensional convolutional neural network. The extracted kinetic energy features are used as model inputs, and the feature samples are distinguished and labeled, and the training data set is put back for sampling to achieve model parameter updates. Finally, the electronic circuit microdamage detection is achieved by inputting the tested circuit samples into the optimal training model. The experiment shows that the proposed algorithm effectively detects microdamage in communication electronic circuits, has high applicability and feasibility for micro damage detection, and has strong anti noise interference ability.

Key words: machine learning algorithm; communication electronic lines; microdamage detection; wavelet packet; wavelet signal; convolutional neural network

随着社会的不断进步,通信电子技术蓬勃发展,通信电子线路不仅可以实现电子数据的传输,

还可以控制电子设备,可见通信电子线路为国家经济建设和社会发展提供了有力的技术支持,此外在

保障国家信息安全方面也处于无可撼动的地位。维护通信电子线路的完整性至关重要,由于通信电子线路中存在诸多微小精密元件,因此很多检测方法无法实现对通信电子线路微损伤的检测。

为此,很多学者致力于通信电子线路微损伤检测,吴军等人^[1]提出基于 Cascade RCNN 算法结合 ResNet101 网络获取线路特点,采用多等级联合检测机实现对通信电子线路的微损伤检测,该方法虽提升了损伤检测的正确率,但遗漏性较高。蔡舒好等人^[2]采用多角度目标检测方法,通过聚合网络建立线路特征结合层并在该层中融合浅层与深层的特征以实现通信电子线路微损伤检测,此方法检测效果较高,但方法中的参数实数冗杂。徐海青等人^[3]提出基于对抗神经网络的通信电子线路微损伤检测方法,以生成机与判断机产生的线路特征形成数据集,构建线路小损伤判断模型,最终结合交叉熵完成线路小损伤检测,但该方法判别真实度较低,可行性较低。

为避免过多的参数导致通信电子线路微损伤的检测效率与准确率降低,提出了一种基于机器学习算法的通信电子线路微损伤检测方法。采用卷积神经网络作为机器学习算法,实现对电子线路的快速检测,该方法在噪声干扰下依然具备损伤检测能力。

1 通信电子线路微损伤检测

机器学习算法下通信电子线路微损伤检测的流程如下。

- (1)收集大量的微损伤电子线路样本;
- (2)通过对所得样本进行数据处理获取其特征作为机器学习算法的输入;
- (3)基于机器学习算法训练结果,组建分类模型;
- (4)根据所构建的分类新模型,检测待测线路样本,并将检测结果输出。机器学习算法下通信电子线路微损伤检测流程如图 1 所示。

1.1 通信电子线路损伤敏感度计算

在通信电子线路微损伤检测过程中,计算损伤敏感度的目的是确定电路的某些因素对微损伤的敏感性,如电路的特性、排布方式、线路的接口及电路的结构等。通过计算敏感度,可以找出电路中哪些元件是比较脆弱的,在实际的损伤检测中着重监测,以避免由于粗放的监测造成一定程度的影响,从而提高检测的准确性和精度。此外,计算损伤敏感度还能后续的设计和改进行提供技术支持,提高电路的鲁棒性和稳定性。因此,在通信电子线路微损伤检测之前,先计算损伤敏感度是非常重要的。

通常情况下,在分析鉴别通信电子线路微损伤情况时,未损伤线路反射和存在微损伤线路反射二者之间的差异极小,难以发现线路的微损伤。线路的损伤情况不能从正常和损伤线路小波转化讯号的频域波谱获取,但小波讯号的动能谱可准确定位线路损伤的情况。为获得线路损伤讯息,利用线路反射讯号,通过小波包解析手段将讯号转化为不同种类时段中的诸多小信号。正常线路反射的讯号 $S^0(t)$ 以及损伤线路的反射讯号 $S^d(t)$,计算式如公式(1)所示:

$$\begin{cases} S^0(t) = \sum_{2^{k-1}}^{j=1} S_{kj}^0(t) \\ S^d(t) = \sum_{2^{k-1}}^{j=1} S_{kj}^d(t) \end{cases} \quad (1)$$

式中, S_{kj}^0 表示正常讯号正交频域的小讯号; S_{kj}^d 表示损伤讯号正交频域的小讯号; k 表示小波转化树线路的层数; j 表示第 j 层。




图 1 通信电子线路微损伤检测流程图

对应的小讯号动能计算如公式(2)所示:

$$\begin{cases} U_{kj}^0 = \int |S_{kj}^0(t)|^2 d(t) \\ U_{kj}^d = \int |S_{kj}^d(t)|^2 d(t) \end{cases} \quad (2)$$

