

doi:10.3969/j.issn.1671-5152.2024.05.003

M1DCNN模型在燃气调压器故障诊断的应用

王 强¹, 李泽明¹, 张龙桦²

1.无锡华润燃气有限公司; 2.润智科技有限公司

摘 要: 燃气调压器的健康状况直接关系到燃气输配系统的稳定和安全运行, 针对调压器的故障识别, 需要大量的专家经验, 且给燃气企业带来较大的运维成本。本文提出一种基于多尺度一维卷积神经网络 (M1DCNN) 的燃气调压器故障诊断模型, 该模型在一维卷积神经网络的基础上, 构建多个不同尺寸卷积核和池化层的通道, 分别提取调压器出口压力数据特征信息并进行处理, 最后进行特征融合, 输出诊断故障类别。实验结果表明, M1DCNN模型能更全面的提取故障特征, 有效进行故障识别, 实现调压器智能故障诊断。

关键词: 燃气调压器; CNN; 多尺度特征提取; 故障诊断

1 概述

燃气调压器是城市燃气管网中的关键设备, 其安全平稳运行关系到居民用户的用气安全, 针对调压器的故障诊断方法进行研究, 对于提高设备的可靠性以及改善燃气公司经营效益具有重要意义。

针对燃气调压器的故障诊断, 多使用一维出口压力信号进行分析。故障诊断方法多采用数据分解和机器学习的方法, 如小波、EMD和SVM等^[1-2]。这类方法往往需要人工提取故障特征并单独设计分类器, 需要具备一定的专家经验和信号处理知识进行故障诊断。卷积神经网络 (convolutional neural networks, CNN) 具备强大的特征提取能力, 能够自动地学习得到样本空间层次化的特征表示, 成为故障诊断领域的研究热点^[3]。文献^[4]利用时频特征提取方法将一维故障信号转换为时频图, 再用二维卷积神经网络进行深层次特征学习和故障分类, 实现轴承故障诊断。文献^[5]设计了不同结构的CNN网络, 通过提取轴承振动信号的频域、时域和时频域特征, 研究了不同CNN网络结构和不同特征提取方法对故障诊断的影响。二维卷积无法

直接对一维信号进行处理, 需要寻找合适的方法对一维信号进行特征转换, 难以进行自适应的特征提取。一些研究利用一维卷积神经网络 (1DCNN) 方法进行故障诊断^[6-7], 可以直接将一维信号作为输入。但1DCNN使用单个通道卷积核进行特征提取, 因此其特征提取能力有限。

本文对燃气调压器出口压力进行分析, 通过改进1DCNN网络, 构建多尺度一维卷积神经网络 (M1DCNN), 可以直接将调压器原始出口压力信号作为网络输入, 进行多个通道的故障特征提取, 再对特征提取结果进行融合和分类, 完成调压器故障诊断过程, 该过程无需依赖特定的专家经验和事先进行特征转换, 实现了调压器智能故障诊断。

2 M1DCNN模型的建立

2.1 1DCNN模型介绍

卷积神经网络 (CNN) 是深度学习的重要分支, 其核心组件主要有卷积层和池化层, 进行层次堆叠。1DCNN从单一方向遍历前一层输入进行卷积和池化运

算，卷积层运算过程如下：

$$z_j^{l+1} = f(\sum_i x_i^l * w_{ij}^l + b_j^l) \quad (1)$$

其中，*为卷积核运算； x_i^l 为第 l 层的第 i 个卷积核输出； w_{ij}^l 和 b_j^l 为第 l 层第 i 个卷积核的权重与偏置； z_j^{l+1} 为第 $l+1$ 层第 j 个卷积核的输出； $f(\cdot)$ 为激活函数Sigmoid、ReLU等。

池化层位于卷积层之后，通过对卷积层输出的下采样减小特征尺寸，池化运算如下：

$$x_j^{l+1} = \text{down}(x_j^l) \quad (2)$$

其中， $\text{down}(x_j^l)$ 为池化函数，如最大池化、均值池化等； x_j^l 和 x_j^{l+1} 为池化层输入和输出。

对于分类任务，在卷积和池化层后通常通过单独设计的分类器输出分类结果，表示为各类别的概率，使用Softmax函数计算，如式(3)：

$$P(z_k) = \frac{\exp(z_k)}{\sum_i^n \exp(z_i)} \quad (3)$$

其中， z_i 为第 i 个神经元的输出值； n 为神经元的个数，即类别个数； $P(z_k)$ 为分类结果为第 k 个类别的概率值。

图1是执行分类任务的1DCNN网络结构，包括数据输入层、特征提取层和分类器3个部分。其中输入数据可以为原始一维信号，特征提取层是若干卷积和池化层的堆叠，分类器由全连接层实现，输出分类结果。由于调压器故障诊断输入为一维时域出口压力信号，对于二维卷积网络，需要对一维时域信号用

