

文章编号:1005-0523(2020)04-0033-08

DOI:10.16749/j.cnki.jecjtu.2020.04.006

基于 CapsNet 模型的过程故障识别研究

衷路生, 卢文涛

(华东交通大学电气与自动化工程学院, 江西南昌 330013)

摘要: 为了实现过程故障的识别诊断, 文章使用 CapsNet 模型训练数据。首先, 运用网络模型的空间特性, 以向量的形式对训练数据进行特征表示、归一化处理。然后, 进行卷积操作, 在动态一致路由更新上进行故障分类。最后, 增加重构模块来对输入数据矩阵反馈修正, 降低损失误差, 使网络快速收敛。同时, 在每一层网络进行特征可视化, 能清楚看到每一层网络特征图的变化。实验结果表明, 文章模型的过程故障识别性能优于其他神经网络模型。

关键词: CapsNet; 动态路由更新; 故障分类; CNN

中图分类号: TP277 **文献标志码:** A

本文引用格式: 衷路生, 卢文涛. 基于 CapsNet 模型的过程故障识别研究[J]. 华东交通大学学报, 2020, 37(4): 33-40.

Citation format: ZHONG L S, LU W T. Research on process fault identification based on CapsNet model[J]. Journal of East China Jiaotong University, 2020, 37(4): 33-40.

近些年来, 深度学习模型在复杂故障识别任务中表现优异, 并且在许多传统的识别任务中的识别准确率也显著提高^[1-2]。文献[3]提出了深度学习模型架构 ResNet, 利用残差恒等映射层, 减轻了网络的训练, 显著提高了图像识别率。文献[4]提出了一种基于电机状态监测的一维卷积神经网络模型故障检测系统, 具有内在的自适应设计, 把电机故障检测的特征提取和分类融合为一体, 更加快速、高效地完成故障检测。文献[5]提出了基于 LeNet-5 的新型 CNN 故障诊断模型, 将信号转换为二维图像的处理, 快速提取转换后的图像特征。文献[6]提出改进后的 DBN 网络模型, 用 Laplace 函数中的位置参数控制稀疏度, 使无标签的数据特征更加直观地表示出来, 达到更好的准确度。文献[7]提出了一种改进的偏最小二乘法 (IPLS) 用于多种状态过程监测。文献[8]提出基于过程监测和故障诊断 (PM-FD) 的基本数据驱动方法, 在非高斯测量噪声下, 其提出的多数测试方法在 TE 过程具有良好的故障诊断性能。文献[9]探索了无监督局部多层感知分类器在过程故障诊断的应用, 其能区分不同类别的已知故障类型, 提高了神经网络模型的性能。文献[10]提出基于随机优化的变量方案的故障识别方法, 优化测试数据的累积误差。文献[11]提出一种基于可扩展 DBN 的故障诊断模型, 利用全双层反向传播网络训练故障特征, 在 TE 平台上的识别率显著提高。

上述方法在一定程度上改善了深度学习模型在图像识别和故障诊断上的性能, 但仍然存在不足。基于文献[12]的学术思想, 本文提出了一种基于 CapsNet 的过程故障识别模型。

1 TE 化工过程数据的处理及分类

本文以 TE 化工过程的故障诊断为实验对象, TE 化工过程是模拟了 Eastman 化学公司的实际化工的联合反映的一个过程, 此平台已经广泛成为测试各种模型和算法的故障检测及诊断性能的依据^[13]。TE 过程主要包括 20 类故障以及 1 类正常工况。采集样本运行时间为 100 h, 故障为第 20 h 引入, 获取 10 000 个观测数据, 其中前 2 000 个数据为正常样本, 其余 8 000 个数据为故障样本。

从生成的 8 000 个故障样本数据随机选取 6 400 个样本作为训练集, 剩余 1 600 个样本作为测试集。20

收稿日期: 2020-02-12

基金项目: 国家自然科学基金项目 (61863012, 61263010); 江西省科技厅项目 (20181BBE50020, 20161BBE50082, 20161BAB202067)