式中, U_{kj}^d 和 U_{kj}^0 为 S_{kj}^d 、 S_{kj}^0 对应的小讯号动能。

将得到的 U_{kj}^d 和 U_{kj}^0 构建为一个通信电子线路振荡反射小波讯号动能特征向量 $\mathbf{V}_d$, 如公式(3)所示:

$$\begin{cases} \mathbf{V}_d = \{\Lambda_1, \Lambda_2, \dots, \Lambda_{2^{k-1}}\} \\ \Lambda_j = \frac{U_{kj}^d}{U_{kj}^0}, j = 1, 2, \dots, 2^{k-1} \end{cases} \quad (3)$$

式中, Λ_j 表示线路的损伤导致第 j 层小讯号动能增加或减小的量。因为通信电子线路损伤的情况过多过少都由各个 Λ_j 决定,所以不同干扰参

量对线路损伤的敏感性可用 Δ_j 的全部总量形容。通信电子线路损伤敏感度常数 R 如公式(4)所示:

$$R = \sqrt{\Delta_1^2} + \sqrt{\Delta_2^2} + \cdots + \sqrt{\Delta_j^2} \quad (4)$$

1.2 基于机器学习的通信电子线路微损伤检测

1.2.1 一维卷积神经网络结构

通过计算通信电子线路损伤敏感度能够确定相应的特征选择、特征提取、分类算法等性能和优缺点,从而选择出最优的机器学习算法和模型。由于一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)相对二维卷积神经网络的参量较少,所以该网络对大范围数据集的依赖性较低^[4-6]。尤其针对讯号分类的现象,1D-CNN 在不更改输入讯号维度的同时,还可使输入固有讯号特点的存留最大化,因此以机器学习算法中的 1D-CNN 为通信电子线路微损伤检测模型的基础。输入层、隐含层和输出层共同构成 1D-CNN 的基础框架,卷积层、池化层与全连接层都属于隐含层。1D-CNN 基础框架,如图 2 所示。




图 2 卷积神经网络的基本框架

1.2.2 模型训练

模型训练包括将模型输入数据集中,通过对模型进行多次训练,能够不断优化模型的性能。深入学习数据集由待测通信电子线路振荡反射小波讯号动能讯息组成,该讯息被待测线路损伤的 1D-CNN 模型接收。采用一定元解析融合现实测验等方法可对现实作业中每个线路节点的损伤情况进行探测,由此得到不同线路损伤情况下的固有反射,从而获取固有数据集。线路的各个重要节点的数据间位于一个时间序列且互相关联,所以对同等时间间隔的讯号碎片采用接连拼凑,因此在不同状况下提高 1D-CNN 模型辨别力。以标注形式对数据集集中的不同特征样本区别标明,标明结束的数据则以训练集合的形式输入 1D-CNN 展开交换

训练。

卷积神经网络和人类视觉系统中的反馈现象比较相似,每一次交换训练中的一些网络参量都参与一次逆向传递。采用任意重组、任意选取的原则对各个批次的训练数据集开展有放回抽样,并将重新抽取好的数据作为模型的输入。设定训练批次及分割样本规模等参量,通过对每个训练批次的任意抽取,训练样本会成为众多分割样本,而分割样本产生的数量和分割样本的乘积即得训练集合规模。根据卷积神经网络对不用样本的计算获取模型参量,再把更新参量输入下个训练批次。

1.2.3 模型参量更新

在训练过程中,根据模型的表现来更新模型的参量,以进一步提高模型的分类精度。每次参量的交换更新意味模型的每次循环,当输入数据途径隐含层中的各个结构时,模型参量的更新也随之完成。隐含层接收到讯号数据后,卷积和激活运算两个重要步骤便开始运作。

(1) 卷积层

以输入层的输出作为卷积层的输入,然后对输入矩阵进行卷积处理,最终通过激活函数操作获得卷积层的输出数据^[7,8]。当传输信号的数值比一个设定好的阈值大时,下个神经节点进行激活处理;当该传输信号比一个设定好的阈值小时,神经节点则不会被激活。

