

# 基于深层卷积神经网络的山地光伏电站防火远程监控系统设计

文/王斌<sup>1</sup> 陈宏<sup>1</sup> 曾峰<sup>2</sup> 张建林<sup>1</sup> 徐清环<sup>1</sup>

1. 中电（福建）电力开发有限公司；2. 中电投绿能科技有限公司

介绍一种基于深层卷积神经网络的山地光伏电站防火远程监控系统。通过采用改进的ResNet模型，研究提出一种高效的火灾检测方法，显著提高监控系统在火灾预防中的准确性和可靠性。实验结果显示，与传统监控方法相比，该系统在准确率、召回率、精确率和F1分数上都有显著提升。未来的工作将着重于算法的实时处理能力和环境适应性的提升。

山地光伏电站因其独特的地理位置和环境条件，成为了火灾风险的重点关注对象。这类电站常面临极端天气、设备故障及环境因素引发的火灾风险，一旦发生火灾，不仅会造成巨大的经济损失，还可能导致不可逆的环境破坏，如大面积森林破坏和生物栖息地丧失。因此，开发有效的防火监控系统对于保障这些电站的安全运营至关重要。

本研究旨在通过引入深层卷积神经网络（CNN），优化山地光伏电站的火灾监控效率和准确性。开发一套能够实时监测和预警的远程监控系统，该系统利用先进的图像处理技术和机器学习算法，不仅能够快速识别潜在火情，还能通过持续学习优化其预警机制，为山地光伏电站提供一个科技支持更为强大的安全保障措施。

## 理论技术基础

### 1. 现有的光伏电站防火技术和方法

光伏电站防火技术主要集中在火灾检测、预警及自动灭火系统。传统的火灾检测方法包括烟雾探测器和温度传感器，这些设备可以在火灾发生初期通过监测烟雾和温度异常迅速响应。此外，一些光伏电站还采用红外热像技术进行温度监测，以识别设备过热情况，预防火灾的发生。尽管这些方法在实际应用中

相对成熟，但它们通常依赖于传感器的准确布置和维护，且在复杂环境下的灵敏度和稳定性仍有待提高。

### 2. 深度学习在火灾监控和预警系统中的应用概述

深度学习，尤其是卷积神经网络（CNN），已广泛应用于图像识别和处理领域。CNN通过模拟人类视觉系统的机制，能够自动从大量图像数据中学习特征，无需手动编码图像属性。基本的CNN结构包括输入层、多个卷积层、池化层、全连接层和输出层。卷积层负责提取图像中的局部特征；池化层用于降维和抽象；全连接层将学习到的特征映射到最终的输出类别。

$$\text{output} = \sigma(WX + b) \quad (1)$$

式中， $W$ 为权重； $X$ 为输入数据； $b$ 为偏置； $\sigma$ 为激活函数。

在火灾监控和预警系统中，CNN可以被训练用于识别烟雾和火焰的图像特征。通过分析安装在光伏电站的监控摄像头获取的实时图像，CNN能够识别出异常模式，迅速触发警报系统。

### 3. 相关工作的优点与局限性

目前，深度学习技术在火灾检测领域已显示出较高的准确性和较低的误报率。例如，利用深度学习进行图像分析的系统能够区分真实火焰与日常环境中的其他光源干扰。然而，这些系统的性能高度

依赖于训练数据的质量和多样性。在数据较为单一或异常情况下，系统的检测速度和准确率可能下降。此外，高复杂度的模型需要较大的计算资源，这在实时监控应用中可能成为瓶颈。

系统设计与方法

1. 系统架构

本研究所开发的远程监控系统基于深层卷积神经网络，其架构设计主要包括数据收集、数据处理和反馈机制三个关键部分。系统首先通过安装在光伏电站的多个高清摄像头收集实时图像数据，这些数据随后被传输到中央处理单元。在数据处理阶段，图像数据经过预处理后输入到深度学习模型中进行火灾识别。一旦识别出火灾特征，系统立即触发警报，并通过相关接口向管理人员发送警报信息，实现快速响应。如图1所示。




