



# 基于自适应卷积核的改进 CNN 数值型数据分类算法

程 诚, 任 佳

(浙江理工大学机械与自动控制学院, 杭州 310018)

**摘 要:** 针对卷积神经网络(Convolutional neural network, CNN)模型在对工业数值型数据分类方面存在特征使用不充分、模型分类性能不佳等问题, 提出了一种基于自适应卷积核的改进 CNN(Improved CNN based on adaptive convolution kernel, ACK-ICNN)算法。该算法为了增加特征的重复使用率, 构建了一种多尺度卷积核的模型结构, 通过融合处理卷积核提取的不同特征来实现, 增强了模型的适应能力; 为了进一步提升该算法的性能, 利用网格搜索算法自适应选取 CNN 中最优的卷积核大小, 使得模型能够提取出最优的特征。采用 TE 过程的故障数据对其进行测试, 并与支持向量机、极限学习机、最近邻等典型的数据驱动方法进行对比, 测试结果表明, 该算法能有效提升各类故障的分类精度。

**关键词:** 卷积神经网络; 数值型数据; 自适应卷积核; 网格搜索

**中图分类号:** TP181

**文献标志码:** A

**文章编号:** 1673-3851 (2019) 09-0657-08

## Improved CNN classification algorithm based on adaptive convolution kernel for numerical data

CHENG Cheng, REN Jia

(Faculty of Mechanical Engineering & Automation, Zhejiang Sci-Tech University, Hangzhou 310018, China)

**Abstract:** To tackle the problems of insufficient use of features and poor performance of model classification of convolutional neural network (CNN) model in the classification of industrial numerical data, an improved CNN based on adaptive convolution kernel (ACK-ICNN) algorithm is proposed. In the algorithm, a multi-scale convolution kernel model structure is constructed in order to increase the reuse rate of features, which is realized by fusion processing of different features extracted from convolution kernel to enhance the adaptability of the model. To further improve the performance of the algorithm, the grid search method is used to select the optimal convolution kernel size in CNN in adaptive way, so that the model can extract the optimal features. The fault data of the TE process is used to test the performance of the proposed algorithm, accompanied with comparison with typical data-driven methods such as support vector machine, extreme learning machine and nearest neighbor. The test results show that the proposed algorithm is helpful to largely improve the classification accuracy of various faults.

**Key words:** convolutional neural network (CNN); numerical data; adaptive convolution kernel; grid search

收稿日期: 2018-12-17 网络出版日期: 2019-02-28

基金项目: 国家自然科学基金项目(61203177); 浙江省自然科学基金项目(LY17F030024)

作者简介: 程 诚(1993-), 男, 安徽阜阳人, 硕士研究生, 主要从事软测量建模方面的研究。

通信作者: 任 佳, E-mail: jren@zstu.edu.cn

## 0 引言

卷积神经网络(Convolutional neural network, CNN)<sup>[1]</sup>作为一种特殊的神经网络,主要由卷积层和池化层组成。其中卷积层和池化层分别完成对数据特征的抽象提取和重构,以加强对不同类别的区分度,最终数据特征表示为平移、旋转和缩放多次的一系列抽象特征的组合。CNN的特殊结构使得其具有稀疏连接、权重共享和空间或时间下采样的特点,其中:稀疏连接建立了数据之间非完全连通的空间关系;权重共享减少了模型训练的参数;时间或空间下采样利用数据的局部特征减少了数据的维度。上述特点使得CNN模型适于处理高维度的图像数据。

为了提高基于CNN的模型对图像数据的分类性能,研究人员相继提出了 AlexNet<sup>[2]</sup>、GoogleNet<sup>[3]</sup>、ResNet<sup>[4]</sup>等模型。这些模型通过不断地增加网络的层数,使得提取的特征变得更加抽象,进而获得更好的性能。经过不断地改进,基于CNN的模型在图像数据分类领域成果显著,这促使更多专家学者希望将CNN能够广泛应用到工业过程故障诊断领域<sup>[5]</sup>。