作者简介: 衷路生 (1979—), 男, 教授, 博士, 主要研究方向故障诊断和检测, 高铁轮轨故障检测。

种故障对应共为 128 000 个训练样本及 32 000 个测试样本。每次随机选取 10 种故障,则有 64 000 个训练样本及其 16 000 测试样本。如图 1 右侧所示,对样本数据训练集的选取。

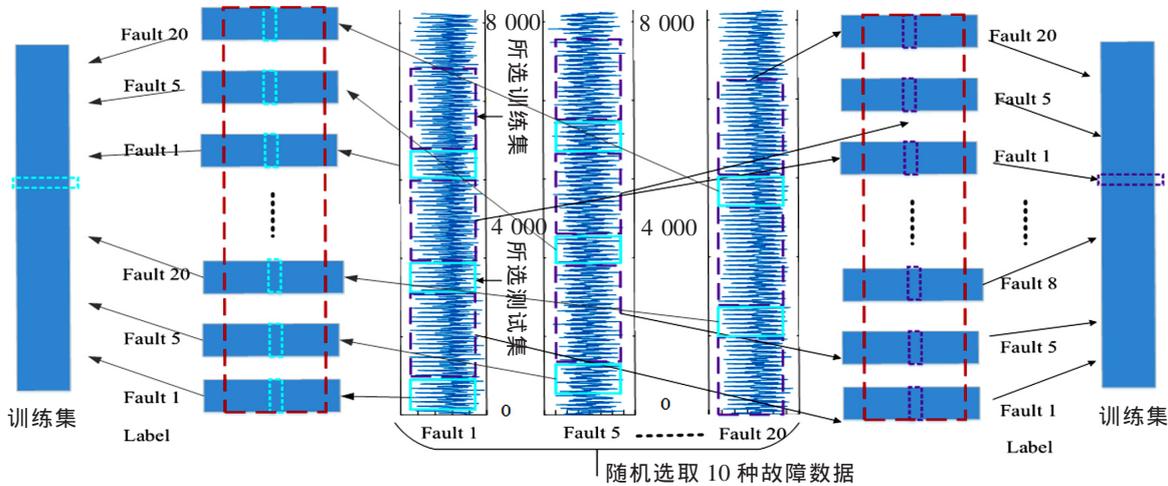


图 1 样本数据集的选取

Fig.1 Selection of sample data set

如图 1 右侧所示,每一种故障数据,从 0 到 8 000 个样本点里,随机选取 6 400 个样本,再进行 10 种故障随机排列,则有 64 000 个样本点作为训练集。最后进行零-均值规范化,对训练集标准化。规范化公式为

$$\chi_j^i = \frac{X_j^i - \mu}{\sigma} \tag{1}$$

式中: i 表示样本数据中的第 i 类故障, j 表示第 i 类故障数据中对应的 53 个变量之一; μ, σ 表示原始故障数据的均值与标准差。

对新生成的故障数据集 χ_j^i ,进行重构,随机选取 49 个变量转换为 7×7 的方形图像,即 $\chi_j^i \in 7 \times 7 \times 64\ 000$ 。基于 7×7 的方形数据图像建立 CapsNet 故障识别网络模型。

2 TE 过程故障模型的建立

从整体结构上,模型可分为故障分类模块、数据重构模块。故障分类模块主要包括:输入层、卷积层、胶囊层,数据重构模块主要利用胶囊网络模型来逆向估计作为训练集输入的 TE 检测数据。图 2 为利用 TE 数据构建的基于 CapsNet 的过程故障识别模型,其中图 2 下方的图形是网络模型各层输出向量的特征可视化图。

从特征图中明显可以看出某类故障已经大致准确预测。充分说明了 CapsNet 对故障分类的有效性和优越性。

2.1 故障分类模块

1) 输入层为重构、归一化所得的 7×7 矩阵,矩阵所包含的 TE 过程数据为 20 类故障以及 1 类正常工况。

2) 第二层是卷积层。该层使用 256 个步幅为 1 的 2×2 卷积核,对输入为 7×7 的检测数据进行卷积,选取 sigmoid 作为神经元的非线性函数。其中,sigmoid 函数、卷积的数学表达式如式(2)式(3)所示,该卷积层得到数据矩阵维数为 6×6 。输出神经元数量为 $256 \times 6 \times 6 = 9\ 216$,权值数量为 $128 \times 10 = 1\ 280$ 。

