

基于微控制器改进 SqueezeNet 交通标志识别的研究

李晓琳^{1,2}, 庞保益³, 曹银杰^{1,2}, 田存伟^{1,2},
冯文文^{1,2}, 刘 明^{1,2}, 耿相珍^{1,2}

(1. 聊城大学 物理科学与信息工程学院, 山东 聊城 252059;

2. 山东省光通信科学与技术重点实验室, 山东 聊城 252059;

3. 山东高速物流供应链有限公司, 山东 青岛 266000)

摘要: 针对目前交通标志的识别都是基于操作系统之上, 无法做到自主可控、稳定可靠的问题, 故提出一种基于微控制器卷积神经网络交通标志识别; 考虑到微控制器内存及计算速度, 研究采用改进 SqueezeNet 网络模型结构, 将 PC 训练机训练好的各种交通标志权值矩阵文件缩小了 50 倍, 移植到前端 Cortex-M 核系列开发板上; 利用内嵌的 CMSIS-NN 网络函数库搭建与训练机相同的网络模型结构实现对标志的快速识别; 实验结果表明, 基于微控制器改进 SqueezeNet 交通标志识别方法平均识别率达到 97.4% 以上, 识别速度得到了有效的提高, 同时为智慧交通的标志识别提供了一种可选择方案。

关键词: 交通标志识别; 微控制器; CMSIS-NN; 改进 SqueezeNet

Research on Surveillance Video Vehicle Type Recognition Based on Cortex-M Convolutional Neural Network

Li Xiaolin^{1,2}, Pang Baomeng³, Cao Yinjie^{1,2}, Tian Cunwei^{1,2}, Feng Wenwen^{1,2},
Liu Ming^{1,2}, Geng Xiangzhen^{1,2}

(1. College of Physics and Information Engineering, Liaocheng University, Liaocheng 252059, China;

2. Shandong Key Laboratory of Optical Communication Science and Technology, Liaocheng 252059, China;

3. Shandong High-speed Logistics Supply Chain Co., Ltd., Qingdao 266000, China)

Abstract: At present, the recognition of traffic signs is based on the operating system, which cannot achieve autonomous control, stable and reliable. Based on this, a method of traffic sign recognition based on microcontroller convolutional neural network was proposed. Considering the memory and calculation speed of the microcontroller, the research uses the improved SqueezeNet network model structure to reduce the weight of the traffic sign matrix files trained by the PC training machine by 50 times, and transplanted to the front-end Cortex-M core series development board; The embedded CMSIS-NN network function library is used to build the same network model structure as the training machine to realize fast recognition of the sign. The experimental results show that the average recognition rate of SqueezeNet traffic sign recognition method based on Microcontroller is over 97.4%, and the recognition speed is effectively improved. At the same time, it provides an alternative scheme for intelligent traffic sign recognition.

Keywords: traffic sign recognition; microcontroller; CMSIS-NN; improved SqueezeNet

0 引言

交通标志作为智慧交通重要的组成部分, 交通标志识别在车辆驾驶和交通安全起着重要的作用^[1]。近年来, 交通标志识别也是国内外学者研究的热点^[2-3], 机器学习的相关理论与应用发展迅速, 尤其是卷积神经网络 (convolutional neural network, CNN) 取得了相对较高的成就, 在

图像识别^[4]、语音识别^[5]、物体检测^[6]等机器学习领域受到广泛应用, 基于神经网络的交通标志识别方法具有检测速度快、识别精度高以及成本低廉等特点是现在机器学习领域的重点研究方向。

基于 CNN 的图像识别研究^[3,7-8]及消费类的电子芯片产品, 大部分基于操作系统之上^[9], 无法做到自主可控性、数据稳定可靠, 并且基于微控制器芯片上做的相对较少; 2019 年 3 月国防科大与旷视的研究团队 (孙剑老师在列) 提出在移动端 ARM 芯片实时运行的两阶段通用目标检测算法 ThunderNet, 为图像的识别可以实现在芯片^[10]上提供了重要的参考价值。2018 年 ARM-NN 针对 Cortex-M 系列芯片研究了 CMSIS-NN 库; CMSIS-NN 库搭建网络模型结构不受光照等过多自然环境影响, 避免手