已有研究<sup>[6-8]</sup>针对特定的故障场景给出了基于CNN的不同模型,取得了不错的效果。例如:林颖等<sup>[9]</sup>针对提高红外检测效率低的问题,提出了基于CNN的电流互感器红外故障图像诊断方法;Jeong等<sup>[10]</sup>针对轨道图像对旋转机械的故障模式进行分类,提出了一种基于CNN的自主轨道模式识别方法;Sun等<sup>[11]</sup>针对货运列车的故障问题,设计了一种基于CNN的铁路货车自动故障识别系统;杨理践等<sup>[12]</sup>针对管道内检测中焊缝法兰组件的识别精度不够的问题,提出了一种基于CNN的智能识别方法。然而上述基于CNN的模型主要针对图像数据,在实际的工业过程中,数据的来源往往是传感器所采集到的数值型数据。针对数值型数据,常用传统的数据驱动方法进行分析<sup>[13-15]</sup>,如极限学习机(Extreme learning machine, ELM)、支持向量机(Support vector machines, SVM)和多层前馈网络(Back propagation, BP)等方法。由于以上方法分析高维度以及数据量很大的数据时会比较困难且耗时,所以需要类似于CNN这种可以分析大数据的方法。例如魏东等<sup>[16]</sup>通过电流采样数据构成二维数据样本,在CNN输出层采用两个Softmax分类器,用同一网络分别解决了区内外故障问题;Yang

等<sup>[17]</sup>通过分析数值变量之间的时滞关系确定CNN输入的时间窗大小,预测了实际蒸馏塔的动态时间延迟序列。由于采集到的数值型数据包含大量噪声,变量之间存在复杂的非线性、耦合关系等问题,基于CNN的模型难以有效使用对数值型数据提取的片段特征,导致模型的拟合能力以及泛化能力不强,因此基于CNN直接对数值型数据进行建模的应用较少。

上述基于CNN直接对数值型数据构建的模型,其参数大部分为手动选取,存在特征提取是否合理、选取的特征能否令模型的性能最佳等问题。针对上述问题,本文提出了一种基于自适应卷积核的改进CNN(Improved CNN based on adaptive convolution kernel, ACK-ICNN)的数值型数据分类算法。该算法一方面为了提高数值型数据的特征重复使用率以加强模型的泛化和表达能力,通过改进CNN模型,将卷积核所提取的不同特征进行融合,融合后的特征再作为下一层的输入,使得特征之间起到互补的作用,得到更加具有代表性的分类决策函数,同时融合后的特征也将高维数据在空间上的关联关系转化为了可用的下一层输入的特征信息,使得模型能够得到数值型数据之间的更多信息;另一方面为了能够使得模型的性能最佳,针对卷积核的大小,采用网格搜索算法对卷积核大小进行自适应选取。该算法采用的卷积核所提取的特征使得模型能更好地表达出数值型数据之间的关系,提高了模型的分类准确率。

## 1 ACK-ICNN 分类算法

### 1.1 ACK-ICNN 模型结构

本文根据改进的CNN模型DenseNet<sup>[18]</sup>提出了ACK-ICNN模型。DenseNet的主要特点是:利用不同大小的卷积核进行特征提取,将提取的不同特征进行融合后再传至下一层进行处理。由于DenseNet综合利用了不同复杂度的特征,更容易得到一个光滑且具有更好泛化性能的决策函数,使得该模型更适合于处理数值型数据。本文设计的ACK-ICNN模型具体结构如图1所示,其中: $m$ 表示输入的数据个数, $n$ 表示输入数据的维度, $k_1$ 、 $k_2$ 表示卷积核的大小。

如图1所示,ACK-ICNN模型包含输入层、卷积层、融合层、池化层、Softmax层以及输出层。每层的作用及其相关参数具体介绍如下。

a)输入层。对于获得的一维数值型数据,直接

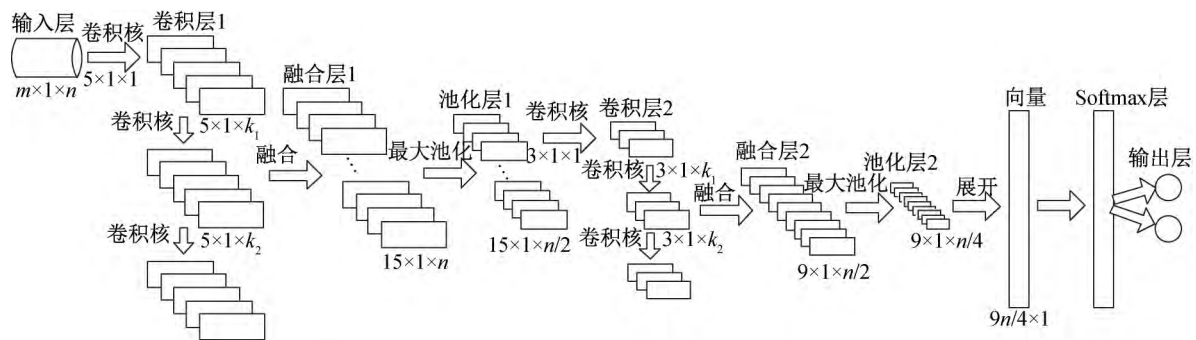


图1 ACK-ICNN 模型结构示意图

将其作为模型输入。例如  $m \times 1 \times n$  数据形式表示一次输入  $m$  个  $1 \times n$  的一维数值型数据至模型中进行训练。