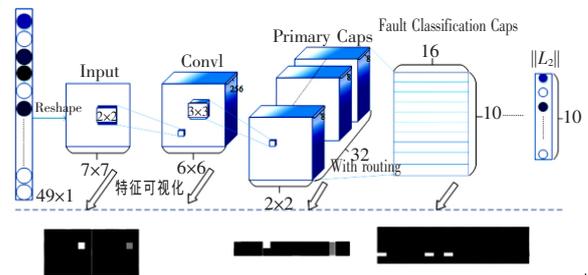


图 2 基于 CapsNet 的过程故障识别模型

Fig.2 Process fault identification model based on CapsNet

$$y = \sigma(x * k + b) \tag{2}$$

$$y(i, j) = \sigma \left(\sum_{u=1}^m \sum_{v=1}^m x(iS-u, jS-v) \cdot k(u, v) + b \right) \quad 0 \leq i, j \leq \frac{n-m}{S} \quad (3)$$

其中用卷积核 $m \times m$ 对 $n \times n$ 的复杂工况故障数据进行步幅 S 的卷积运算。

3) 第三层为初始胶囊层(胶囊层 1),该层包含卷积运算,并作为胶囊层的输入。该层有 32 个通道,每个通道包含 8 维的卷积胶囊。根据式(2)式(3)定义,通道内每个卷积单元对第二层 6×6 的数据矩阵进行卷积运算后得到的 2×2 数据矩阵,因此,该层的输出神经元数量为 $32 \times 8 \times 2 \times 2 = 1\,024$,胶囊数量为 $32 \times 2 \times 2 = 128$,连接第二层和第三层之间的卷积运算的权值数量为 $256 \times 3 \times 3 \times 32 \times 8 + 32 \times 8 = 590\,080$ 。第二层与第三层之间卷积运算组成第三层胶囊的 8 维向量。胶囊层 1 的输出是产生胶囊层 2 的输入向量。

4) 第四层为故障分类胶囊层(胶囊层 2),该层包含 10 组 16 维的故障分类胶囊。

2.2 动态路由更新模块

在网络训练过程中,选择了动态路由算法来预测 TE 过程故障类别,防止了以往神经网络中池化层的故障信息丢失,根据图 2 可知,胶囊层 2 在胶囊层 1 输出 8 维向量的基础上进行传播和路由更新。路由更新如图 3 所示。

