

基于Keras框架的油气管道缺陷分类应用研究

李清旭¹, 李荣威²

¹上海理工大学机械工程学院, 上海

²武汉纺织大学计算机与人工智能学院, 湖北 武汉

收稿日期: 2023年12月23日; 录用日期: 2024年1月20日; 发布日期: 2024年2月29日

摘要

针对油气管道缺陷现代化检测问题, 本文提出了一基于Keras框架的深度学习检测算法, 采用Adam-S优化器算法应用到卷积神经网络, 并融合了Environment-Cognition-Action (ECA)-Effi注意力机制, 增强了卷积神经网络的特征表达能力, 提高了有效验证数据的利用效率, 并通过对比实验, 分析比较了影响深度学习过拟合现象高度相关的学习率、Dropout两个参数, 提取最优权重参数矩阵, 建立验证集并导入到预测模型中, 得到油气管道6种缺陷特征的预测结果, 且预测结果与真实标签高度接近, 验证了所搭建神经网络的表现及其有效性, 最后, 量化对比了目前应用较为普遍的ResNet18网络以及改进前的Adam-CNN算法, 有效验证了Adam-S结合改进ECA-CNN算法的优越性能。

关键词

油气管道, 缺陷检测, Keras, 深度学习, 卷积神经网络

Application Research on Defect Classification of Oil and Gas Pipelines Based on Keras Framework

Qingxu Li¹, Rongwei Li²

¹University of Shanghai for Science and Technology, School of Mechanical Engineering, Shanghai

²School of Computer and Artificial Intelligence, Wuhan Textile University, Wuhan Hubei

Received: Dec. 23rd, 2023; accepted: Jan. 20th, 2024; published: Feb. 29th, 2024

Abstract

This paper proposes a deep learning detection algorithm based on the Keras framework to address the issue of modern detection of oil and gas pipeline defects. The Adam-S optimizer algo-

rithm is applied to convolutional neural networks, and the Environment Recognition Action (ECA) Effi attention mechanism is integrated to enhance the feature expression ability of convolutional neural networks and improve the utilization efficiency of effective validation data. Finally, through comparative experiments, We analyzed and compared the learning rate and Dropout parameters that are highly correlated with the overfitting phenomenon in deep learning, extracted the optimal weight parameter matrix, established a validation set, and imported it into the prediction model to obtain the prediction results of six types of defect features in oil and gas pipelines. The predicted results were highly close to the real labels, verifying the performance and effectiveness of the constructed neural network.

Keywords

Oil and Gas Pipelines, Defect Detection, Keras, Deep Learning, CNN

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

进入新世纪以来,我国的油气管道建设工业发展迅猛,近年来伴随着能源结构调整,管道运输仍然是解决东西部能源分布不均衡的重要一环,作为国内距离最长、口径最大的西气东输工程,每年通过管道向内地输送近 120 亿立方米天然气,俨然成为国民经济的中流砥柱,沿线在扩大内需、增加就业,促进电力、化工冶金等相关行业的发展做出重要贡献[1]。长输油气管道一般由金属材料加工而成,由于分布环境复杂,不可避免的会被油气腐蚀或制管缺陷放大,造成很多管道网线出现老化,出现了安全隐患甚至爆炸,严重影响了人民安全,因此对管道的安全检测有着重要的意义。

在 20 世纪 60 年代研发智能清管器由美国 Knapp 公司和 Girard 公司共同研发,缺点是对缺陷位置的确定误差较大[2], SoldevilaL [3]利用了贝叶斯网络稳定的效率,在验证中提出一种与时间参数结合的利用贝叶斯进行分类器,降低了建模的不确定性和传感器本身误差的影响,进一步提高了分类性能和定位精度。徐蒋明等[4]用 3 种基于小波包变换(WPT)的特征提取方法,对焊缝缺陷回波信号提取特征,并将其作为 BP 神经网络的输入,达到了 85.71%的缺陷识别率。2017 年, Vaswanis [5]等人提出了 Transformer 模型,广泛应用于自然语言处理领域,人工智能领域取得了卓越的成绩。2022 年,韩飞[6]提出了一种 Adam-S 的优化算法,通过复用前后两个梯度的二阶动量增强了预测的准确性。基于上述理论研究,本文通过搭建 Keras 深度学习多标签分类框架,并结合线下采集的 2077 个管道缺陷图像,采用新 Adam-S 算法将模型应用于 6 个缺陷特征的分类,并通过分析优化模型的影响因素提高了其泛化能力,为管道缺陷的现代化检测,生产过程的有效监督提供了一定的社会价值。

