

基于CNN-集成学习的多风电机组故障诊断

叶祎旎，李艳婷

(上海交通大学 机械与动力工程学院，上海 200241)

摘要：海上风电场地处偏远环境，长期受到盐碱腐蚀。为解决风电机组运行过程中产生的多种故障检测识别问题，在传统卷积神经网络LeNet-5的基础上构建模型。该模型采用ReLU函数作为激活函数，增加了卷积层、池化层和全连接层。针对风电机组的监督控制和数据采集(supervisory control and data acquisition, SCADA)系统及状态监控(condition monitoring, CM)系统所提供的数据集，进行多元类别故障诊断。并对多台风电机组进行聚类分析，应用集成学习方法，构建多风电机组故障诊断模型。实验表明，所提方法取得了97%~99%的诊断精度。通过将实验结果与其他算法进行对比，验证了该方法的有效性。

关键词：故障诊断；LeNet-5网络；监督控制和数据采集；多元类别；集成学习

中图分类号：TP312;TK83 文献标志码：A 文章编号：1007-7375(2022)01-0136-09

Fault Diagnosis of Multi Wind Turbine Based on CNN-Ensemble Learning

YE Yini, LI Yanting

(School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai 200241, China)

Abstract: Offshore wind farms are located in remote environment and have been constantly corroded by saline alkali. In order to solve the problems of multiple-fault detection and identification in the operation process of wind turbines, a model is established based on the traditional convolution neural network LeNet-5. The model adopts the ReLU function as the activation function, and a convolutional layer, a pooling layer and a full connection layer are incepted. Aiming at the datasets of the wind turbine supervisory control and data acquisition (SCADA) system and the condition monitoring (CM) system, a multi-category fault diagnosis is carried out. A cluster analysis is implemented on several wind turbines, followed by ensemble learning to build a multi-machine wind turbine fault diagnosis model. The experimental results indicate that the diagnostic accuracy of the proposed method is 97%~99%. By comparing the experimental results and other algorithms, the effectiveness of the proposed method is verified.

Key words: fault diagnosis; LeNet-5 network; supervisory control and data acquisition (SCADA); multi-category; ensemble learning

风能作为一种可再生的清洁能源，已展现出优异的特性，在世界能源市场上的份额越来越大。我国风电场计划容量显著增加，风电并网容量和装机量也在逐年增长^[1]。但风电机组往往处于偏远恶劣环境，承受着高度变化的随机负载，导致风电机组性能衰退、部件损坏、故障频发。由此导致停机时间增加、风能损失，甚至造成安全事故。因此，对风电机组进行实时状态监控和故障诊断，尽快检测和识别风电机的潜在异常情况，具有重要意义。

大多数故障诊断的方法可以分为基于模型的方

法，基于信号的方法和数据驱动的方法。基于模型的方法包括线性的Takagi-Sugeno (TS)模型^[2]、逻辑斯谛模型^[3]和非线性的威布尔分布模型^[4]、奇偶空间法^[5]等。基于信号的方法包括经典的快速傅立叶变换(fast Fourier transform, FFT)^[6]、短时傅立叶变换(short-term Fourier transform, STFT)^[7]，以及包络分析^[8]、希尔伯特变换^[9]等。风电机组内置的监督控制和数据采集(supervisory control and data acquisition, SCADA)系统记录着大量历史数据，通常采用数据驱动的方法加以分析。高斯过程分类器(Gaussian processes cla-

ssifier, GPC)^[10]、支持向量机(support vector machine, SVM)^[11]都曾被用于故障分类。基于神经网络^[12]的方法近年来也得到深入研究, 包括多层感知器(multilayer perceptron, MLP)、长短时记忆(long short-term memory, LSTM)^[13]、卷积神经网络(convolutional neural network, CNN)^[14]等。

由于风电机组是一个复杂的非线性动态系统, 而本文研究对象未提供有效的故障机理信息, 无法建立准确的数学模型。本文所获得的SCADA数据集具有低频采样、样本小的特点, 不适合应用基于信号的方法。浅层神经网络达不到理想的故障诊断效果, 故本文采用卷积神经网络, 在传统LeNet-5网络结构

基础上进行改进, 进行多风电机组故障诊断研究。

1 数据集介绍

本文所研究的数据, 来自位于上海市浦东新区东海大桥西侧的一个风电场, 研究对象一共包含24台风电机组。该数据包括风电机组的状态监测(condition monitoring, CM)系统和SCADA系统采集到的数据集, 采集时间从2019年1月2日9时30分0秒至2020年1月1日0时0分0秒。