收稿日期: 2019-09-27; 修回日期: 2019-10-28。

基金项目: 国家自然科学基金项目 (61431009)。

作者简介: 李晓琳 (1993-), 女, 山东临清人, 硕士, 主要从事信息处理技术方向的研究。

通讯作者: 曹银杰 (1963-), 男, 山东聊城人, 硕士生导师, 教授, 主要从事信息处理技术方向的研究。

工制作特征的设计难度,能够在训练中能够自动完成特征的提取、抽象和分类,此方法基于微控制器采用 CMSIS-NN 库搭建网络识别程序框架实现对各类图像的识别,数据安全可靠。2016 年 F. N. Iandola, S. Han 等人提出 SqueezeNet 网络模型,此结构不仅可以保证精度不损失,相比原来的 AlexNet 网络,其网络结构可以将训练的权值压缩 50 倍左右;为提高标志识别的准确度,提出采用改进 SqueezeNet 网络模型为在 Cortex-M 开发板上实现图像识别奠定了基础^[11-12]。

本文提出一种基于微控制器改进 SqueezeNet 交通标志识别的方法,采用改进 SqueezeNet 网络模型结构,降低权值大小,成功移植到前端,前端应用 CMSIS-NN 卷积神经网络库搭建与训练机相同的网络模型结构进行对交通标志的识别,提高了图像识别的速度,并且只将识别结果发送给后端服务器,可降低后端计算数据量。此研究能为智能交通提供了一种可选择的方案同时,也可以为交通管理部门提供了便利。

1 基于微控制器的交通标志识别的设计

1.1 CMSIS-NN 库

CMSIS (Cortex Microcontroller Software Interface Standard) 是 Cortex 微控制器软件接口标准, CMSIS-NN 作为 2018 年 CMSIS 加入的重要的成员,大大缓解了微控制器神经网络相关软件优化压力。CMSIS-NN 通过对神经网络中所需要的重要的关键函数进行优化而达到加速的目的,由 NNFunction (各种实用函数) 和 NNSupportFunctions (实现神经网络层类型相关函数) 两部分组成,内核 API 简单,对在开发板上搭建与 PC 训练机相同的改进的 SqueezeNet 网络模型结构重定位起到关键作用。

1.2 交通标志识别的整体设计

系统 PC 训练机的网络是采用基于 TensorFlow 架构,python 语言编程,利用改进 SqueezeNet 网络模型结构对交通标志图像数据库进行训练,使得权值文件大小缩小了 50 倍,并将训练好的权重矩阵以 .h 文件方式保存;前端利用 Cortex-M 系列芯片内嵌的 CMSIS-NN 库,搭建与训练机相同网络模型结构;并将训练好的权值矩阵 .h 文件成功移植到前端 STM32F767 开发板程序中,同时摄像头采集到的图像利用自定义的图像处理库函数进行预处理,提高了在微控制器 Cortex-M 开发板上的识别速度,数据安全可靠,如图 1 所示为系统整体功能结构图。

2 改进 SqueezeNet 网络模型

从 AlexNet 模型到 Deep Residual Learning 模型,其网络模型经过参数化的,训练的权值矩阵参数存在大量的冗余,由于后期要将其权值矩阵参数移植到嵌入式开发板上,考虑到开发板的运算速度与栈空间,降低冗余的参数以及提高识别准确率的问题,在 SqueezeNet 网络模型结构的基础上提出采用改进 SqueezeNet 网络结构^[12],其参数设置如表 1 所示。