b) 卷积层。卷积层通过卷积核在输入数据中顺次滑动, 执行卷积(加权)操作来完成特征的提取。例如, 输入  $I$  为  $1 \times 6$  的矩阵, 卷积核  $W$  为  $1 \times 2$  的

矩阵, 移动步长设置为 1, 卷积操作利用卷积核在输入数据上从左向右移动, 一次一步, 最终提取的特征序列  $F$  大小为  $1 \times 5$ 。卷积计算的具体实现过程如图 2 所示。其中:  $p_1, p_2, \dots, p_6$  表示输入数据  $I$  的元素,  $w_1, w_2$  表示卷积核  $W$  的元素,  $x_1, x_2, \dots, x_5$  表示经过卷积操作后得到的特征序列  $F$  的数值。




图2 卷积计算过程示意图

特征序列内数值的计算方法为:

$$x_1 = p_1 \times w_1 + p_2 \times w_2 \quad (1)$$

$$x_2 = p_2 \times w_1 + p_3 \times w_2 \quad (2)$$

$$x_3 = p_3 \times w_1 + p_4 \times w_2 \quad (3)$$

本文卷积层的结构及参数设置为: 卷积层 1 中使用了 3 种不同大小 ( $1 \times 1, 1 \times k_1, 1 \times k_2$ ) 的卷积核, 其个数均为 5,  $k_1, k_2$  的具体数值由 1.2 节中介绍的网格搜索算法自适应选取。为了使得经过不同卷积核提取出的特征序列的维度与输入数据的维度一致, 本文在输入数据尾端采用填充 0 的处理方式。例如, 如图 2 所示, 在输入  $I$  后进行补 0 操作, 使得输入维度扩展为  $1 \times 7$ , 则经过同样的操作后, 得到的特征序列大小为  $1 \times 6$ 。此外, 卷积操作后得到的特征序列  $F$  加上偏置  $b$ , 再通过激活函数进行映射, 作为该层的输出, 本文使用 Relu 函数作为激活函数。Relu 函数的计算公式为:

$$\text{Relu}(F) = \max(0, F + b) \quad (4)$$

c) 融合层。融合层的目的是将提取出的特征序列进行融合, 形成新的组合特征序列输入下一层。卷积层 1 将输入依次通过 3 种不同大小的卷积核进行特征提取可分别得到 5 个大小一致的不同特征序

列, 将这些特征序列合并到同一层形成融合层 1, 融合后该层有 15 个特征序列。卷积层 2 中也使用了同样的 3 种大小 ( $1 \times 1, 1 \times k_1, 1 \times k_2$ ) 的卷积核, 其个数均为 3, 因此融合后可得到 9 个特征序列。

d) 池化层。池化层的作用是减少参数并避免过拟合的发生, 其具体操作为获取特征映射区域中的最大值或平均值。

e) Softmax 层。在进行 Softmax 层分类之前, 需要将池化层 2 的特征序列依次进行转置并合并成一维列向量形式。Softmax 层将这些向量利用全连接神经网络进行映射。最后将多个神经元的输出  $e_i$ , 通过 Softmax 函数映射到  $(0, 1)$  区间内, 作为最终的输出  $a_i$ 。Softmax 函数计算公式为:

$$a_i = e_i / \sum_{i=1}^2 e_i \quad (5)$$

f) 输出层。输出层将 Softmax 层的最终输出  $a_i$  作为模型的预测值, 同时利用损失函数  $L$  用来衡量模型预测值和真实值  $y_i$  之间的偏差。本文采用交叉熵函数作为损失函数, 计算公式为:

$$L = - \sum_{i=1}^2 y_i \ln a_i \quad (6)$$

利用损失函数,对 CNN 中卷积核中的参数  $W$  和偏置  $b$  采用自适应动量项(Adaptive moments, Adam)<sup>[19]</sup>方法进行更新。