频变换等方法进行信号转换，才可进行故障识别。1DCNN可直接对一维时域信号进行处理，随网络加深逐层提取信号特征，但无法在同一时间提取多空间特征，限制了其特征提取能力。

2.2 M1DCNN模型结构

在调压器的故障诊断中，不同类型的故障特征在信号中所占比例、稀疏程度等不尽相同，因此单一尺度卷积核通道难以提取到完整的故障特征。本文提出使用多通道卷积核改进1DCNN网络，构建多尺度一维卷积神经网络(M1DCNN)，并将其应用于调压器的故障诊断。M1DCNN在1DCNN网络基础上，增加多个特征提取层通道，每个通道使用不同尺寸的卷积核单独进行特征提取，使得网络变的更宽。该网络结构可在同一空间提取多种特征，使得特征提取更加细腻和全面。

图2是本文所使用的包含3个特征提取通道的M1DCNN网络结构，可分为4个部分：数据输入层、多尺度特征提取层、特征融合层和分类器。对调压器的出口压力数据按日期截取并打乱作为网络输入，再通过3个通道并行特征提取。每个通道分别分配不同尺寸的卷积核，通道1的卷积核尺寸最大，用于提取调压器出口压力全局特征；通道2和通道3的卷积核尺寸依次减小，用于提取局部特征。通道中使用ReLU函数作为激活函数，其表达式为：