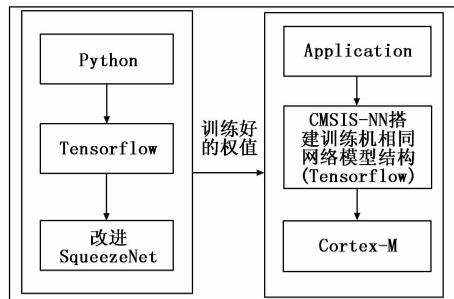


图 1 整体功能结构图

表 1 改进的 Squeezenet 模型参数

Layer type	Filter Size/ Stride	depth	Output size	S	E1	E3
Input Data	—	—	224 * 224 * 3	—	—	—
Conv1	1 * 1/1(64)	1	224 * 224 * 64	—	—	—
Maxpool1	3 * 3/2	0	112 * 112 * 64	—	—	—
Fire2	—	2	112 * 112 * 128	16	64	64
Fire3	—	2	112 * 112 * 256	32	128	128
Fire4	—	2	112 * 112 * 384	48	192	192
Maxpool4	3 * 3/2	0	56 * 56 * 384	—	—	—
Fire5	—	2	56 * 56 * 384	48	192	192
Fire6	—	2	56 * 56 * 384	48	192	192
Fire7	—	2	56 * 56 * 512	64	256	256
Maxpool7	3 * 3/2	0	28 * 28 * 512	—	—	—
Fire8	—	2	28 * 28 * 512	64	256	256
Conv9	1 * 1/1 * 1024	1	28 * 28 * 1024	—	—	—
Global Avgpool9	28 * 28 * 1	0	1 * 1 * 1024	—	—	—
Softmax						

原有的 SqueezeNet 提出 fire module 核心模块^[15], fire module 模块由 squeeze 层和 expand 层两部分组成。squeeze 层有 1 * 1 滤波器的压缩卷积层; expand 层包含 1 * 1 和 3 * 3 卷积滤波器,系统把 1 * 1 和 3 * 3 得到的 feature map 进行 Concat,并满足 $S < e_1 + e_3$,经过这样的一个替换,使得模型缩小了大概 50 倍,同时提高识别的准确率。具体操作如图 2 所示。

在原有 SqueezeNet 模型基础上,为了提高识别的准确度,因此对 SqueezeNet 网络模型结构^[12-13]进行了改进,在保持池化层特征大小与将融合 Fire model 输入输出特征大小保持一致基础上,进行两个方面的改进。

将池化层融合引入到后续的卷积层:融合的算法是池化层提取上一级 t 个特征图,下一层的卷积层 t 个特征图输出提取的 a 个特征图,将 a 和 t 个特征图进行融合得到 s 个特征图,式 (1) 为融合算法。

$$x^s = f[\lceil w^a \text{down}(x)^t + b \rceil]f(w^s x^a)(t + a = s) \quad (1)$$

采用 L2 正则化来实现约束 Softmax: Softmax 函数是归一化的基于概率进行多分类的指数函数,式 (2) 为分类概率的计算式,式 (3) 为训练集损失函数的计算式:

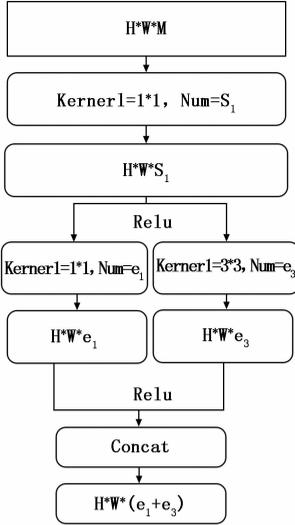


图 2 Fire module 功能结构图

改进的 SqueezeNet 网络模型结构中采用的 L2 约束 Softmax 分类函数，式 (4) 为其计算公式，此函数增加对 $f(x_i)$ 的 L2 范数约束，采用最佳 g 值来确定特征 $f(x_i)$ 的约束值，从而做到对交通标志的明确分类，加快标志分类的收敛速度。

$$f_t = \frac{e^{f(x_t z_t + b_t)}}{\sum_{k=1}^s e^{f(x_k z_k + b_k)}} \quad (2)$$

$$L_a = -\frac{1}{s} \sum_{i=1}^s \lg \frac{e^{w_i^T f_i}}{\sum_{t=1}^c e^{w_t^T f_t}} \quad (3)$$

$$L_a = -\frac{1}{N} \sum_{i=1}^N \lg \frac{e^{w_i^T f(x_i) + b_a}}{\sum_{t=1}^M e^{w_t^T f(x_i) + b_t}} \|f(x_i)\|_2 = g \quad (4)$$