CM数据集包括故障状态码值、状态码描述、故障的激活时间和复位时间。状态码示例如表1所示。

表1 风电机组状态码示例

Table 1 Examples of wind turbine status code

状态码值	状态码描述	激活时间	复位时间
30101	线电压欠压	2019-06-30 06:34:11:455	2019-06-30 06:44:59:979
220011	紧急停机超时	2019-12-19 05:00:55:300	2019-12-19 05:02:41:260
30903	变流器故障(硬件DI)	2019-05-08 16:02:01:277	2019-05-08 16:09:56:190
140011	风轮锁定1未解锁	2019-03-28 09:23:38:059	2019-03-28 11:18:06:448
70031	电机冷却水温度超限	2019-03-31 19:09:01:689	2019-03-31 19:21:04:109

每台风电机组发生的故障数量和故障类型不完全相同, 故障类型主要包括过热故障、主电力供应故障、馈电故障、硬件故障、运行状态异常5大类故障。CM数据集更新时间滞后, 无法及时处理故障。

SCADA系统每隔10 min采样一次, 每台风电机组一共采集到49 549条数据样本和80个数据变量。数据的采样频率较低, 且数据量较少。图1为故障发生时的其中3 000个平均风速、机舱振动传感器、电网频率和塔筒温度按时间序列编号的折线图。