$$\text{Relu}(x) = \begin{cases} x(x > 0) \\ 0(x \leq 0) \end{cases} \quad (4)$$

特征融合层对各通道所提取的特征 X_1 、 X_2 和 X_3 使

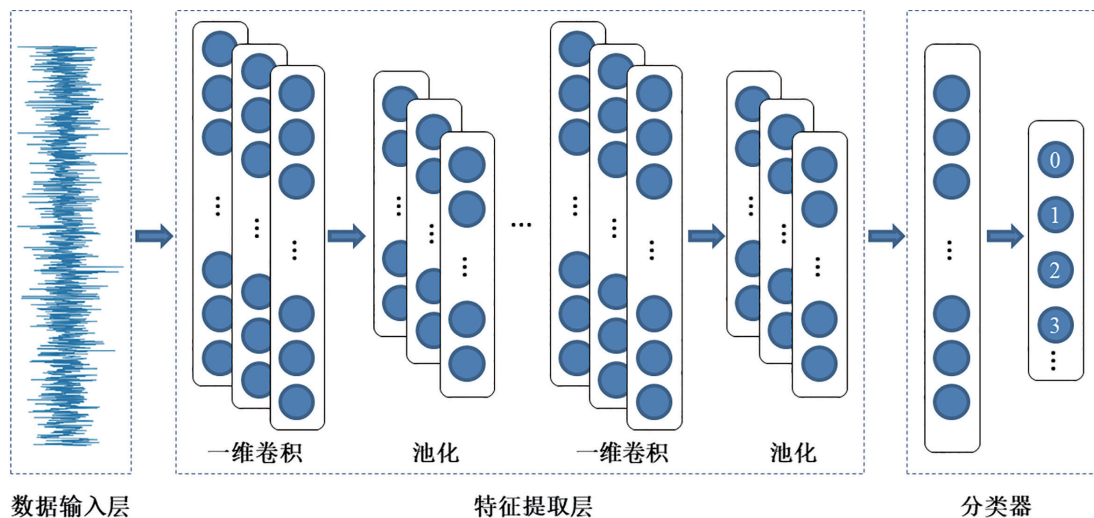


图1 1DCNN网络结构

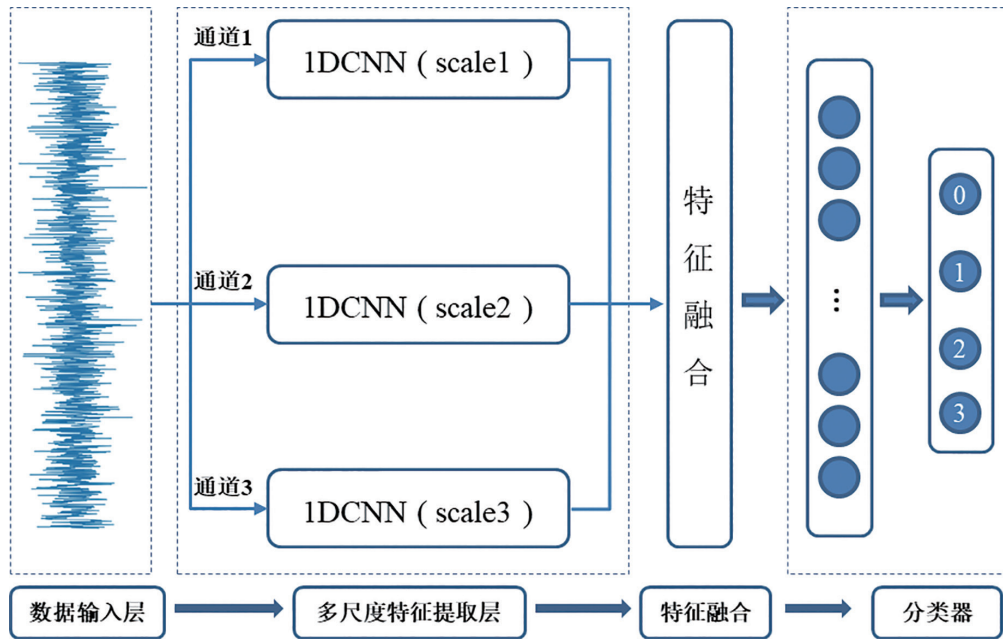


图2 M1DCNN网络结构

用张量拼接的方式进行堆叠，得到融合后的特征 X ，如式（5）。最后输入全连接层，经Softmax函数进行故障分类。

$$X = \text{concat}(X_1, X_2, X_3) \quad (5)$$

本文所构建的M1DCNN网络通过多个不同尺寸的卷积核通道，较全面的对输入信号进行特征提取，网络的学习和推理能力更强，该网络结构常用于故障诊断领域^[8-9]。

3 模型优化和故障诊断

3.1 数据集描述

本文数据集来源于无锡市某燃气公司SCADA系统中采集的236台在线调压器运行数据（下文同）。从2021年3月1日至2023年6月30日的历史数据中，选取内漏、喘振、关闭压力过高和正常状态共4种典型工况的案例进行分析，每种故障类别进行独热编码。研究各调压器每个自然日的出口压力数据，每1min采集一次数据，1440个/d数据作为一个样本。数据集统计见表1。

3.2 模型参数设置

本文所构建的M1DCNN网络通过3个通道的卷积核提取调压器出口压力特征，卷积核尺寸是模型中的

表1 数据集统计

运行状态	独热编码向量	样本数量（例）
正常状态	(1, 0, 0, 0)	500
内漏	(0, 1, 0, 0)	471
喘振	(0, 0, 1, 0)	432
关闭压力过高	(0, 0, 0, 1)	517

关键参数，体现出特征提取的细腻程度，会影响故障识别的准确率。通过多次实验得到的M1DCNN网络参数如表2所示，各通道卷积核尺寸依次减小，各通道包含2层卷积层逐层提取；通道1各层为256和128的大卷积核，卷积核数量分别为8和16，用于提取全局特征；通道2和通道3各层分配较小尺寸卷积核，用于提取细节特征；池化层均选择MaxPooling，池化参数为2，激活函数为Relu，防止过拟合。全连接层作为分类器使用，其中输出层使用Softmax激活函数输出故障类型。

3.3 模型训练和故障诊断流程

使用Pytorch深度学习框架搭建和训练模型，其网络训练和故障诊断流程如图3所示，主要步骤包括：

（1）数据预处理和标准化，对数据集中的异常值和缺失值进行预处理，并对数据进行Z-Score标准

表2 M1DCNN网络结构参数

结构	通道1	通道2	通道3	激活函数
卷积层-1	256, 8, 2	64, 8, 2	32, 8, 2	Relu
卷积层-2	128, 16, 2	32, 16, 2	16, 16, 2	Relu
全连接层	140, 激活函数为Relu			
Dropout层	dropout=0.4			
输出层	4, 激活函数为Softmax			

化处理;

- (2) 训练集和测试集划分, 将样本集随机打乱, 并按8:2比例划分为训练集和测试集;
- (3) 构建M1DCNN网络, 对网络参数进行初始化;
- (4) 模型训练, 在训练集数据上对网络模型训练, 使用反向传播算法优化网络参数;
- (5) 模型评估, 使用测试集进行模型评估, 输出故障分类结果。