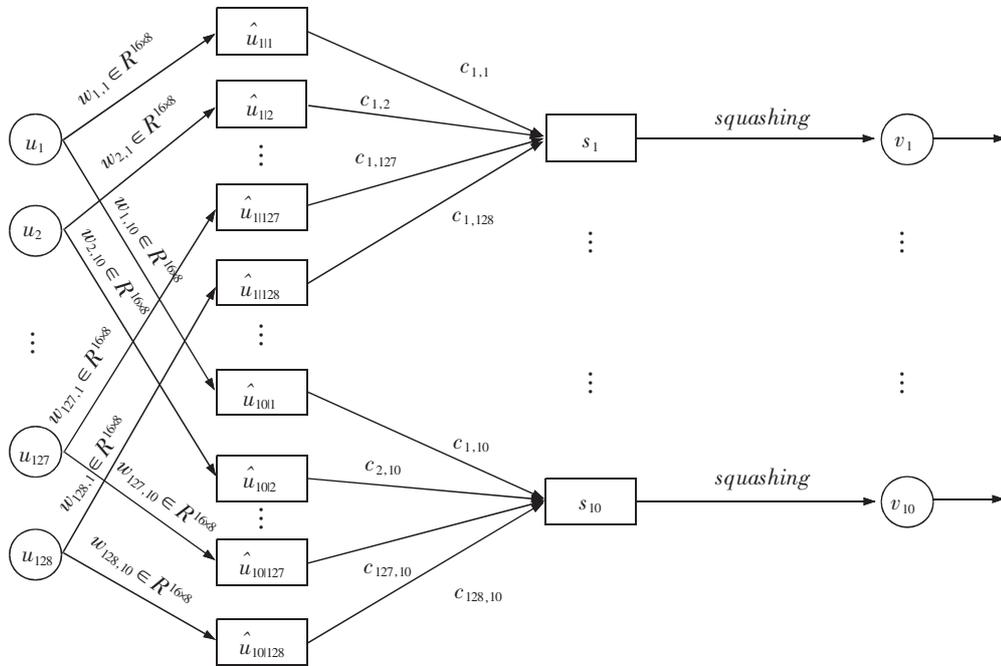


图 3 路由更新

Fig.3 Routing update

胶囊层 1(即低层)的 128 个胶囊的输出向量 $u_i \in R^{8 \times 1}, i=1, 2, \dots, 128$,通过动态路由机制发送到合适的高层胶囊,使得该胶囊能以最大概率表征某类故障的存在性, $u_i \in R^{128 \times 1}$ 被路由到该高层胶囊使得其输出向量的模长 $\|v_j\|$ 最大化,同时保持 u_i 的方向不变,即 u_i 所表征的参数信息被保留到高层胶囊。

$$\hat{u}_{ji} = w_{ji} u_i \quad (4)$$

其中: $u_i \in R^{8 \times 1}, i=1, 2, \dots, 128$ 是低层胶囊的输出向量;变换矩阵 $w_{ji} \in R^{16 \times 8}$ 与 u_i 相乘得到预测向量 $\hat{u}_{ji} \in R^{16 \times 1} (i=1, 2, \dots, 128; j=1, 2, \dots, 10)$ 。变换矩阵 $w_{ji} \in R^{16 \times 8}$ 的参数总量为 $128 \times 10 \times 16 \times 8 = 163\,840$ 。预测向量是来自低层胶囊的预测并对高层胶囊的输出产生的影响。预测结果会给胶囊层 2 提供 TE 故障的参数信息。

$$s_j = \sum_i c_{ij} \hat{u}_{ji} \quad (5)$$

$$\sum_{j=1}^{10} c_{ij} = 1 \quad (6)$$

式中： \hat{u}_{ji} 乘以耦合系数 c_{ij} 作为 s_j 的输入向量。 $c_{ij} \in R^{16 \times 1} (i=1, 2, \dots, 128, j=1, 2, \dots, 10)$ 的参数量为 1 280。当多个预测值达成一致时，就会激活胶囊层 2 中的高级胶囊，其模长值就会变大，模长值最大的高级胶囊所表征的故障类型即为模型故障诊断结果。

$$v_j = \frac{\|s_j\|^2}{1 + \|s_j\|^2 \|s_j\|} \tag{7}$$

式中： $v_j \in R^{16 \times 1}, j=1, 2, \dots, 10$ 是高层胶囊的输出向量； $s_j \in R^{16 \times 1}, j=1, 2, \dots, 10$ 为高层胶囊的输入向量。当 s_j 较小时， $v_j \approx \|s_j\| s_j$ ；当 s_j 较大时， $v_j \approx \frac{s_j}{\|s_j\|}$ 。

胶囊层 2 (即高层) 胶囊的输出向量 $v_j \in R^{16 \times 1}, j=1, 2, \dots, 10$ ，模长 $\|v_j\|$ 表示 TE 过程中某类故障存在的概率，因此必须满足概率条件 $0 \leq \|v_j\| \leq 1$ 。向量 v_j 的方向可表示故障类型。

在迭代过程中，若输出向量与预测向量有很高的相似度，就可以断定这两个胶囊是高度相关的。这种相似性则通过预测向量 \hat{u}_{ji} 和输出向量 v_j 的标量积来衡量的。

$$b_{ij} \leftarrow b_{ij} + \hat{u}_{ji} \cdot v_j \tag{8}$$

最终，耦合系数 c_{ij} 由 b_{ij} 的 softmax 函数计算得到

$$c_{ij} = \frac{e^{b_{ij}}}{\sum_k e^{b_{kj}}} \tag{9}$$

耦合系数 c_{ij} 用来量化低层胶囊与高层胶囊之间的连接，从而计算胶囊的输出。其动态路由更新过程为：初始化 b_{ij} 为 0；根据公式 (9) 计算耦合系数 c_{ij} ；运用式 (4) 式 (5) 计算预测向量及高层胶囊的输入向量；由式 (7) 计算高层胶囊的输出向量；式 (8) 更新相似性 b_{ij} ，然后返回，迭代次数 3 次；计算胶囊输出。