## 1.2 基于 GS 的自适应卷积核实现

在图 1 所示的 ACK-ICNN 结构中,卷积核的大小影响特征提取的结果,最终影响模型分类准确率,本文提出了一种自适应的卷积核大小优化方法,即网格搜索(Grid search, GS)算法,对卷积核大小进行优化。网格搜索算法是一种解决有约束非线性极值问题的原始的数字规划法,也称为穷举法<sup>[20]</sup>。该方法通过在参数列表中进行网格搜索,能够很好地避免参数之间可能出现的耦合关系而引起的多解性问题。每种组合参数利用训练集的数据进行对应的训练,通过  $t$  折交叉验证的方法,重复训练  $t$  次,将  $t$  次交叉验证的平均结果作为最终结果,进而选取平均结果最优的一组参数组合。 $t$  折交叉验证的方法能够有效避免模型出现过拟合或者欠拟合的现象,因此文中使用 5 折交叉验证方法。

通过以上介绍,基于 GS 优化搜索的 ACK-ICNN 算法流程如图 3 所示。其中模型搭建环境基于 Tensorflow 和 Keras 框架。 $k_1, k_2$  搜索区间设置为  $[1, 5]$ ,卷积神经网络初始化参数  $W \in U[-\sqrt{6}/\sqrt{k+1}, \sqrt{6}/\sqrt{k+1}]$ ,  $b=0$ ,其中  $k=k_1$  或  $k_2$ 。迭代次数  $E=30$ ,池化层特征映射区域设置为  $1 \times 2$ ,池化操作使用最大池化法,移动步长设置为 2。

## 2 算法测试

### 2.1 TE 过程简介

田纳西伊士曼(TE)是基于伊士曼化学公司研究的实际工业过程的基准过程控制案例。TE 过程主要由 5 个操作单元组成:反应器、冷凝器、汽/液分离器、循环压缩机和汽提塔。过程中共包含 8 种成分:A、B、C、D、E、F、G 和 H。图 4 给出了 TE 过程的工艺流程示意图<sup>[21]</sup>,更详细的信息可参阅文献<sup>[22]</sup>。

TE 过程包含 22 种工况  $\{d_{00}, d_{01}, \dots, d_{21}\}$  以及 52 个变量,每种工况的训练数据和测试数据的数值均通过对变量进行采样获得。22 种工况中  $d_{00}$  为正常工况,该工况下采集了 500 组训练数据  $d_{00\text{train}}$  和 960 组测试数据  $d_{00\text{test}}$ 。其余 21 种工况均为故障工况,每种故障工况中采集了 480 组训练集  $\{d_{01\text{train}}, d_{02\text{train}}, \dots, d_{21\text{train}}\}$  和 960 组测试集  $\{d_{01\text{test}}, d_{02\text{test}}, \dots, d_{21\text{test}}\}$ 。在每种故障工况的测试集  $\{d_{01\text{test}}, d_{02\text{test}}, \dots,$

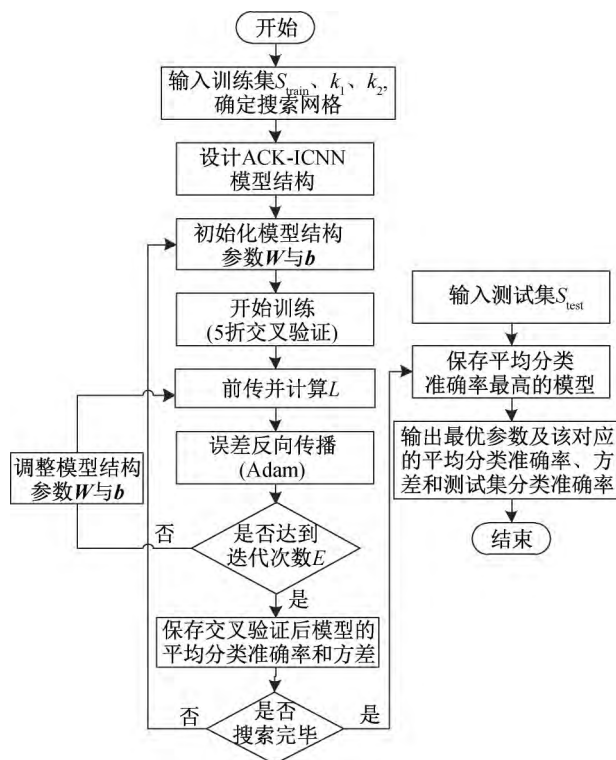


图 3 ACK-ICNN 算法流程

$d_{21\text{test}}\}$  中,前 160 组为正常数据,其后 800 组为故障数据。以  $d_{01\text{train}}$  和  $d_{01\text{test}}$  为例,数据组成如图 5 所示。