1D-CNN 可以判定某种特征的强弱是否满足一定基准。由于 ReLU 激活函数具有收敛速度快和精准度高的优点,所以采用 ReLU 激活函数,如公式(5)所示:

$$\text{ReLU}(x) = \max\{0, x\} \quad (5)$$

其中,最大值函数用 $\max\{\cdot\}$ 表示,该函数折回值在括号中为最大,当 $x < 0$ 时,ReLU 的值也一直为 0;当 $x > 0$ 时,ReLU 的值一直等于 0。基于此,卷积层模型如公式(6)所示:

$$x_j^i = f\left(\sum_{i=M_j}^l x_i^l \times k_{ij}\right)R \quad (6)$$

其中, x_j^i 代表第 l 层网络的输出; f 代表激活函数; M_j 代表提取的特征集合; x_i^l 代表第 l 层网络的输入; k_{ij} 代表第 i 个特征输出的第 j 个特征相连的卷积中心; b_j^i 代表偏置项。

(2) 池化层

通过卷积层处理信息实现部分感知化,需先将信息通过池化层进行凝压处理。池化分为最大值池化与均值池化。其中,最大值池化指输出值为其最大值的子矩阵^[9-11],均值池化指池化结果为其子矩阵的平均值。采用卷积层抓取其特征,并对其实施整合处理,从而实现数据的凝压,使 1D-CNN

提取特征的规模更大。

(3)全连接层

通过卷积池化的多次处理^[12],利用模型连接一个至多个神经节点。任意神经节点之间均在全连接层中连接,其具备汇合卷积池化层中存在种类特征信息的重要性能。通过卷积池化层中抓取的特征信息映射于样本标识领域的处理,完成输入数据的归类^[13],因此在 1D-CNN 中全连接层等同分类器的效果,对其处理如公式(7)所示:

$$y = Wx_j^i \quad (7)$$

其中, y 表示全连接层的输出; W 表示权值。

(4)Softmax 层

通过 1D-CNN 的多次卷积、池化处理以及全连接层后,输入信号特征的抓取及凝压工作也相继完成^[14],采用 Softmax 可以进行电子线路微损伤检测工作^[15]。Softmax 属于深入学习多分类情况中的重要算法,该算法本质为概率表达,如公式(8)所示:

$$p(y^{(i)} = j | x^{(i)}; \theta) = \frac{y \sum_{l=1}^k e^{\theta_l^{(i)}}}{e^{\theta_l^{(i)}}} \quad (8)$$

其中, θ 表示权重; $x^{(i)}$ 表示 Softmax 层的输入; i 和 j 分别表示 m 个训练集中第 i 个训练样本以及 n 个分类标识中第 j 个标识。

1.2.4 通信电子线路微损伤检测实现

利用训练好的模型进行通信电子线路微损伤检测,将检测结果映射到输出层。根据公式(3)提取到的通信电子线路损伤导致讯号动能特征向量 V_d ,将其作为 1D-CNN 模型输入数据,构建基于 1D-CNN 的通信电子线路微损伤检测模型。通过测验集正确值、损耗值和收敛速率等要素对 1D-CNN 结构持续调整并最终明确超参量,以此实现 1D-CNN 的最佳模型。若判断模型训练结束或完成收敛损耗值最小化,根据超参量优化以及模型参量更新后运算所得 1D-CNN 模型,并将该模型应用在特定待测损伤辨识度模型,从而实现模型组建。以待测通信电子线路损伤的原有振荡反射讯号作为训练后最佳模型的输入数据,从而输出通信电子线路损伤检测结果。基于 1D-CNN 的通信电子线路微损伤检测过程如图 3 所示。

2 实验分析

通信系统用于传递信息,系统中包含多种设备及装置,由输入、输出变换器,发送、接收设备以及信道组成。通信电子线路作为传输信息的载体,其完好性对信息的传输至关重要。以某通信公司的电子线路为实验对象,选取相同长度的完好线路以

及 0.05 %微损伤线路,采用本文方法分别对二者施加无噪声和 4 倍噪声,并获取它们的振荡反射讯号,通过处理振荡反射讯号得到小波分析图如图 4 所示。




图 3 通信电子线路微损伤检测过程




图 4 无噪声和 4 倍噪声线路损伤特征量

根据图 4(a) 可知,根据小波分析线路的损伤振荡反射讯号损伤特征量,在无噪声状态下,小波能量谱变化不大,说明本文方法可以实现烦琐讯号

的细致化及放大化,更加凸显微损伤的信息特征;在图 4(b)中,噪声状态下的损伤特征量尤为多样,说明在频率富集的噪声下存在更多的模块进行振荡,振荡的模块越多,线路的损伤状况越突出,更加可以说明线路微小损伤的状况。