图1 基于深层卷积神经网络的山地光伏电站防火远程监控系统示意图

2. 基于改进ResNet的山地光伏电站火灾识别模型设计

为提高火灾识别的准确性和效率，本研究采用基于ResNet（残差网络）的改进模型。ResNet-50是一种流行的深度残差网络，设计用于处理更深层次的网络结构而不会遇到退化问题。ResNet通过引入残差学习解决了深度网络训练难的问题，使得网络能够在增加深度的同时保持性能。本研究中的网络模型结构包括初始的卷积层，多个残差块，以及最后的全连接层。

初始卷积层：输入层后接一个卷积层，用于提取图像的初步特征。第一个卷积层使用 $7 \times 7$ 的

卷积核，步长为2，进行卷积操作，将图像尺寸从 $512 \times 512$ 减少到 $253 \times 253$ （考虑到边界效应和步长）。接着是一个 $3 \times 3$ 的最大池化层，步长也是2，进一步降低尺寸到 $126 \times 126$ 。

残差网络模块是多个残差块的堆叠，每个块内包含两个卷积层，中间接ReLU激活函数，且采用批归一化（Batch Normalization）。在残差网络模块中，包含四个残差块，每一个残差块包含若干卷积层：

第一组：包含3个残差单元，每个单元中的卷积层使用 $1 \times 1, 3 \times 3, 1 \times 1$ 卷积核，特征图尺寸保持为 $126 \times 126$ 。

第二组：包含4个残差单元，特征图大小下降至 $63 \times 63$ 。

第三组：包含6个残差单元，特征图大小下降至 $32 \times 32$ 。

第四组：包含3个残差单元，特征图大小最终减少至 $16 \times 16$ 。

网络结果层次见表1。

表1 改进ResNet网络结构层次

| 层       | 输入尺寸             | 输出尺寸             | 卷积核大小          | 备注             |
|---------|------------------|------------------|----------------|----------------|
| 初始卷积层   | $512 \times 512$ | $253 \times 253$ | $7 \times 7/2$ | 含边界填充(padding) |
| 最大池化    | $253 \times 253$ | $126 \times 126$ | $3 \times 3/2$ | -              |
| 残差块组1   | $126 \times 126$ | $126 \times 126$ | 多种             | 3个残差单元         |
| 残差块组2   | $126 \times 126$ | $63 \times 63$   | 多种             | 4个残差单元         |
| 残差块组3   | $63 \times 63$   | $32 \times 32$   | 多种             | 6个残差单元         |
| 残差块组4   | $32 \times 32$   | $16 \times 16$   | 多种             | 3个残差单元         |
| 全局平均池化  | $16 \times 16$   | $1 \times 1$     | 全局             | -              |
| 全连接层    | $256 \times 1$   | 输出类别数            | -              | -              |
| Softmax | 输出类别数            | $1 \times 1$     | -              | 火灾置信度          |

在所有残差块之后，一个全局平均池化层将每个 $16 \times 16$ 的特征图缩减成一个单一的特征值，最后通过全连接层+Softmax函数将特征映射到输出类别。

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_{c=1}^C e^{z_c}} \quad (2)$$

式中， $z_i$ 为第 $i$ 个节点的输出值； $C$ 为输出节点个数，并通过Softmax函数将多分类的输出值映射到0~1之间。

在基于深度学习的火灾检测模型中，最后一个

全连接层通常接一个Softmax函数，用以输出每一个类别的预测概率。对于火灾检测，可以设定一个特定的阈值，当模型输出的火灾类别的置信度超过这个阈值时，系统触发预警信号。

设 $p$ 是模型通过Softmax函数输出的火灾类别的预测概率， $\theta$ 是预设的阈值。预警策略可以表示为一个简单的条件判断公式

$$\text{预警信号} = \begin{cases} \text{True}, & p \geq \theta \\ \text{False}, & p < \theta \end{cases} \quad (3)$$