2. Keras 框架及多标签分类问题

2.1. Keras 简介

作为深度学习较为热门的框架之一, Keras 是一个高层次的神经网络 API, 基于 Tensorflow、Theano 以及 CNTK 后端编写, 它的模型可以理解各个层的序列分布或数据运算, 可同时配置自定义模块, 用户可以自由组合, 这些模型包括各网络层、不同分布的损失函数、优化器以及初始策略管理等, 具有较好的模型构建能力, 并且扩展性能较为出色, 更适合与先进的研究工作。

2.2. Adam-S 优化器

Adam 是基于实现神经网络的反向传播过程, 通过训练数据迭代更新所在层的权重参数矩阵, 是可以替代随机梯度下降的优化算法[7]。Adam 算法和传统的随机梯度法的区别在于, 随机梯度下降在迭代更新过程中参数保持恒定, Adam 算法则会通过计算各梯度动量值针对特定的学习率, 适应参数的改变, 文献[8]证明了 Adam 算法的学习率主要是有二阶动量控制的, 二阶动量会随时间变化而变化, 且变化是非单调的, 导致网络在训练期间学习率产生震荡使模型无法收敛。在 Adam-S 中, 考虑了时间变量的影响, 修正偏差及更新参数如下, 其中 m_t 是一阶动量, s_t 为当前梯度的二阶动量, β_1 、 β_2 分别为 m_t 和 s_t 在步骤 t 下的动量值, θ 为模型相关收敛参数, Δ 为偏差因子。

$$m_t \leftarrow \frac{m_t}{1-\beta_1}, s_t \leftarrow \frac{s_t}{1-\beta_2} \quad (1)$$

$$\theta_t \leftarrow \theta_{t-1} - \frac{\alpha m_t}{\sqrt{s_t} + \Delta} \quad (2)$$

2.3. ECA 注意力机制

ECA 算法作为一种用于卷积神经网络特征增强表达的方法, 目的是将不同的权重参数分配到不同的特征数据, 使得网络能够选择性的关注某一特征或忽略某种特征, SENet [9]在网络中引入 ECA 注意力机制, 显著提高了模型的性能。研究过程发现基于 EfficientNet 与 ECA 机制结合, 结合了新的算法具有更快的训练速度和模型轻量化作用, 并且可有效增强模型对管道缺陷特征的提取能力, 部分 Fused-MBconv (MBconv)结构图如图 1 所示。




Figure 1. Partial Fused-MBconv schematic diagram
图 1. 部分 Fused-MBconv (MBconv)示意图

2.4. 多标签分类问题

针对本文 6 个管道缺陷样本标签, 2077 个样本数量, X 为样本集, Y 为特征集, 那么假设其数学表示为:

$$X = \{x_1, x_2, x_3, \dots, x_{2076}, x_{2077}\} \quad (3)$$

$$Y = \{y_1, y_2, y_3, y_4, y_5, y_6\} \quad (4)$$

其中 x 为每个图像样本的特征矩阵, y 分别对应分类需求的 6 个标签, 对于该多分类输出层采用 *softmax* 作为激活函数, *softmax* 激活函数的思想是将最后得到的全连接层即 N 维的实数向量缩减至一个 6 维实数向量, 经过非线性变换后, 使得图像每个元素大小值都在 0~1 之间, 并且满足归一化条件, 通过神经网络对样本初步建模模型的输出为