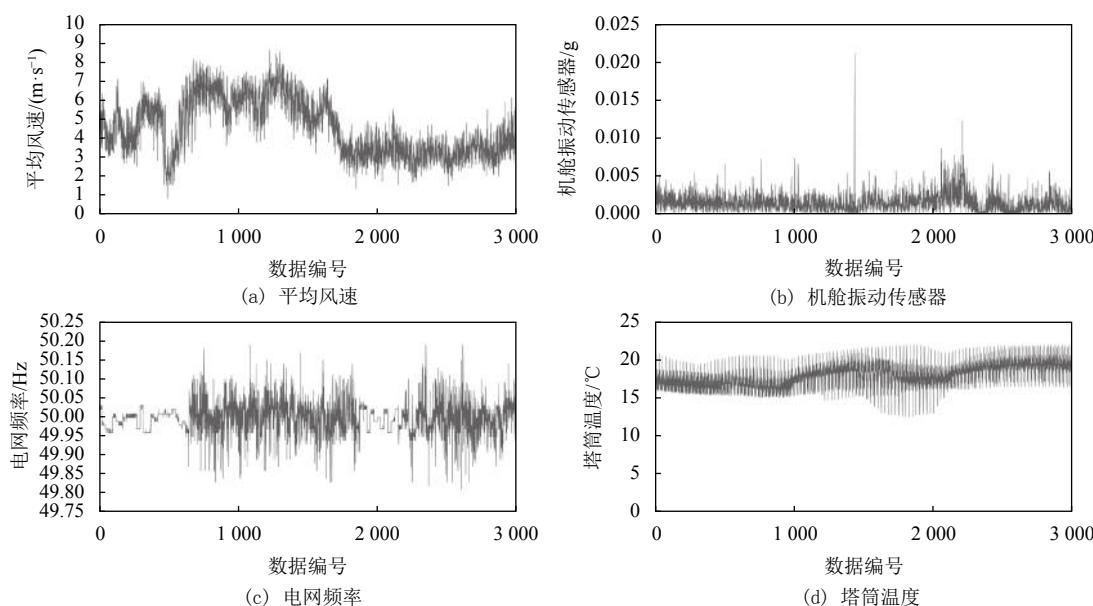


图1 不同特征的时间序列图

Figure 1 Time series plot of different characters

2 风电机组故障诊断方法

2.1 基于改进LeNet-5的风电机组故障诊断过程

基于改进的LeNet-5网络的风电机组故障诊断过程如图2所示。

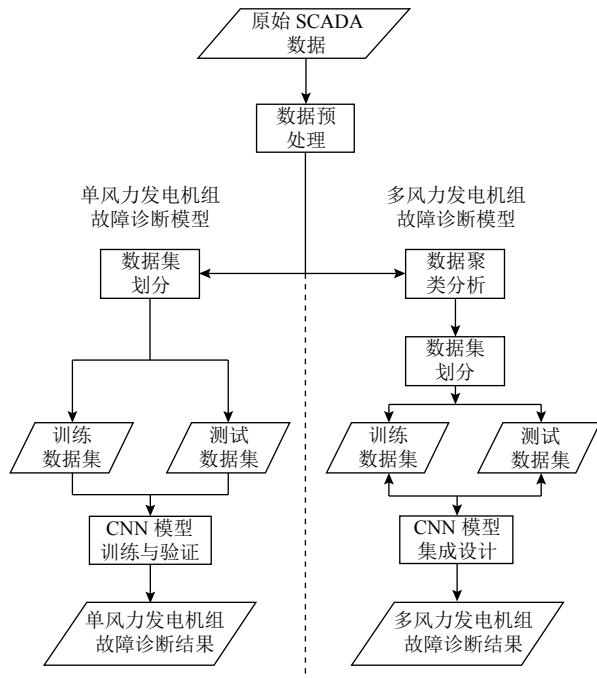


图 2 风电机组故障诊断流程

Figure 2 Fault diagnosis process of wind turbines

首先，对原始SCADA数据集进行预处理。构建单个风力发电机组故障诊断模型时，将所得训练集输入改进的CNN进行训练，模型训练完毕后使用测试集进行测试，检验其有效性。构建多风力发电机组故障诊断模型时，对预处理后的数据集进行聚类分析，利用集成学习方法组合单个CNN模型，并将训练集输入模型进行训练，利用测试集检验模型的有效性。

2.2 数据预处理

不同特征的数值数量级差别较大，故对数据进行Min-Max归一化处理，将数据映射到[0, 1]区间。

数据集具有高达80维的变量，为避免过拟合，采用主成分分析(principal components analysis, PCA)^[15]筛选出30维主要特征。

初步筛选后，将进入故障状态后10 min到该状态改变前10 min数据提取出来，标记状态码值，作为该故障类型的数据。将进入正常状态后30 min到正常状态改变前2 h的数据提取出来，以排除故障状

态前后的过渡数据，确保选定的是无故障数据，并加上标签“0”。

经过数据筛选，标记状态码，发现数据样本存在严重的不平衡问题。以37号风电机组为例，数据集共获得49 206条无故障数据，而状态码为“800002”的数据仅有6条。数据不平衡会影响模型性能，使得模型对少数样本的特征学习不够充分，导致诊断效果变差，不能很好地反映不同类型故障的分类效果。因此，将每类故障数据利用合成少数类过采样(synthetic minority oversampling technique, SMOTE)^[16]方法进行过采样，获得1 000条训练数据和300条测试数据。

2.3 单个风电机组的LeNet-U设计

传统的LeNet-5神经网络是一种基于梯度学习的CNN结构，最初应用于手写体数字字符识别^[17]。其特征提取过程主要采用卷积层的卷积核在数据矩阵上依次移动，进行权值求和，所得值加上偏置后，经过激活函数输入下一层。为了减少神经网络的参数，通常在两个连续的卷积层之间添加池化层，缩小数据规模，增强鲁棒性。针对本文所研究的风电机组SCADA数据集，在传统的LeNet-5基础上进行调整与改进，设计一种新的网络LeNet-U。

1) 添加一个卷积层、一个池化层和一个全连接层。从理论上讲，神经网络越深，特征表达能力越强，但优化问题就越困难。改进的LeNet-U网络可以提取更多的故障特征信息并进行整合，获得更好的训练效果。

2) 选择ReLU函数作为激活函数，如式(1)所示。

$$f(x) = \frac{1}{1 - e^{-x}}. \quad (1)$$

当输入太小或太大时，Sigmoid函数的输出趋于0并接近平滑，不利于权值的更新。Krizhevsky等^[18]讨论了卷积神经网络中不同的激活函数，通过实验发现，ReLU函数不仅可以解决梯度消失问题，而且收敛速度较快。

3) 对卷积核的形状和数量进行调整。传统LeNet-5网络的每个卷积层的卷积核数量较少，有必要仔细调整卷积核的大小和数量以提高故障分类能力。LeNet-U的3个卷积层的卷积核分别为16、32、64个，形状均为1×3。

4) 在卷积之后，采用“padding”操作填充数据。由于卷积之后数据的长度会变短，因此，在数据两

端填充“0”，使卷积前后的数据形状一致，从而在进行下一步池化操作时，尽可能不丢失数据信息。

5) 最初的LeNet-5设置固定学习率，但随着网络层次的加深，同一学习率难以达到最优化的效果。太大的学习率可能导致结果振荡，错过最优解，而

太小的学习率容易导致模型陷入局部最优解。因此，本文设置衰减学习率，随着网络层次的加深自适应地减小学习率，有利于模型的训练。经过初步实验，将初始学习率设为0.001。