阈值 $\theta$ 的设定非常关键，它决定了系统预警的灵敏度和特异性。阈值设置过低可能导致频繁的误报，设置过高则可能错过一些实际的火灾事件。需要通过在验证集上的测试和调整来确定，以达到最佳的预警效果。实际系统中可能还需要考虑预警的持续性和重复性，即连续多个预测结果超过阈值时才触发预警，以减少误报。要求连续三次预测的置信度超过阈值才发出预警信号。这样的策略可以进一步稳定预警系统的表现。

### 3. 模型训练和测试方法

本研究中，精心选择具体的数据集来训练和验证改进的ResNet模型，以便准确识别山地光伏电站中的火灾场景。选定的主要数据集为FIRE-DS（火灾检测数据集）。FIRE-DS是一个专门为火灾检测研究设计的数据集，包含多种火灾和非火灾图像，这些图像涵盖了不同的火灾类型以及多样的环境背景，如森林、建筑内部和户外场景等。

为了进行有效的模型训练与测试，将数据集分为训练集、验证集和测试集。具体而言，70%的数据用于模型训练，这部分数据用来调整模型的参数；15%的数据作为验证集，用于模型的超参数调整和防止过拟合；剩余的15%作为测试集，用于评估模型的最终性能。

在模型的训练过程中，损失函数由两部分组成：一个是基于数据的损失（例如交叉熵损失），另一个是正则化项。L2正则化也称为权重衰减，其目的是减少模型参数的复杂度，防止过拟合。

$$\mathcal{L} = \mathcal{L}_{\text{data}} + \lambda \sum_i W_i^2 \quad (4)$$

式中， $\lambda$ 为正则化系数； $W_i$ 为模型权重； $\mathcal{L}_{\text{data}}$ 为针对每个类别的预测和实际标签的交叉熵损失。

整个训练过程中，使用了批量梯度下降法来优化损失函数，选择了Adam优化器，因其在实践中

展现出的快速收敛性和自适应学习率调整能力。最终，模型的性能通过在独立测试集上的表现来验证，确保所开发系统的准确性和实用性。

## 实验结果与分析

本实验所使用的硬件包括具有NVIDIA Tesla V100 GPU的高性能计算机，使用Python编程语言，基于TensorFlow框架的Keras库来构建和训练模型。旨在验证基于改进ResNet的深层卷积神经网络模型相对传统机器学习方法（Bayesian）在山地光伏电站防火远程监控中的有效性和优势。选用准确率、精确度、召回率和F1分数作为防火远程监控系统的监测性能。不同算法性能对比见表2。

表2 不同光伏电站防火监控算法性能对比

| 模型                       | 准确率 (%) | 召回率 (%) | 精确率 (%) | F1分数  |
|--------------------------|---------|---------|---------|-------|
| Bayesian (Baseline)      | 85.6    | 83.2    | 86.1    | 0.845 |
| ResNet-50                | 92.5    | 90.1    | 93.6    | 0.915 |
| ResNet-50+Regularization | 93.2    | 91.2    | 94.3    | 0.927 |

从结果可以看出，基于ResNet-50的模型在所有关键性能指标上都明显优于Bayesian模型（基线）。进一步增强的ResNet-50模型，通过加入L2正则化（Regularization），展现了更优的性能。具体来说，该模型的准确率提升到了93.2%，召回率提升到91.2%，精确率提升到94.3%，而F1分数达到0.927。这些改进主要得益于正则化处理，有效减少模型过拟合，提高其在多变环境下的泛化能力。这些结果充分展示基于深度卷积神经网络的方法在火灾监控领域的应用潜力，特别是在提高监控系统的准确性和可靠性方面。

## 结束语

本研究成功开发一套基于改进的ResNet模型的深层卷积神经网络，用于山地光伏电站的火灾远程监控。通过详细的理论分析、系统设计以及严密的实验验证，证明该系统在火灾检测中的高效性和准确性。特别是在对比传统的监控方法与基于深度学习的方法后，显著提升的性能指标如准确率、召回率、精确率和F1分数，均表明深度学习技术在火灾预防和监控领域的应用潜力和优势。EA

（收稿日期：2024-05-07）