由于 TE 过程为评估过程控制和监控方法提供了一个真实的工业过程模型,所以很多专家学者以此为模型进行故障的分类识别。目前针对 TE 故障识别的研究以传统数据驱动及其改进方法为主。例如,直接将 ELM、SVM、最近邻(One nearest neighbor, 1-NN)等<sup>[23]</sup>方法用于 TE 过程中的分类任务,或者先使用主成分分析(Principal component analysis, PCA)降低数据特征维度,再采用 SVM 进行分类的方法<sup>[24]</sup>。或者先采用级联特征选择方法对数据进行预处理,最后采用 ELM 进行分类的方法<sup>[25]</sup>。还有基于深度学习的方法 Deep belief net (DBN)<sup>[26]</sup>,通过 DBN 网络进行故障特征的提取对 TE 过程进行空间特征提取进而分类。以上方法对部分故障的预测准确率仍然较低,平均分类效果仍然不佳<sup>[27-28]</sup>。同时,TE 过程作为现实的案例,产生的均为数值型数据,所以本文采用 TE 数值数据作为算法的测试案例,并将本文算法与传统的数据驱动方法的预测结果进行了对比分析。

### 2.2 结果对比及分析

在对每种工况模型进行训练时,模型的训练集由 TE 过程正常工况的训练集  $d_{00}$  分别与该工况故障的训练集进行了组合,形成新的训练集  $S_{\text{train}}$ ,组