$\forall i = 1, 2, \dots, M$

改进 SqueezeNet 网络模型结构在 CNN 的基础上，通过前向传播获取计算输出结果，利用反向传播计算误差结果，采用反向计算误差对权值进行更新。

3 基于微控制器 Cortex-M 交通标志图像预处理

3.1 图像的采集处理

采用 Cortex-M 系列的 STM32F767 开发板作为系统前端，使用 DCMI 接口，OV5640 摄像头^[14]选择支持数字视频接口 (DVP) 连接前端，采集图像输出格式为分辨率为 1280×800 , RGB565 (16 位)，为了获得网络可识别的图片格式，通过 ARM 公司提供的 CMSIS-DSP 库加快对拍摄到的交通标志图像进行处理^[1314]，程序中 CMSIS-DSP 库调用 DSP 指令对所要标志的图像进行处理得到网络可识别的图像格式，DCMI 接口支持 DMA 传输，系统采用对芯片用程序扩展 32M 的 SDRAM 得到一部分空间，用 DMA 直接上传图片数据，不经 CPU 直接到内存，加快图片上传的速度，对交通标志的快速识别起到了关键性作用。

3.2 图像的预处理

在微控制器上进行图像识别的过程中，主要在于卷积的图像数据的矩阵运算，利用 CMSIS-DSP 库中具有

量运算、矩阵运算、滤波器、统计功能和高级数学等功能，程序中用结构体 arm_matrix_instance_f32 表示矩阵 (软件程序如下)：结构体的元素 Rows 表示矩阵的行，Cols 表示矩阵的列，rData 指向矩阵数组，矩阵元素为 32 位无符号 float 类型，满足数据精度要求。

```
typedef struct
{
    uint16_t Rows;
    uint16_t Cols;
    float32_t * rData;
} arm_matrix_instance_f32;
```

除了矩阵运算，对于摄像头采集到图像，要做到对获取图像的滤波、去噪及快速定位，提出了自定义的图像处理库，对于前端实现对交通标志快速识别，起到重要的作用。相比在 PC 端的图像处理及识别，基于微处理器图像识别功耗较低，稳定可靠及自主可控的优点。

3.3 前端标志的识别

在前端进行标志图像识别前考虑到神经网络运算调用栈区空间大小，微控制器芯片在初始化时扩展了栈区的空间大小，提高神经网络的计算空间。采用改进后的 SqueezeNet 模型结构，在训练机对现有的交通标志集进行训练，并以 .h 权值矩阵文件形式进行保存，根据 .h 文件中是 float32 型数据，微控制器 Cortex-M 系列开发板需要 int8 型数据，需要进行数据转换，并将处理好的权值矩阵 .h 文件移植到 Cortex-M 系列 STM32F767IGTX 开发板，在软件程序中利用程序对摄像头，对于一张图相片上多个标志图像的，利用相关的软件程序对交通标志的标注定位，利用图像处理库会对识别的交通标志进行灰度、去噪^[14]等预处理，利用搭建与训练机相同模型结构进行识别，并将识别出的交通标志信息上传。交通标志识别流程如图 3 所示。