$$\hat{y}_0 = \arg \max_{j \in \{1,2,3,4,5\}} p(s_j|x_i) \quad (5)$$

其中 P 为 x 中的某个样本对应正确标签的概率, s_j 即表示图像样本。

3. 深度学习 CNN 模型的搭建

3.1. 金属管道缺陷图像特征的采集

管道材料加工表面通过工业高帧率工业相机拍摄, 产品参数如表 1 所示。采集样本主要包括月牙间隙、油斑、夹杂物、卷坑、表面腐蚀、加工划伤 6 类特征, 并将其归类做数据集的预处理。

Table 1. Modal frequency and mode characteristics of frame
表 1. 高帧率工业相机参数

属性	参数	属性	参数
分辨率	1920*1080	帧速率	120 fps
信噪比	39 dB	快门系统	Frame.exp
传输距离	L < 10 m	续航时间	3~4 h
镜头直径	8.5 mm	防水级别	IP67

3.2. 图像数据的预处理

对于采集的原始数据, 处理方式如图 2 所示。通过预处理工作, 使得图像具有相同的尺寸, 将 RGB 三个通道均转换为神经网络可识别的矩阵形式。

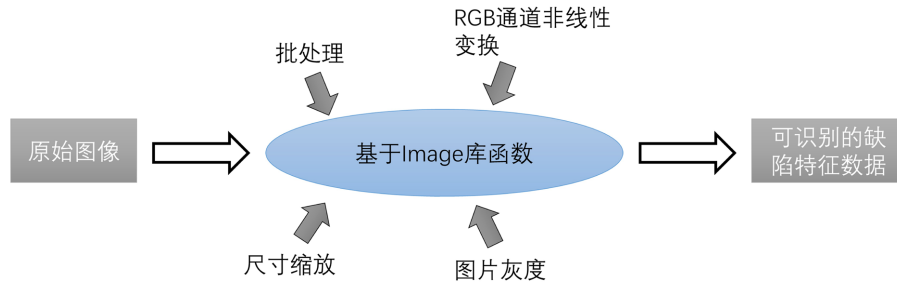


Figure 2. Pipeline defect image preprocessing process
图 2. 管道缺陷图像预处理流程

3.3. 卷积神经网络的搭建

卷积神经网络是由卷积层和若干子采样层(池化层)构成的特征提取器, 本实验设计结构图如图 3 所示, 即输入图像数据后, 经卷积层、池化层、全连接层以及 Dropout 选择性断点结合, 大大简化了模型的复杂度, 提高了运算效率, 输出后的数据会被储存。

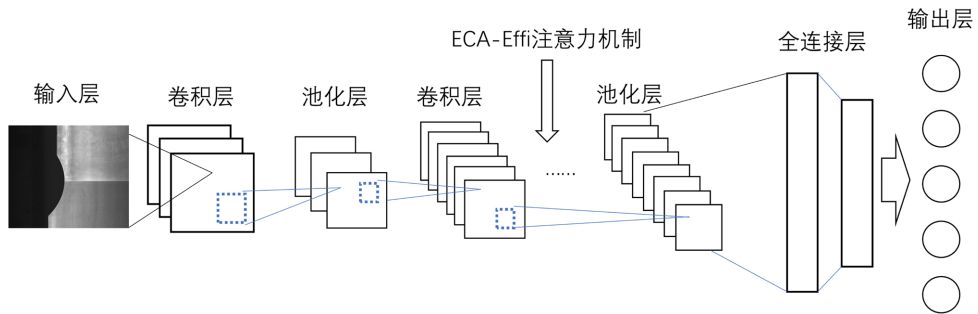


Figure 3. Pipeline defect image preprocessing process
图 3. 管道缺陷图像预处理流程

在卷积网络构建的过程中,应用深度可分离卷积[10]的方法,可优化模型计算过程参数。对于一个输入和输出参数都不变的多层网络,考虑单个卷积核与多个卷积核灵活应用,可实现计算参数数量的数量级降低,同时提高模型的计算速度。