本文方法对不同噪声环境下的线路损伤特征量影响,可用式(4)中 R 代表不同噪声环境下的线路损伤特征量影响,不同噪声下的 R 变化曲线如图 5 所示。




图 5 不同信噪比下损伤敏感度常数 R

根据图 5 可知,在 30 倍噪声环境下,损伤敏感度常数 R 最大,太大或太小的噪声对损伤特征讯息都有影响,说明本文方法以 30 倍噪声条件为最优环境,在该环境下可全面展现线路的微损伤特征讯息。

分别用本文方法在 10 倍、20 倍、30 倍的噪声下对 1D-CNN 模型进行训练。随机抽取线路损伤数据的 20% 作为模型的测验集并获得收敛曲线,如图 6 所示。




图 6 不同噪声下的 1D-CNN 模型训练过程

如图 6 所示,1D-CNN 模型在训练过程中收敛速率较快,在第 7 批次训练完成后,该模型几乎收敛完成。综上所述,一维卷积神经网络在噪声影响下依然可以实现电子线路微损伤检测,说明本文方

法对电子线路微损伤检测具备高可信性和高反馈性。

3 结 论

电子线路微损伤难以发觉并检测,采用一维卷积神经网络实现了电子线路微损伤的检测。通过计算通信电子线路损伤敏感度,选择出最优的机器学习算法并构建一维卷积神经网络模型,对模型训练完成参数更新,进一步提高模型的分类精度,从而实现通信电子线路微损伤检测。本文方法具有线路微损伤检测的高可行性和高可靠性,在噪声干扰的环境下可完成对线路损伤的检测,尤其在微小损伤方面,说明本文方法对微小损伤检测有强烈针对性,而且可在第一时间准确反馈检测结果。

参考文献

[1] 吴军,白梁军,董晓虎,等.基于 Cascade R-CNN 算法的输电线路小目标缺陷检测方法[J]. 电网与清洁能源,2022,38(4):19-27+36.

[2] 蔡舒舒,闫子砚.基于改进 YOLOv4 的航空发动机小目标损伤检测研究[J]. 航空动力学报,2023,38(2):445-452.

[3] 徐海青,余江斌,梁攀,等.基于 GAN 的改进 RPN 输电线路细小金具缺陷检测方法[J]. 电子器件,2021,44(6):1409-1416.

[4] 张健飞,蔡东成.基于多尺度卷积神经网络的结构损伤识别研究[J]. 地震工程与工程振动,2022,42(1):132-142.

[5] 苟军年,杜慷慷,刘力.基于改进掩膜区域卷积神经网络的输电线路绝缘子自爆检测[J]. 电工技术学报,2023,38(1):47-59.

[6] 缪希仁,林志成,江灏,等.基于深度卷积神经网络的输电线路防鸟刺部件识别与故障检测[J]. 电网技术,2021,45(1):126-133.

[7] 王浩,单文静,方宝富.基于多层上下文卷积神经网络的目标检测算法[J]. 模式识别与人工智能,2020,33(2):113-120.

[8] 姚宗伟,杨宏飞,胡际勇,等.基于机器视觉和卷积神经网络的轨道表面缺陷检测方法[J]. 铁道学报,2021,43(4):101-107.

[9] 胡怀中,李龙飞,李梦迪.基于卷积神经网络的新型爆珠缺陷检测算法[J]. 浙江工业大学学报,2022,50(6):609-614.

[10] 骆勇鹏,王林堃,廖飞宇,等.基于一维卷积神经网络的结构损伤识别[J]. 地震工程与工程振动,2021,41(4):145-156.

[11] 何浩洋,王玮,黄磊.基于卷积神经网络和递归图的桥梁损伤智能识别[J]. 应用基础与工程科学学报,2020,28(4):966-980.

[12] 梁波,卢军,曹阳.基于改进 U-Net 卷积神经网络的钢轨表面损伤检测方法[J]. 激光与光电子学进展,2021,58(2):334-340.

[13] 王道累,李超,李明山,等.基于深度卷积神经网络的光伏组件热斑检测[J]. 太阳能学报,2022,43(1):412-417.

[14] 张飞飞,张俊,吴龙,等.基于深度卷积神经网络的变电一次设备故障检测方法[J]. 电气传动,2022,52(23):67-72.

[15] 胡年宗,伍世度,张亦明.基于卷积神经网络的 SLAM 回环检测算法研究[J]. 计算机仿真,2020,37(5):282-286.