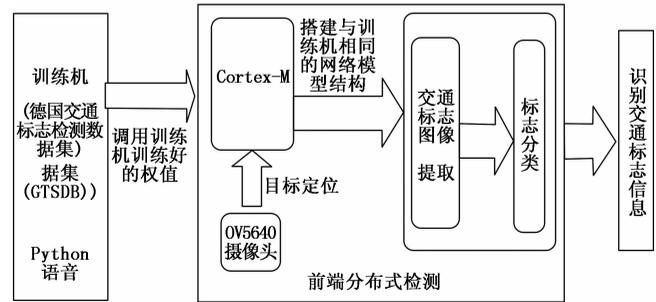


图 3 交通标志识别整体流程

4 实验

4.1 GTSDB 数据集

系统采用德国交通标志检测数据集 (GTSDB)，此数据集包含 43 类真实车辆驾驶环境下的高清交通标志场景图像，数据集包含大量分辨率低、光照不良、遮挡及运动模糊等不利条件下的交通标志样本图像^[14]。为了扩充以及增强数据集的质量，在交通部门允许的情况下，自行拍摄晴天、阴天、雨天、光照不足等不同条件的车辆真实驾驶图

像来补充数据集, 最终自定义数据集包含 102 类主交通标志的图像。实验采用对 102 类自定的数据库由不同亮度下的各个交通标志的标准样本标志图像进行训练, 通过数据扩增的方法将所有图像按照正方向、反方向各旋转 20°, 每隔 5°采集一次, 根据四种天气环境 (晴朗, 光照合适、阴, 光照不足、雨天、部分被阴影遮挡), 定义大约一幅图像形成 320 幅样本图像, 自定义数据库标志图像库图片已达到 35840 张, 为了便于训练, 将所有的数据集每幅图像分辨率都处理成尺寸为 224 * 224 像素^[8], 标志图像部分样本如图 4 所示。



图 4 部分标交通标志样本

4.2 实验验证与结果分析

在公路交通管理部门的许可监督下, 实验采用一辆正在行驶的车辆为例, 利用 PC 训练机采用改进 SqueezeNe 网络模型结构将对 102 类指示交通标志进行训练, 并将训练好的权值矩阵文件成功移植到 Cortex - M 系列 STM32F767IGTX 开发板上, 在开发板上搭建与训练机相同的网络结构, 首先利用自定义的图像处理库进行对摄像头采集到的图像进行预处理, 然后调用权值矩阵文件, 实现对预处理图像的识别。实验采取在开发板上测试完后结果进行记录, 再对相同的标志图像在计算机上面进行测试识别验证, 并将获得的结果进行比对的方法。

表 2 是针对不同测试环境下, 对指示标志、禁令标志、警告标志和旅游区标志等 4 类共 102 种主标志交通标志图像识别, 并将准确率进行比较; 表 3 对不同标志 (圆形指示标志、圆形禁令标志、三角形警告标志、方形旅游区标志) 类型进行识别; 表 4 是利用训练机所得到的权值矩阵成功移植到开发板上, 随意抓取六次六种车型在原始 AlexNet、SqueezeNet、改进 SqueezeNet 及利用改进 SqueezeNe 网络模型结构在 Cortex-M 实现的准确率以及模型参数大小的比较。

表 2 在不同环境下各个特征识别准确率(%)

测试环境	指示标志	警告标志	禁令标志	旅游区标志
晴朗, 光照合适	98.256	97.332	96.928	96.636
阴, 光照不足	97.336	96.289	96.716	96.984
雨天	97.127	96.356	97.132	97.829
部分被阴影遮挡	98.565	98.435	98.329	98.605
平均准确率	97.821	97.103	97.276	97.514

表 3 不同类型标志识别精确度(%)

标志类型	实验数据	识别准确度
圆形指示标志	384	98.332
圆形禁令标志	768	98.289
三角形警告标志	1568	96.356
方形旅游区标志	544	98.435

表 4 针对不同网络模型在计算机与 Cortex-M 系列开发板交通标志识别结果比较(%)

标志类型	原始	原始	改进	改进
	AlexNet (计算机)	Squeezenet (计算机)	Squeezenet (计算机)	Squeezenet (Cortex-M)
指示标志	95.342	95.342	98.378	98.300
警告标志	95.200	95.200	97.323	97.300
禁令标志	92.641	92.641	97.352	97.400
旅游区标志	95.816	95.820	97.276	97.300
平均识别率	94.750	94.751	97.582	97.575
平均测试时间/s	0.220	0.200	0.132	0.132
模型大小	287M	5.74M	5.74M	5.74M