4. 模型预测实验

4.1. 环境模型参数

模型详细参数如表 2 所示。

Table 2. Model detailed parameters
表 2. 模型详细参数

属性	值
样本数量	2077
迭代次数	200
批次大小	32
学习率	0.01、0.001、0.0001
优化器	Adam-s
缺陷特征数	6

本研究实验环境为 Intel(R)Corei7-9750@2.60Ghz 处理器, NVIDIA GeForce 1660Ti 和 16GRAM, 软件环境为 Windows 操作系统, 基于 Keras-Tensorflow2.1 搭建神经网络模型。

4.2. 对比实验

4.2.1. 学习率




Figure 4. Learning rate $lr = 0.01$ Model accuracy curve
图 4. 学习率 $lr = 0.01$ 模型准确率曲线

通过侧重的应用层面, 对比了该卷积网络结构设计的 3 种学习率对模型参数的影响, 学习率分别是 0.01、0.001 以及 0.0001, 训练和验证的准确率曲线如图 4~6 所示。对比结果可知, 学习率数值越大, 曲线也会出现较大波动, 学习率数值越小, 模型计算的步进长度越小, 数值也更加精密, 但验证集和训练集的差值不断增大, 迭代到第 50 次与第 135 次临界, 图像趋于直线, 但是出现了过拟合现象, 因此需要对模型进一步改进。




Figure 5. Learning rate $lr = 0.001$ model accuracy curve
图 5. 学习率 $lr = 0.001$ 模型准确率曲线




Figure 6. Learning rate $lr = 0.0001$ model accuracy curve
图 6. 学习率 $lr = 0.0001$ 模型准确率曲线

4.2.2. Dropout 策略

Hinton 和 Srivastava 于 2012 年提出了 Dropout 思想, 来解决前馈神经网络过拟合的问题, 以提高神经网络的性能。为了使神经网络计算细节更加直观, 规定学习率 $\text{learning rate} = 0.0001$, 实验过程中对两个全连接层分别随机删除 50% 以及 25% 的神经元, 之后再再将神经元通过修改后的网络正向传播, 最后再将下一步的结果反馈给上一级, 是模型更加具有泛化性。两种方案的模型曲线如图 7 和图 8 所示。




Figure 7. Set 3 * Dropout = 0.25 (lr = 0.0001)

图 7. 设定 3 * Dropout = 0.25 (lr = 0.0001)




Figure 8. Set 3 * Dropout = 0.5 (lr = 0.0001)

图 8. 设定 3 * Dropout = 0.5 (lr = 0.0001)

通过曲线可以看出 Dropout 机制对神经网络的影响, 随机剔除神经元数目越少, 验证数据的损失率不断升高, 而验证集的准确率趋于常数, 约为 75%, 相反, 如果增大删除神经元的数目, 那么不可避免的也会造成数据特征丢失, 但从曲线来看, 训练准确率是保持稳步上升的, 验证数据的损失也随着神经网络的运行先降低后升高, 而后出现波动, 可通过网络结构的微调以改善该情况。

4.3. 常规化预测模型

将权重参数矩阵导出, 建立预测模型, 从处理好的未参加训练及测试的数据中选择几组图像, 导入模型进行预测, 对于 6 个特征预测的准确率如图 9 所示。




Figure 9. Feature prediction accuracy
图 9. 特征预测准确率

从图中可以看出, 神经网络对表面腐蚀以及加工划伤预测准确率较高, 分别为 96.19% 和 94.57%, 对管道夹杂物以及月牙间隙的识别率分别为 86.73% 以及 88.93%, 可判断是由于管道所处环境的复杂性决定的, 夹杂物的多态性, 对模型的识别效果产生了很大程度的影响。