2.3 重构模块

数据重构模块利用胶囊网络模型故障分类模块的结果来编码训练样本的输入数据，即利用胶囊网络模型来逆向估计作为训练集输入的 7×7 的 TE 检测数据，构建三层全连接的网络架构，实现对过程控制系统检测数据的重构/估计。数据重构模块如图 4 所示。

首先，设置重构模块的输入向量。网络训练过程的故障分类胶囊层采用掩蔽方法只保留正确胶囊的激活向量，即胶囊层 L 中对应于训练标签的胶囊输出向量作为活跃向量，而胶囊层 L 中的其他输出向量，则全部设置为零，由此得到 160 维的重构模块输入向量 (除 16 维活跃向量非零外，其余 144 维向量为零)；

然后，将得到的重构模块输入向量传给由三个全连接层组成的解码器，经过三个全连接层的训练，最终输出 7×7 的 TE 数据矩阵，与最初的输入数据矩阵进行比对，从而快速进行反馈修正，使损失误差降为最小。

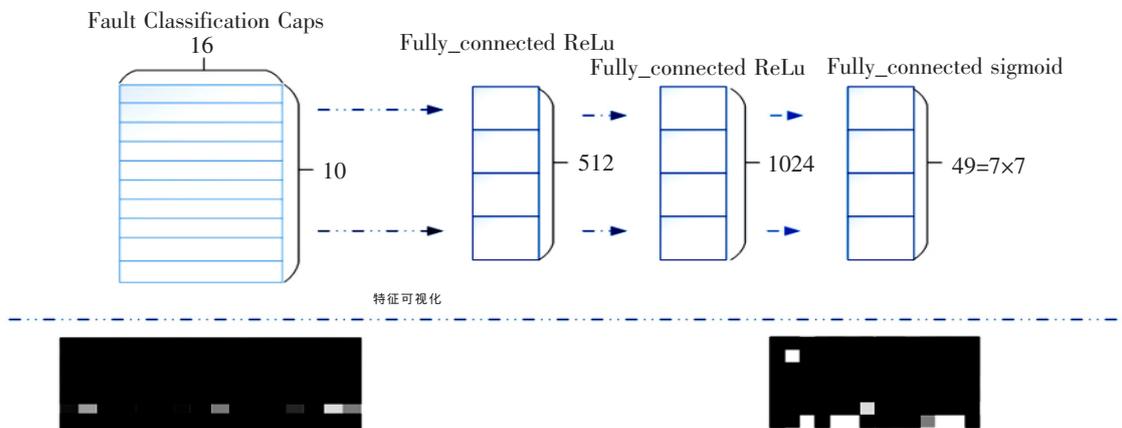


图 4 重构模块

Fig.4 Reconstitution module

3 实验验证

本文采用深度学习框架 Tensorflow^[14]进行实验验证。网络模型设置处理数据的 batch_size 为 100,共对实验数据训练 30 个 epoch。训练集的批量个数为 640(64 000/100=640),每 epoch 迭代 640 次,每次需要 0.3 s。