根据表 2 结果分析, 通过采取对 102 种的 4 类部分主交通标志在不同环境下识别结果统计, 实验结果表明标志识别精度比较稳定, 标志平均识别率也达到了较高的精确度; 表 3 根据识别数目不同, 按相同的规则分配识别数目多少, 针对不同类型标志识别, 发现圆形标志与方形要比三角形标志识别准确度要高; 由表 4 分析在原有模型 AlexNet、原 SqueezeNet 及修改的 SqueezeNet 网络模型结构三者相比较, 在计算机与开发板上结果对比发现识别准确率基本相同, 并且改进模型结构权值矩阵大小相比 AlexNet 模型缩小了将近 50 倍, 提高 Cortex-M 核对标志图像识别的处理, 明显看出再识别率有了明显的改善, 在识别速率上, 在前端将交通标志识别与在计算机上直接识别基本一致, 说明此方法可行。

实验结果验证, 利用 Cortex-M 系列芯片推出的 CM-SIS-NN 库搭建网络可以进行交通标志图像识别是可行的, 并且通过改进的 SqueezeNet 网络模型结构训练好的权值参数的大小有了明显的减少, 对于将模型参数移植到 Cortex-M 嵌入式开发板上奠定了基础, 同时利用自定的图像处理库, 提高图像识别及预处理的速度。针对目前交通标志的识别都是基于操作系统之上, 此研究方法提出不依赖操作系统的, 在微控制器芯片上实现神经网络识别的方法, 为车辆驾驶和交通安全管理提供极大便利。给未来机器学习能在芯片上学习提供可选择的方案, 同时提高了交通标志识别效率。

5 结语

基于交通标志识别研究的基础上, 提出基于微控制器 Cortex-M 系列开发板对交通标志识别, 考虑到 Cortex-M 开发板栈区空间大小的调整以及内存的分配问题, 采用

改进 SqueezeNet 卷积神经网络模型结构,有效的缩小了权值文件的大小,便于成功移植到开发板上,提高了图像训练识别的速度;同时采用自定义的图像处理库,实现对摄像头采集到的图像快速定位与滤波、去噪等预处理,而且基于 Cortex-M 系列芯片图像识别,不依赖于操作系统,稳定可靠,而且通过实验证明,对于 102 类交通标志识别平均准确度达到了 97.4% 以上,而且识别速度也有了明显的提高。但是由于数据集有限,目前只能对交通部分的 102 类主标志进行识别,争取实现对更多交通标志的识别,为车辆驾驶和交通安全管理提供可参考的价值。

参考文献:

- [1] 谢铮桂. 基于改进的卷积神经网络的手势识别的研究 [J]. 计算机应用与软件, 2019, 36 (3): 192-195.
- [2] Schmidhuber J. Deep learning in neural networks: An overview [J]. Neural networks, 2015, 61: 85-117.
- [3] 徐岩, 韦镇余. 一种改进的交通标志图像识别算法 [J]. 激光与光电子学进展, 2017, 54 (2): 124-131.
- [4] 王旺, 徐俊武, 李颖先. 改进的基于卷积神经网络的图像超分辨率方法 [J]. 计算机应用与软件, 2019, 36 (3): 214-218.
- [5] Andrychowicz M, Denil M, Gomez S, et al. Learning to learn by gradient descent [A]. Advances in Neural Information Processing Systems [C]. 2016: 3981-3989.