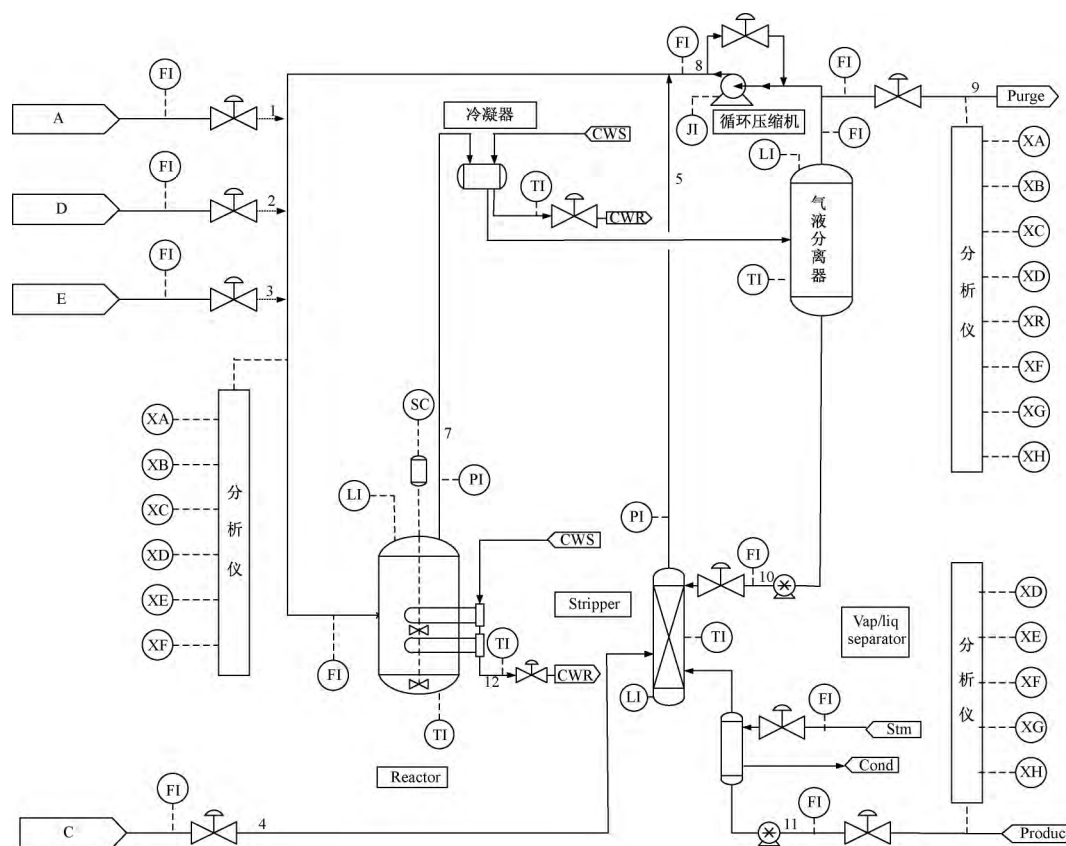



图 4 TE 过程工艺流程示意图

图 5  $d_{01\text{train}}$  和  $d_{01\text{test}}$  数据组成

合方式如图 6 所示。训练时,取 10 组数据作为一组输入,即图 1 输入层中  $m=10$ 。模型的测试集  $S_{\text{test}}$  为该工况的测试集,即  $S_{\text{test}} \in \{d_{01\text{test}}, d_{02\text{test}}, \dots, d_{21\text{test}}\}$ 。




图 6 TE 训练集组成

$S_{\text{train}}$  与  $S_{\text{test}}$  产生之后,将  $S_{\text{train}}$  输入 ACK-ICNN 模型中对卷积核大小  $k_1$  和  $k_2$  进行寻优,以故障 1 为例,通过网格搜索算法寻找最优参数过程结果如表 1 所示,表中准确率为 5 次交叉验证后模型的平均分类准确率,方差为 5 次交叉验证分类准确率的

方差。

由表 1 可以看出,对于故障 1,最优的卷积核大小组合为  $k_1=4$ 、 $k_2=1$ 。这表明不同组合下的卷积核大小所提取出的不同特征对模型的分类准确率存在影响。因此针对 21 种故障,通过 GS 寻找最优的卷积核大小组合,如表 2 所示。由表 2 可以发现,对于不同的故障,变量之间的相关关系存在不同,导致提取出的特征信息大有不同,使得改进的 CNN 模型的平均分类准确率也会发生较大差异。因此针对不同故障数据,通过寻优为每个分类模型选取合适的卷积核大小是必要的。

同时,寻找到最优参数后,模型的性能可以通过训练集和交叉验证集的分类准确率曲线来评价。因此,以故障 1 和故障 2 寻找到最优参数时 ACK-ICNN 模型的训练集和交叉验证集的分类准确率曲线为例,如图 7 所示。由图 7 可知,训练集和交叉验

表 1 故障 1 寻优过程中的分类准确率及其方差

$k_1$	$k_2$	准确率	方差
1	1	0.991837	0.004082
1	2	0.993878	0.005950
1	3	0.991837	0.005203
1	4	0.993878	0.003818
1	5	0.993878	0.003818
2	1	0.992857	0.005203
2	2	0.994898	0.004563
2	3	0.993878	0.002041
2	4	0.994898	0.004563
2	5	0.994898	0.003227
3	1	0.991837	0.005203
3	2	0.993878	0.002041
3	3	0.991837	0.006122
3	4	0.993878	0.005950
3	5	0.994898	0.003227
4	1	0.995918	0.003818
4	2	0.992857	0.004082
4	3	0.993878	0.003818
4	4	0.993878	0.005950
4	5	0.990816	0.011363
5	1	0.991837	0.006122
5	2	0.991837	0.005203
5	3	0.994898	0.004563
5	4	0.990816	0.006769
5	5	0.993878	0.005950

表 2 网络结构最优参数  $k_1$  和  $k_2$

故障类型	$k_1$	$k_2$
d <sub>01</sub>	4	1
d <sub>02</sub>	5	1
d <sub>03</sub>	4	5
d <sub>04</sub>	1	5
d <sub>05</sub>	4	4
d <sub>06</sub>	1	2
d <sub>07</sub>	1	2
d <sub>08</sub>	5	4
d <sub>09</sub>	5	1
d <sub>10</sub>	2	4
d <sub>11</sub>	3	2
d <sub>12</sub>	1	5
d <sub>13</sub>	4	3
d <sub>14</sub>	4	3
d <sub>15</sub>	4	5
d <sub>16</sub>	4	4
d <sub>17</sub>	2	2
d <sub>18</sub>	3	5
d <sub>19</sub>	5	5
d <sub>20</sub>	3	4
d <sub>21</sub>	5	4





图 7 d<sub>01</sub>、d<sub>02</sub> 训练集和交叉验证集分类准确率

证集两条曲线基本重合,这说明模型的拟合能力较好,未出现过拟合或者欠拟合的现象。此外,训练集和交叉验证集的分类准确率都较高,说明模型能够取得较好的分类效果。

采用最优参数组合下训练好的 ACK-ICNN 模型对各个故障进行测试,分别将不同故障工况测试集输入模型中得到测试集的分类准确率,并分别与传统的数据驱动方法如 1-NN、SVM、ELM<sup>[23]</sup> 的预测结果进行对比。4 种方法在测试集的分类准确率如表 3 所示。