改进后的LeNet-U结构如图3所示。

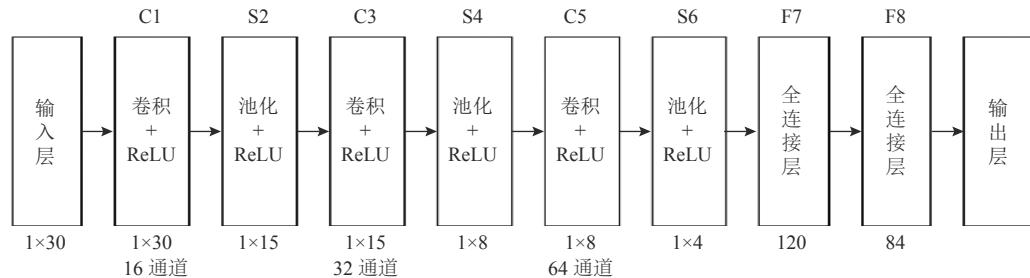


图3 LeNet-U卷积神经网络结构

Figure 3 The structure of convolutional neuro network LeNet-U

对于本文所研究的风电机组数据集，输入层为经过预处理后的SCADA数据，输出层为模型对数据进行诊断所得的故障类型标签。在训练过程中，模型会将输出结果与真值进行对比，自适应地调整隐藏层的权值和偏置，以达到诊断效果的优化目的。

2.4 多风电机组故障诊断模型

由于单个风电机组的某些故障类型数据极少，不利于CNN对数据的学习，影响诊断效果。鉴于不同风电机组的故障类型有重合，同时利用不同风电机组的数据，可使模型对于重合类型故障的数据特征学习更为充分。但不能盲目将不同风电机组之间的数据混合使用，因此，考虑对各台风电机组数据进行聚类分析，并采用集成学习方法，构建多风电机组故障诊断模型。

集成学习的结构如图4所示，通过训练输入数据生成多个基学习器，采用特定策略组合各个学习器的预测结果，提高模型的性能^[19]。

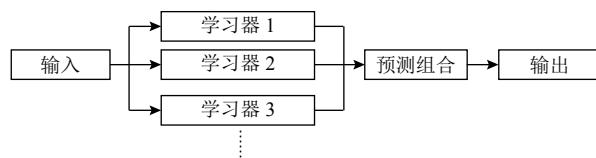


图4 集成学习结构

Figure 4 The structure of ensemble learning

本文将LeNet-U模型作为集成学习的基学习器，采用AdaBoost^[20]和Bagging^[21]两种方法进行集成设计。

AdaBoost最初为训练数据分配相同的权重，得

到初始的LeNet-U模型。在进行下一轮训练时，初始模型中被错误分类的数据权重增加，从而得到新的LeNet-U模型。依次迭代后，最终的故障诊断模型是训练所得的多个LeNet-U模型的加权组合，精度越高的模型权重越大。

Bagging引入自助抽样法来构建故障诊断模型。在训练数据集中均匀、有放回地选取数据样本，分别用于训练不同的LeNet-U模型。当测试数据呈现给每个模型时，使用投票法来组合预测结果，即选取出现次数最多的结果作为故障诊断的类别。

3 实验研究及结果分析

3.1 单台风电机组故障诊断

为评估所提出的LeNet-U模型的有效性，利用单台风电机组的数据集对模型进行训练和测试。为更好地观察模型的训练效果，在训练阶段，每200次迭代进行一次模型测试。以37号风电机组数据集为例，图5和图6显示在故障诊断模型的训练和测试阶段基于LeNet-U网络获得的精度曲线和损失函数曲线。

如图5所示，经过约7 500次迭代，故障分类精度趋于稳定，可达95.32%。如图6所示，损失函数值在前1 000次迭代中迅速减小，然后缓慢减小并接近于0。从图5和图6可以看出，模型训练结果通常接近模型测试结果，且没有欠拟合或过拟合，证明了所提出的故障诊断模型的有效性。