4.4. 不同模型算法的性能对比

为了验证本文 Adam-S-改进 ECA-CNN 算法的优越性, 在相同实验条件下, 选取了传统的 Adam-CNN-ECA, 传统的 Adam-CNN 以及应用较为普遍的 ResNet18 网络模型作为对照, 训练参数设置同上, 实验结果如表 3 所示。

Table 3. Performance comparison of different models
表 3. 不同模型性能比较

Model 算法	Train Acc (%)	ValLoss (%)	Train Time (s)
Adam-CNN-ECA	91.88	2.37	62
Adam-CNN	89.96	3.03	87
ResNet18	92.39	3.36	38
Adam-S-改进 ECA-CNN	94.17	1.69	42

由表 3 可得, Adam-S-改进 ECA 卷积网络的训练准确率比传统 Adam-CNN 提升了接近 4.2%, 对于表面腐蚀缺陷分类准确度最高达到了 96.19%, 其训练速度有了大幅提升, 相同的实验条件下, 与 ResNet18 相比, 虽然训练时间接近, 但该算法有着较高的训练精度。综合评估, 本研究提出的 Adam-S-改进 ECA-CNN 模型算法在识别与分类油气管道缺陷图像数据集上具有更优异的性能。

5. 结论

1) 本文通过概述 Keras 软件深度学习框架, 包括从原始数据采集到神经网络结构搭建, 再通过多次迭代得到网络模型的实际预测率, 完成了深度学习在管道缺陷的应用, 为现有铺设管道以及在制管道的现代化检测提供了一定的应用价值。

2) 实验过程中通过控制时间变量, 量化对比了目前应用较为普遍的 ResNet18 以及改进前的 Adam-CNN 算法, 有效验证了 Adam-S-改进 ECA-CNN 算法的优越性能。

3) 通过对比实验两个关键参数, 比较了学习率以及 Dropout 机制对神经网络结构的影响, 同时应用较小的学习率细化了模型的计算细节, 后续通过微调神经网络结构, 提高了模型的泛化性, 后续实验将其导入移动设备或在线设备中。

参考文献

- [1] 崔国宁. 基于深度学习的管道缺陷漏磁数据识别方法研究[D]: [硕士学位论文]. 沈阳: 沈阳工业大学, 2022.
- [2] 王郑, 吴新团, 杨爱萍. 超声波加相控阵超声波技术在管道检测中的应用[J]. 石油工业技术监督, 2021, 37(12): 33-35+41.
- [3] Soldevila, A., Fernandez-Canti, R.M., Blesa, J., *et al.* (2017) Leak localization in Water Distribution Networks Using Bayesian Classifiers. *Journal of Process Control*, **55**, 1-9. <https://doi.org/10.1016/j.jprocont.2017.03.015>
- [4] 徐蒋明, 柯黎明. 拌摩擦焊缝缺陷超声检测信号特征分析与神经网络模式识别[J]. 核动力工程, 2020, 41(1): 163-166.
- [5] 彭斌, 白静, 李文静, 等. 面向图像分类的视觉 Transformer 研究进展[J]. 计算机科学与探索, 2023.
- [6] 韩飞. 基于 Adam-S 的 CNN 对变工况下滚动轴承的故障诊断方法研究[D]: [硕士学位论文]. 太原: 中北大学, 2023.
- [7] 谷玉海, 朱腾腾, 饶文军, 等. 基于 Adam-DBN 网络的行星齿轮箱故障诊断方法研究[J]. 组合机床与自动化加工技术, 2020, 554(4): 118-122.
- [8] Reddi, S.J., Kale, S. and Kumar, S. (2019) On the Convergence of Adam and Beyond. *Siam Review*, **60**, 223-311. <https://doi.org/10.1137/16M1080173>
- [9] Hu, J., Shen, L. and Albanie, S. (2020) Squeeze-and-Excitation Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **42**, 2011-2023. <https://doi.org/10.1109/TPAMI.2019.2913372>
- [10] 冯邦军. 基于 Keras 卷积神经网络的分拣蔬菜识别的设计[J]. 自动化应用, 2023, 64(10): 176-178+181.