由表 3 可知,在平均分类准确率方面,本文提出的算法比 SVM 提高了 6.73%,比 1-NN 和 ELM 分别提高了 24.53%和 20.78%。4 种方法中,在对 21 种故障类型的识别中,本文的 ACK-ICNN 算法取得了 14 个最优值,明显高于其它 3 种方法。从单个故障识别能力来看,故障 3、8、9、10、11、13、15、16、21 这 9 个故障的识别效果都得到了明显的提高。以上实验结果进一步表明:ACK-ICNN 模型通过提取数值型数据的不同复杂度特征,从空间关系或者关联程度方面对特征进行了融合,提高了特征的可利用

表 3 4 种方法在 TE 过程测试集上的分类准确率

故障类型	ACK-ICNN	1-NN	SVM	ELM
d <sub>01</sub>	0.9958	0.8788	0.9793	1.0000
d <sub>02</sub>	0.9949	0.9763	0.9750	0.9997
d <sub>03</sub>	0.6673	0.4450	0.5929	0.4953
d <sub>04</sub>	1.0000	0.6963	1.0000	0.9895
d <sub>05</sub>	0.9816	0.5988	1.0000	0.9834
d <sub>06</sub>	1.0000	0.9875	1.0000	1.0000
d <sub>07</sub>	1.0000	0.8013	1.0000	0.9953
d <sub>08</sub>	0.9714	0.7788	0.8771	0.6458
d <sub>09</sub>	0.7337	0.4450	0.5158	0.4288
d <sub>10</sub>	0.8449	0.5175	0.6870	0.4767
d <sub>11</sub>	0.8806	0.3938	0.6828	0.4491
d <sub>12</sub>	0.9745	0.7463	0.9658	0.8289
d <sub>13</sub>	0.9796	0.6475	0.6575	0.3923
d <sub>14</sub>	0.9724	0.4838	0.9595	0.4716
d <sub>15</sub>	0.7112	0.4700	0.5241	0.4529
d <sub>16</sub>	0.8020	0.4075	0.7059	0.5131
d <sub>17</sub>	0.8704	0.5475	0.9468	0.7570
d <sub>18</sub>	0.9102	0.9050	0.9154	0.8844
d <sub>19</sub>	0.7357	0.6450	0.8283	0.4905
d <sub>20</sub>	0.8837	0.5438	0.8841	0.6815
d <sub>21</sub>	0.6157	0.4600	0.4158	0.2256
平均值	0.8822	0.6369	0.8149	0.6744
最优个数	14	0	8	3

率,使得在模型结构上拟合出更优的函数成为可能。同时,通过网格搜索算法自动地选取卷积核大小,可以得到适合模型的最佳参数,进一步提升模型分类准确率。由于 TE 过程中的 21 种故障数据,每种故障数据变量的非线性关系、变量之间的关联程度都不相同,因此采用自适应卷积核 ACK-ICNN 算法,最大程度地利用了数值型数据所蕴含的信息,能够取得比传统数据驱动方法更高的分类准确率。

### 3 结 论

本文通过构建特征复用的改进型 CNN 网络结构,对卷积核的大小采用网格搜索算法进行自适应优化,提出了一种直接处理数值型数据的分类算法 ACK-ICNN。该算法利用不同大小的卷积核组合,提取出适合模型的特征;同时利用不同复杂度的特征进行融合,加强模型的泛化和表达能力。对 TE 过程数据的测试结果表明,ACK-ICNN 的故障识别能力优于传统的数据驱动方法,是可以作为直接处理数值型数据的有效方法。

### 参考文献:

[1] Lecun Y L, Bottou L, Bengio Y, et al. Gradient-based

learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.