理的对于4种调压器运行状态的检修数据。图4是不同运行状态下调压器出口压力随时间(分钟)的变化情况, 图4(a)表示该调压器在该日内用气低谷时段阀门关闭不严, 导致内漏故障, 压力持续升高; 图4(b)表示该调压器该日出口压力出现剧烈波动, 表现为喘振故障; 图4(c)表示该调压器在用气低谷时可正常关闭, 但由于配件老化等原因导致关闭压力过高; 图4(d)表示调压器正常运行无明显异常。

通过将选取的不同运行状态的调压器出口压力数据输入训练完成的M1DCNN模型, 识别故障类型并根据正确识别的数量计算准确率指标。表3为M1DCNN模型的故障诊断结果, 调压器不同运行状态的样本数量各不相同, 正常状态的数量最多, 这是大部分调压器的运行状态。其中内漏、喘振和关闭压力过高故障的调压器样本数量分别为28例、23例和21例, M1DCNN模型对这3种故障的样本均正确识别出故障类型, 识别准确率为100%; 对于100个运行正常的样本, 识别准确率也达到了94%, 结果表明M1DCNN模型的故障诊断准确率很高, 表现出了该模型的可靠性。同时, 该模型在故障诊断的过程中, 可以直接对出口压力数据进行处理, 将调压器出口压力的特征提取与故障诊断融为一体, 克服了传统故障诊断方法大量依赖专家经验的不足, 是一种智能故障诊断模型。

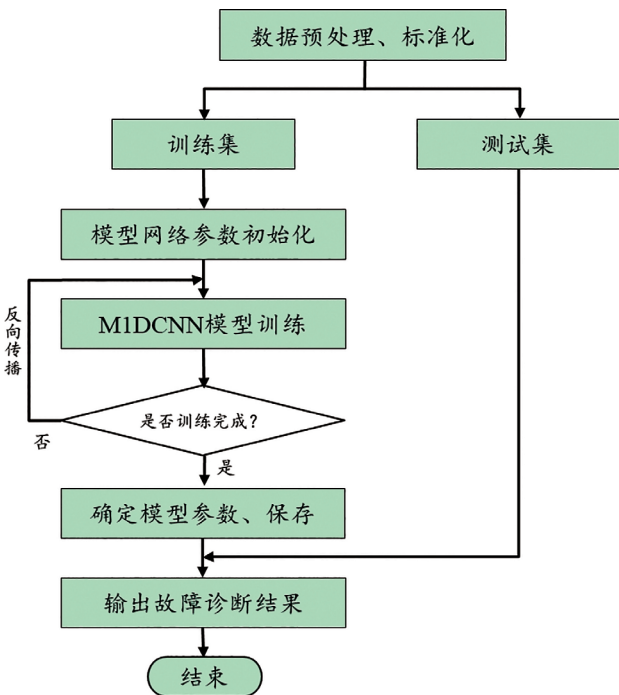


图3 M1DCNN模型训练和故障诊断流程

4 工程应用

4.1 实例验证模型的准确性

选取该燃气公司2023年10月至11月期间调压班整

4.2 模型输出结果分析

为进一步验证本文所提的M1DCNN模型性能, 每种运行状态选取2个样本对模型输出结果进行分析。每种运行状态的独热编码向量如表1中设定, 对应M1DCNN模型Softmax输出层的4个神经元的输出值。由表4可知, 将选取的8个测试样本输入模型, 获取的输出向量与对应故障类型的独热编码向量基本一致, 模型可以准确识别出相应故障类型, 表现出了较好的性能。




图4 调压器典型运行工况分析

表3 M1DCNN模型故障诊断结果

运行状态	样本总数 (例)	模型正确识别数量 (例)	准确率 (%)
正常状态	100	94	94
内漏	28	28	100
喘振	23	23	100
关闭压力过高	21	21	100