分别使用24台风电机组数据集训练与测试模型，

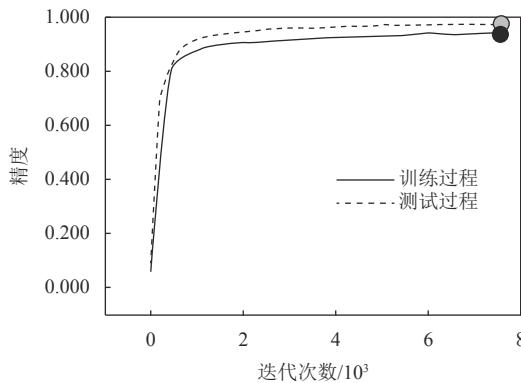


图 5 LeNet-U 模型训练精度曲线

Figure 5 Accuracy curve during the training process of LeNet-U

采用平均精度(AC)和平均召回率(MAR)作为评价指标,所得实验结果如表2所示。

由表2可知,采用LeNet-U模型,在24台风电机组中的17台达到了最优精度,13台达到了95%以上,且召回率也达到了较高水平。另外7台的精度接近最大值,但在召回率上有极好的表现。由于LeNet-U的稀疏连接网络参数较少,相较于SVM、MLP和GPC,不易产生过拟合,更容易达到收敛;

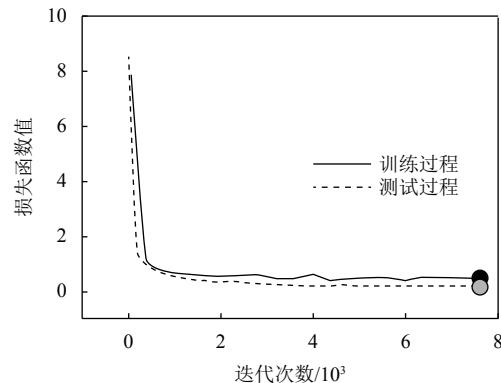


图 6 LeNet-U 模型训练损失函数曲线

Figure 6 Loss curve during the training process of LeNet-U

其多通道网络可以更有针对性地进行特征提取,在不同故障状态都能达到较高的准确率。

以37号风机组为例,其接受者操作特性(receiver operating characteristic, ROC)曲线如图7所示。曲线越接近左上角,模型的性能越好。由图7可知,LeNet-U的诊断效果优于其他3种模型。

综上所述,LeNet-U模型对于本文风机组数据集表现出了优异的性能,不仅在所有类型数据上

表 2 单风电机组故障诊断结果

Table 2 Fault diagnosis results of single wind turbines

%

性能指标	模型	风机组编号											
		37	38	39	40	41	42	43	44	45	46	47	48
AC	LeNet-U	95.32	97.83	93.59	100.00	98.16	98.16	99.33	90.97	94.15	99.50	91.20	98.16
	SVM	93.49	93.16	87.49	98.25	97.66	96.49	97.50	97.00	93.32	95.66	92.48	92.28
	MLP	92.64	90.80	93.59	99.25	98.33	86.12	97.16	91.47	89.30	96.32	89.77	97.66
	GPC	94.32	91.32	56.36	97.74	98.16	93.82	99.67	97.33	92.82	93.66	91.28	96.99
MAR	LeNet-U	99.46	99.74	96.01	100.00	99.49	99.46	100.00	99.45	99.74	100.00	96.72	99.75
	SVM	94.83	94.67	92.00	99.75	98.66	92.67	98.33	98.33	94.50	100.00	92.21	99.50
	MLP	95.51	91.14	94.21	97.54	99.24	99.68	99.25	97.43	97.47	92.65	90.50	96.56
	GPC	99.72	88.24	95.24	95.65	98.98	98.81	99.74	98.73	95.83	97.06	93.75	99.75
性能指标	模型	风机组编号											
		49	50	51	52	53	54	55	56	57	58	59	60
AC	LeNet-U	91.85	99.83	98.50	86.68	88.56	95.99	98.33	93.65	89.95	96.29	99.37	95.48
	SVM	72.97	98.50	97.75	90.98	86.70	93.24	98.16	87.15	91.23	91.09	95.62	90.73
	MLP	67.79	99.00	97.62	83.92	86.55	95.24	97.99	93.98	85.68	94.09	96.12	91.71
	GPC	75.34	99.17	97.12	87.69	85.92	94.87	94.99	93.01	93.98	94.24	95.50	94.97
MAR	LeNet-U	95.57	99.75	99.49	98.58	94.67	99.82	99.74	98.96	100.00	99.22	99.48	98.91
	SVM	72.00	100.00	97.37	95.24	85.50	97.12	98.67	94.83	95.75	97.90	98.87	98.25
	MLP	87.38	98.75	98.83	94.10	91.18	99.29	99.74	97.87	100.00	96.17	90.99	94.60
	GPC	75.88	99.50	98.81	95.16	92.44	99.46	100.00	98.38	97.37	98.22	97.70	97.34