- [2] Krizhevsky A, Sutskever I, Hinton G. Image Net classification with deep convolutional neural networks [C]//In Advances in Neural Information Processing Systems 25. Lake Tahoe: Curran Associates Inc, 2012: 1106-1114.
- [3] Szeged C, Liu W, Jia Y, et al. Going deeper with convolutions[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston. IEEE, 2015: 1-9.
- [4] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, IEEE, 2016: 770-778.
- [5] 任浩, 屈剑锋, 柴毅, 等. 深度学习在故障诊断领域中的研究现状与挑战[J]. 控制与决策, 2017, 32(8): 1345-1358.
- [6] 刘涵, 郭润元. 基于 X 射线图像和卷积神经网络的石油钢管焊缝缺陷检测与识别[J]. 仪器仪表学报, 2018, 39(4): 247-256.
- [7] Yan H, Baoping T, Lei D. Multi-level wavelet packet fusion in dynamic ensemble convolutional neural network for fault diagnosis[J]. Measurement, 2018, 127: 246-255.
- [8] Jia F, Lei Y, Lu N, et al. Deep normalized convolutional neural network for imbalanced fault classification of machinery and its understanding via visualization [J]. Mechanical Systems & Signal Processing, 2018, 110: 349-367.
- [9] 林颖, 郭志红, 陈玉峰. 基于卷积递归网络的电流互感器红外故障图像诊断[J]. 电力系统保护与控制, 2015, 43(16): 87-94.
- [10] Jeong H, Park S, Woo S, et al. Rotating machinery diagnostics using deep learning on orbit plot images[J]. Procedia Manufacturing, 2016, 5: 1107-1118.
- [11] Sun J, Xiao Z, Xie Y. Automatic multi-fault recognition in TFDS based on convolutional neural network[J]. Neurocomputing, 2017, 222: 27-136.
- [12] 杨理践, 曹辉. 基于深度学习的管道焊缝法兰组件识别方法[J]. 仪器仪表学报, 2018, 39(02): 193-202.
- [13] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1): 1-9.
- [14] 马仕强, 任佳, 赵梦恩. 基于移动窗口和粒子群寻优的集成偏最小二乘改进算法[J]. 浙江理工大学学报, 2018, 39(4): 453-460.
- [15] 文成林, 吕菲亚, 包哲静, 等. 基于数据驱动的微小故障诊断方法综述[J]. 自动化学报, 2016, 42(9): 1285-1299.
- [16] 魏东, 龚庆武, 来文青, 等. 基于卷积神经网络的输电线路区内外故障判断及故障选相方法研究[J]. 中国电

- 机工程学报, 2016, 36(s1):21-28.
- [17] Yang B, Li H. A novel convolutional neural network based approach to predictions of process dynamic time delay sequences [J]. Chemometrics & Intelligent Laboratory Systems, 2018, 174:56-61.
- [18] Gao H, Zhuang L, Maaten L V D, et al. Densely connected convolutional networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, Honolulu.IEEE,2017:2261-2269.
- [19] Kingma D, Leiba J. Adam: A method for stochastic optimization [EB/OL]. (2014-12-22) [2017-01-30]. <https://arxiv.org/abs/1412.6980>.
- [20] 李清毅, 周昊, 林阿平, 等. 基于网格搜索和支持向量机的灰熔点预测[J]. 浙江大学学报(工学版), 2011, 45(12):2181-2187.
- [21] He N, Han R, Wang S. A new multivariate statistical process monitoring method using modified fast ICA [C]//2013 Ninth International Conference on IEEE, USA.IEEE, 2013: 106-110.
- [22] Downs J J, Vogel E F. A plant — wide industrial process control problem [J]. Computers & Chemical Engineering, 1993, 17(3): 245-255.
- [23] Boldt F D A, Rauber T W, Varejao F M. Evaluation of the extreme learning machine for automatic fault diagnosis of the Tennessee Eastman chemical process [C]//Conference of the IEEE Industrial Electronics Society.IEEE, 2014: 2551-2557.
- [24] Gao X, Hou J. An improved SVM integrated GS — PCA fault diagnosis approach of Tennessee Eastman process[J]. Neurocomputing, 2016, 174: 906-911.
- [25] Boldt F D A, Rauber T W, Varejao F M. Cascade feature selection and ELM for automatic fault diagnosis of the Tennessee Eastman process [J]. Neurocomputing, 2017, 239: 238-248.
- [26] Zhang Z, Zhao J. A deep belief network based fault diagnosis model for complex chemical processes[J]. Computers & Chemical Engineering, 2017, 107: 395-407.
- [27] 程健, 杨凌凯, 崔宁, 等. 基于流形嵌入过采样的非平衡数据分类方法[J]. 中国矿业大学学报, 2018, 47(6): 1325-1333.
- [28] Bakdi A, Kouadri A. A new adaptive PCA based thresholding scheme for fault detection in complex systems[J]. Chemometrics and Intelligent Laboratory Systems, 2017, 162: 83-93.

(责任编辑:康 锋)