表4 M1DCNN模型输出结果

样本编号	运行状态	模型输出向量	独热编码向量
1	正常状态	(0.917 4, 0.023 5, 0.038 7, 0.020 4)	(1, 0, 0, 0)
2	正常状态	(0.735 8, 0.015 2, 0.001 5, 0.247 5)	(1, 0, 0, 0)
3	内漏	(0.006 9, 0.900 7, 0.035 8, 0.056 6)	(0, 1, 0, 0)
4	内漏	(0.134 2, 0.763 3, 0.032 7, 0.069 8)	(0, 1, 0, 0)
5	喘振	(0.298 8, 0.162 2, 0.536 5, 0.002 5)	(0, 0, 1, 0)
6	喘振	(0.125 4, 0.051 5, 0.659 0, 0.164 1)	(0, 0, 1, 0)
7	关闭压力过高	(0.155 2, 0.236 4, 0.031 9, 0.576 5)	(0, 0, 0, 1)
8	关闭压力过高	(0.094 5, 0.226 4, 0.036 1, 0.643 0)	(0, 0, 0, 1)

5 结论

(1) 本文主要对调压器出口压力信号进行分析, 提出一种基于M1DCNN的模型, 将该模型应用于燃气调压器的故障诊断。经过验证, 该模型表现出较高的故障识别准确率, 验证了模型的有效性。

(2) 基于M1DCNN的调压器故障诊断模型能够智能的进行故障特征提取和分类, 减弱了对大量的专家经验的依赖, 在节省运维成本的同时也提高了故障诊断的效率。

参考文献

- [1] 姜赛赛. 中低压燃气调压器故障智能诊断模型与模拟研究[D]. 哈尔滨工业大学, 2020.
- [2] 孙明远, 郝学军. 小波包和Apriori算法燃气调压器故障诊断与预警[J]. 煤气与热力, 2021, 41(08): 1-6+44-45.
- [3] Waziralilah N. Fathiah, Abu Aminudin, Lim M.H, Quen Lee Kee, Elfakharany Ahmed. A Review on Convolutional

Neural Network in Bearing Fault Diagnosis[J]. MATEC Web of Conferences, 2019, 255.

- [4] 李鲜画. 时频图结合深度神经网络的轴承智能故障诊断研究[D]. 燕山大学, 2020.
- [5] Luyang Jing, Ming Zhao, Pin Li, Xiaoqiang Xu. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox[J]. Measurement, 2017, 111.
- [6] 陈向民, 韩梦茹, 舒文伊, 等. 基于VMD与多尺度一维卷积神经网络的故障诊断方法[J]. 现代电子技术, 2023, 46(09): 103-109.
- [7] 王琦, 邓林峰, 赵荣珍. 基于一维CNN迁移学习的滚动轴承故障诊断[J]. 振动. 测试与诊断, 2023, 43(01): 24-30+195.
- [8] 卞景艺, 刘秀丽, 徐小力, 等. 基于多尺度深度卷积神经网络的故障诊断方法[J]. 振动与冲击, 2021, 40(18): 204-211.
- [9] 古天龙, 孙镇海, 宾辰忠, 等. 基于多尺度卷积神经网络的滚动轴承智能诊断算法[J]. 机械设计与制造, 2022(05): 20-23.

工程信息

哈尔滨市2024年改造燃气老旧管线500km

2024年3月22日, 从哈尔滨市住建局获悉, 为解决哈尔滨市燃气地下管线建设标准低、设施老化等问题, 2024年哈尔滨市将继续推进老化燃气管网及户内安全设施改造。按照计划, 2024年将改造老旧管线500km, 更新安装“四件套”31.5万户。

据悉, 哈尔滨市是全国较早使用管道燃气的特大城市, 城市燃气管道总长1.98万km, 其中市政管道0.45万km、庭院管道0.31万km、室内立管1.22万km。2022年全市启动燃气老化管道更新改造工作, 按照国家确定的“2025年底前, 基本完成城市燃气管道等老化更新改造任务”目标, 对建设年限超过20年的3168km燃气管线(含2365km户内管线)进行集中更新改造, 至2023年年底已完成燃

气老化管网改造1524km, 实现了全市燃气老化管网改造整体任务, 时间过半、完成过半。

据哈尔滨市住建局介绍, 为加快推进燃气设施改造和提档升级, 该市将2024年作为燃气老旧设施改造的攻坚年, 年度计划改造老旧管线500km; 为31.5万户居民家庭更新安装带切断阀的报警器、自闭阀、燃气表、波纹软管的燃气“四件套”。同时, 对已经运行30年、隐患较多的哈依管道(全长246km)进行改造, 改造腐蚀管线约7km, 更新修复防腐层破损627处, 漂管、露管及水工保护更新改造30处, 改造场站7座。目前, 该项目已启动临时用地征收, 计划2025年5月30日前完成。

(本刊通讯员供稿)