3.1 特征可视化

针对传统网络训练过程无法熟知每层网络的具体操作的问题,本文对 CapsNet 的每层网络的输出向量进行特征可视化分析,如图 5 所示。

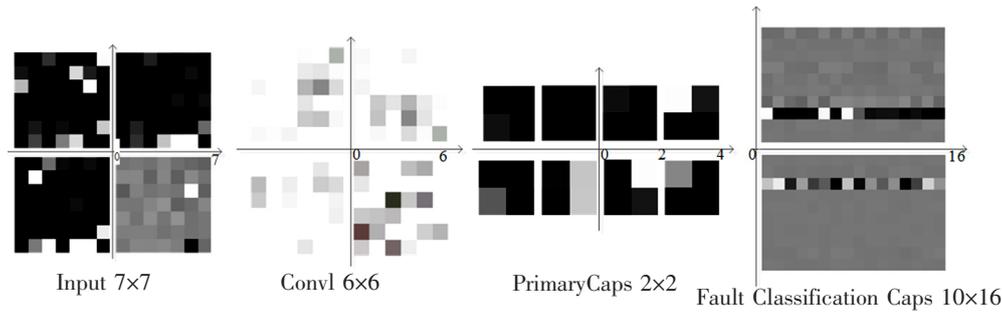


图 5 特征可视化

Fig.5 Feature visualization

首先,将输入从一维故障数据重构为二维 7×7 的图像数据。卷积操作后,可以看出故障数据的某类特征被提取出来,得到新的二维 6×6 的图像。然后,使用步幅为 1 的 3×3 卷积核操作得到 2×2 的图像矩阵,故障特征再次被提取、被细分化。最后,经过动态路由算法更新预测。从得到的 10×16 的输出图像清楚看到,一类故障类型可以被网络快速识别,且识别准确率也极高。

从图 5 所示的故障分类胶囊层可以看出,随机选取的 10 类故障向量是一个 160 维(10×16)的输出矩阵,每行表示一类故障输出,16 维的输出活跃向量与其他输出向量存在明显差异,表明模型能准确识别每一类输入故障。

3.2 实验仿真结果

针对本文所提的 20 种故障数据以及一种正常工况数据,随机进行 4 次实验验证。每次随机选取 10 类不同故障进行训练。这样既可以保证训练集和测试集不重复,又能同时对 20 种故障数据进行识别。

表 1 20 种故障的训练准确率与测试准确率

Tab.1 Training accuracy and test accuracy of 20 kinds of faults

故障	Training accuracy/%	Testing accuracy/%
Random10 Faults 1	96.875 0	92.468 8
Random10 Faults 2	99.218 8	96.137 5
Random10 Faults 3	97.656 3	95.956 3
Random10 Faults 4	98.437 5	97.812 5
mean	98.046 9	95.593 8

从表 1 可以得出:20 种故障的整体训练准确率都达到 96%以上,整体测试准确率均达到 92%以上,说明了模型具有良好的诊断能力。

其次,再对每一类故障样本的数据集进行 3 次测试,每类故障的测试准确率如表 2 所示。

表2 每类故障的测试准确率表
Tab.2 Test accuracy of each type of fault

故障	Test acc1/%	Test acc2/%	Test acc3/%	Mean/%
Fault1	98.742 3	97.631 0	96.011 2	97.461 5
Fault2	99.518 9	99.994 1	98.534 1	99.349 0
Fault3	87.031 9	88.044 9	85.808 9	86.961 9
Fault4	93.292 8	95.869 7	94.544 6	94.569 0
Fault5	92.256 9	90.271 3	89.913 6	90.813 9
Fault6	99.918 5	98.946 1	93.564 9	97.476 5
Fault7	100.00	100.00	100.00	100.00
Fault8	100.00	100.00	100.00	100.00
Fault9	100.00	100.00	100.00	100.00
Fault10	97.051 0	96.937 8	95.897 8	96.628 9
Fault11	97.891 9	98.586 2	97.766 4	98.176 4
Fault12	97.664 8	98.059 1	94.337 3	96.198 2
Fault13	100.00	100.00	100.00	100.00
Fault14	98.153 4	98.075 8	98.991 1	98.533 5
Fault15	96.876 9	96.541 1	96.203 2	96.372 1
Fault16	90.402 5	90.893 4	94.524 4	92.708 9
Fault17	97.592 2	96.854 2	99.557 0	98.705 7
Fault18	100.00	100.00	100.00	100.00
Fault19	90.117 8	90.068 5	94.636 1	92.352 3
Fault20	94.500 1	95.237 4	94.367 8	94.701 8
Mean	96.550 6	96.600 3	96.233 0	96.461 3

如表2中所示,除第三类故障外,其余19类故障的测试准确率都为90%以上,达到预期的实验效果,由于故障3和故障5较难识别,在文献[8,10]中,故障3的识别率仅达到2.37%和10.25%,在文献[8]中,故障5的识别率仅达到34.75%。在本文的20类故障识别里,故障3的测试准确率达到86.96%,故障5的测试准确率为90.81%,实验表明本文提出的故障诊断模型的性能有了明显提高。