- [6] Cheng G, Zhou P, Han J. Duplex metric learning for image set classification [J]. IEEE Transactions on Image Processing, 2017, 27 (1): 281-292.
- [7] Yin S, Deng J, Zhang D, et al. Traffic Sign Recognition Based on Deep Convolutional Neural Network [A]. Ccf Chinese Conference on Computer Vision [C]. Springer, Singapore, 2017.
- [8] 余泽东, 黄妙华. 基于 SIFT 算法的交通标志识别方法研究 [J]. 数字制造科学, 2018, 16 (1): 55-59.
- [9] Liu W, Wang Z, Liu X, et al. A survey of deep neural network architectures and their applications [J]. Neurocomputing, 2017, 234: 11-26.
- [10] Qin Z, Li Z, Zhang Z, et al. ThunderNet: Towards Real-time Generic Object Detection [J]. arXiv preprint arXiv: 1903.11752, 2019.
- [11] Iandola F N, Han S, Moskewicz M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size [J]. arXiv preprint arXiv: 1602.07360, 2016.
- [12] 吴军, 邱阳, 卢忠亮. 基于改进的 SqueezeNet 的人脸识别 [J]. 科学技术与工程, 2019, 19 (11): 218-223.
- [13] 焦计晗, 张帆, 张良. 基于改进 AlexNet 模型的油菜种植面积遥感估测 [J]. 计算机测量与控制, 2018, 26 (2): 186-189.
- [14] 董艺威, 于津. 基于 SqueezeNet 的轻量化卷积神经网络 SlimNet [J]. 计算机应用与软件, 2018, 35 (11): 226-232.

(上接第 79 页)

如表 2 前 3 项, 运行人员收到诊断系统发出故障诊断结果后, 及时安排检修, 检修结果发现这 3 个电容器确有电容值变化和介损增大的问题, 可能内部已经出现绝缘老化的现象。该诊断结果有效避免了可能出现的电容器故障导致的突然停电。

10 kV 配网电容器在线监测与故障诊断系统实现了全天候的在线实时诊断。该为电气运行管理部门提供了充分的电容器运维决策依据, 降低了因电容器故障导致的停电风险, 并能自动生成报告, 减轻运行人员工作量。

5 结束语

电力电容器作为电力系统必不可少的无功补偿装置, 能否在其故障前及时发现并处理是非常重要的。针对目前大多数电力电容器状态监测系统因信息实时性不足和数据频密度不足, 导致难以实现准确的在线故障预判等问题。本文立足于电力电容器运维的实际需求, 构建了一套完整的电力电容器故障在线监测系统, 给出了一套采用神经网络融合电容器电流、电容、电阻和电压等信息的故障诊断模型和方法。在实际应用中, 该系统能及时并准确地对电容器的异常状态和故障特征进行捕捉, 能够提高电网设备的运维效率, 提升电网运行可靠性。

参考文献:

- [1] 苏志明. 电力电容器智能化监测与故障监测系统研究 [D]. 北京: 华北电力大学, 2014.
- [2] 汪力, 曾湘隆, 唐娟, 等. 电力电容器故障统计分析 [J]. 电工技术, 2019 (9): 88-89.
- [3] 康军强, 郑江峰, 陈伟. 配网补偿电容器故障监测研究 [J]. 水利规划与设计, 2015 (7): 60-63.
- [4] 郭昆丽, 田海霞, 王建波, 等. 某变电站 10 kV 并联电容器故障分析及对策 [J]. 广东电力, 2017, 30 (3): 58-63.
- [5] 陈桂文, 吴丽霞, 戴军瑛, 等. 变电站电力电容器智能在线监测 [J]. 电力电容器与无功补偿, 2013, 34 (6): 56-59.
- [6] 张健, 余超耘, 潘亮, 等. 基于表面分析的金属化膜电容器老化机理研究 [J]. 广东电力, 2019, 32 (8): 119-125.
- [7] 潘佩明. 电力电容器安全运行分析与在线监测技术研究 [D]. 北京: 华北电力大学, 2015.
- [8] 咸日常, 李其伟, 孙学锋, 等. 基于状态量监测的电力电容器故障监测技术的研究 [J]. 电力电容器与无功补偿, 2018, 39 (3): 21-25.
- [9] 超级电容器时变电路模型参数辨识与仿真 [J]. 同济大学学报: 自然科学版, 2012 (6): 949-954.
- [10] 基于超级电容模型的参数辨识及其仿真研究 [J]. 机电一体化, 2010 (12): 13-16.