随机选取10种故障识别的数据测试仿真图如图6所示。

图6所示,图中实线表示随机选取10种故障识别的训练准确率,图中虚线表示随机选取10种故障识别的测试准确率。当step为0到4000时,训练准确率和测试准确率同时迅速增加为96%和94%左右。4000步之后,增长速度逐渐缓慢,最终均趋于稳定。在此过程中,训练及测试准确率的增长趋势保持同步,有一定的稳定性和一致性。

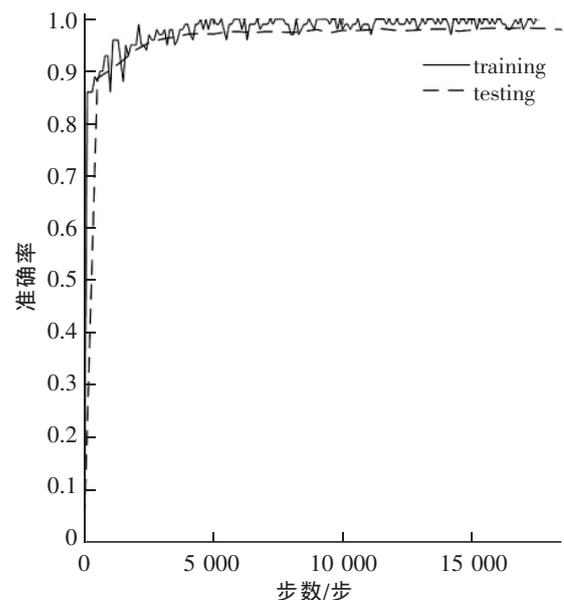


图6 随机选取10种故障识别的数据测试仿真图
Fig.6 Test simulation diagram of randomly selected 10 kinds of fault identification data

总的误差损失为边缘损失误差与重构模块损失误差之和。当迭代次数达到 4 000 次的时候,准确率接近 95%,总的误差损失已经低至 0.1。随着迭代次数的增加,损失值收敛于 0.09。

3.3 实验结果对比

表 3 中,将本文所提过程故障诊断模型的数值仿真结果与同在 TE 过程数据库上进行故障诊断其他故障诊断方法的仿真结果进行对比,本文模型的平均故障分类准确率可达到 95.593 8%,高于现有模型对 TE 过程故障的识别准确率。说明了本模型的故障识别性能较之前模型有显著提高。

表 3 测试结果对比

Tab.3 Comparison of test results

Methods	Mean accuracy/%
PM-FD model	74.58
PCA	77.44
DBN	82.10
This paper	95.593 8

4 结论

本文提出基于 CapsNet 模型的过程故障诊断方法,首先,对输入数据进行预处理,再进入网络模型训练,主要通过动态一致路由更新上进行故障分类,还增加重构模块来对输入数据矩阵及时反馈修正,降低损失误差。实验结果表明 CapsNet 模型比之前模型更适合过程故障识别。同时因为网络结构简单以及网络的空间特性,训练速度及识别准确率都大大提高。

参考文献:

- [1] ZHANG K, ZHOU D H, CHAI Y. Overview on composite fault diagnosis technology[J]. Control Theory & Application, 2015, 32(9): 1143-1157.
- [2] JIANG L, GE Z, SONG Z. Semi-supervised fault classification based on dynamic sparse stacked auto-encoders model[J]. Chemometrics & Intelligent Laboratory Systems, 2017, 168(6): 72-83.
- [3] K HE, X ZHANG, S REN and J SUN. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, United States: CVPR, 2016: 770-778.
- [4] INCE T, KIRANYAZ S, EREN L, et al. Real-time motor fault detection by 1-D convolutional neural network[J]. IEEE Transactions on Industrial Electronics, 2016, 63(11): 7067-7075.
- [5] WEN L, LI X, GAO L, et al. A new convolutional neural network-based data-driven fault diagnosis method[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5990-5998.
- [6] 程焕新, 王建庆. 改进深度置信网络对 TE 过程故障诊断研究[J]. 电子测量技术, 2019, 42(9): 117-120.
- [7] MA HE-HE, HUYI, et al. An Improved PLS (IPLS) method utilizing local standardization strategy for multimode process monitoring[J]. Journal of Donghua University (English Edition), 2012, 29(4): 288-294.
- [8] SHEN Y, DING S, HAGHANI A, et al. A comparison study of basic data-driven fault diagnosis and process monitoring methods on the benchmark Tennessee Eastman process[J]. Journal of Process Control, 2012, 22(9): 1567-1581.
- [9] RAD MA, YAZDANPANAH MJ. Designing supervised local neural network classifiers based on EM clustering for fault diagnosis of tennessee eastman process[J]. Chemometrics and intelligent Laboratory System, 2015, 146(8): 149-157.
- [10] GHOSH K, RAMTEKE M, SRINIVASAN R. Optimal variable selection for effective statistical process monitoring[J]. Computers & Chemical Engineering, 2014, 60(60): 260-276.
- [11] ZHANG Z, ZHAO J. A deep belief network based fault diagnosis model for complex chemical processes[J]. Computers & Chemical Engineering, 2017, 107(12): 395-407.
- [12] SABOUR S, FROSST N, HINTON G E. Dynamic routing between capsules [C]//the 31st Conference on Neural Information Processing Systems, Long Beach, CA, USA. 2017: 3859-3869.
- [13] CHANDRA B, SHARMA R K. Fast Learning on deep neural networks[J]. Neurocomputing, 2015, 171(C): 1205-1215.
- [14] MARTIN ABADI, ASHISH AGARWAL, PAUL BARHAM, et al. Tensorflow: Large-scale machine learning on heterogeneous distributed system[J/OL]. arXiv preprint arXiv: 1603.04467, 2016.

Research on Process Fault Identification Based on CapsNet Model

Zhong Lusheng, Lu Wentao

(School of Electrical and Automation Engineering, East China Jiongtong University, Nanchang 330013, China)

Abstract: In order to realize the recognition and diagnosis of process faults, this paper uses CapsNet model to train data. Firstly, using the spatial characteristics of the network model, the training data was characterized and normalized in the form of vectors. Then, a convolution operation was performed to classify the faults on the dynamic consistent routing update. Finally, the reconstitution module was added to modify the input data matrix, reduce the loss error and make the network converge quickly. At the same time, feature visualization was performed on each layer of the network, and the changes in the feature map of each layer were clearly seen. The experimental results show that the process fault recognition performance of this model is better than other neural network models.

Key words: CapsNet; dynamic routing update; fault identification; CNN

(上接第 32 页)

Analysis of Influence of Water Level Rise and Fall on Seepage Field and Stability of Reservoir Slope

Lei Weijia¹, Liu Weihuang^{2,3}, Guo Shenggen⁴, Tan Yifan^{2,3}, Zhu Junhua^{2,3}

(1. Jiangxi Port and Shipping Administration Border Management Office, Yingtan 335099, China; 2. Jiangxi Key Laboratory of Infrastructure Safety Control in Geotechnical Engineering, East China Jiaotong University, Nanchang 330013, China; 3. Engineering Research & Development Centre for Underground Technology of Jiangxi Province, Nanchang 330013, China; 4. Jiangxi Province Harbor and Shipping Administration, Nanchang 330013, China)

Abstract: Relying on a slope project in a reservoir area, through on-site hydrogeological survey and laboratory tests, to master the geotechnical engineering properties of the bank slope, combined with dry and wet cycle tests, theoretical analysis and numerical simulation software, to study the water storage period of the project and the water level after operation Reservoir bank slope stability under dynamic ups and downs. The results show that the groundwater infiltration line is "concave" at high water levels and "convex" at low water levels. As the water level of the reservoir area rises, the stability of the slope will also increase, and when the water level gradually falls, the stability of the slope will decrease, and eventually the stability of the slope will be lower than that of the slope that has not experienced the change of water level. The water level in the reservoir area can be regarded as the safe water level range between the normal storage level of 30m and the highest storage level of 36m. This study can provide a reference for the slope protection of the reservoir area and the water level scheduling scheme in the reservoir area.

Key words: reservoir slope; dynamic fluctuation of water level; fluid-solid coupling; numerical simulation; slope stability