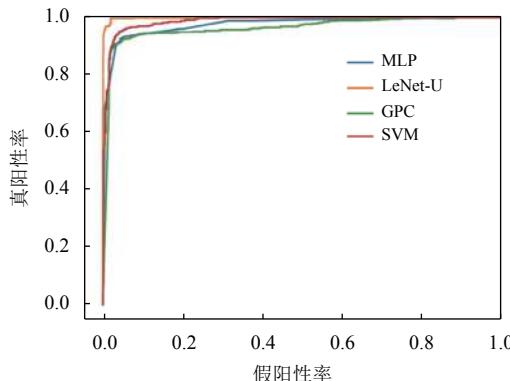


图7 37号风电机组ROC曲线

Figure 7 ROC curve of wind turbine 37

平均精度较高,且能够有效地对故障数据进行准确分类,对于故障诊断和维护具有重要意义。

3.2 多风电机组故障诊断

从表2的结果可以看出,部分风电机组的诊断效果仍存在提升空间。由于某些故障类型数据极少,单独研究时模型对于数据特征的学习不够充分。因此,本文选取诊断精度小于97%的风电机组,进行进一步研究。

采用均值移动算法进行聚类分析后,可得3个聚类,如表3所示。

表3 风电机组聚类结果

Table 3 Clustering results of wind turbines

聚类	风电机组编号
1	52, 53, 57
2	39, 44, 45, 47, 49, 56
3	37, 54, 58, 60

将表3中所得同一聚类的风电机组数据整合到一起,合并相同故障类型数据,整合得到聚类数据集。

分别采用AdaBoost和Bagging的方法集成LeNet-U模型,初始学习率设为0.001,Bagging的采样率设为0.75。利用各个聚类数据集对模型进行训练,可得故障诊断结果如表4所示。

由表4结合表2可知,聚类1、聚类2和聚类3的多风电机组故障诊断精度相对于每一台风电机组单独诊断的精度,提升幅度分别为8.8%~12.07%、3.14%~6.32%和2.45%~3.05%。精度达到90%以上时,这样的提升效果是非常显著的。

3个聚类的混淆矩阵如图8所示。对角线上的方块颜色越深,对应类别的诊断准确度越高,其余方

表4 多风电机组故障诊断结果

Table 4 Fault diagnosis results of multi wind turbines

聚类	模型	基分类器个数	AC/%	MAR/%
1	CNN-AdaBoost	7	97.43	98.77
	CNN-Bagging	8	98.75	99.14
2	CNN-AdaBoost	6	97.29	98.17
	CNN-Bagging	8	96.98	98.13
3	CNN-AdaBoost	6	99.34	99.81
	CNN-Bagging	7	96.26	97.74

块颜色越浅越好。

由图8可知,CNN-集成学习模型不仅能够达到较高的总体诊断精度,对每个故障类型的诊断准确率也十分出色,证实了该多风电机组故障诊断模型的优越性。

综上所述,本文所提出的CNN-集成学习模型具有很强的提取特征的能力,利用集成学习使模型对分类难度大的数据进行更加充分的学习。结合多个强分类器的模型不仅具有较高的分类精度,而且具有稳定的分类性能,应用于小样本数据集的多分类故障诊断问题是有效的,达到了良好的故障诊断效果。

4 结论

本文针对风电机组的故障诊断问题,对采样率较低、样本量较少的多分类SCADA数据集,进行了筛选、标记、平衡处理和数据划分,将卷积神经网络LeNet-5进行改进,增加卷积层、池化层和全连接层,改变卷积核形状和数量,改进激活函数,增加padding操作,设置衰减学习率,从而构建LeNet-U网络,达到优于其他方法的诊断效果。且将风电机组数据进行聚类分析,利用集成学习中AdaBoost和Bagging的方法集成单个LeNet-U模型,构建多风电机组故障诊断模型,达到了优于任一台单风电机组故障诊断的效果,验证了模型的优异性能。

在未来的研究工作中,可以尝试将LSTM神经元与本文构建的卷积神经网络结合,使模型可以充分利用数据集的时序性。另外,还可以考虑在集成学习的模型训练过程中,根据不同类别的分类精度自适应地调整权重,分类精度更低的类别权重降低,进一步提高模型对难以区分的类别的诊断能力。

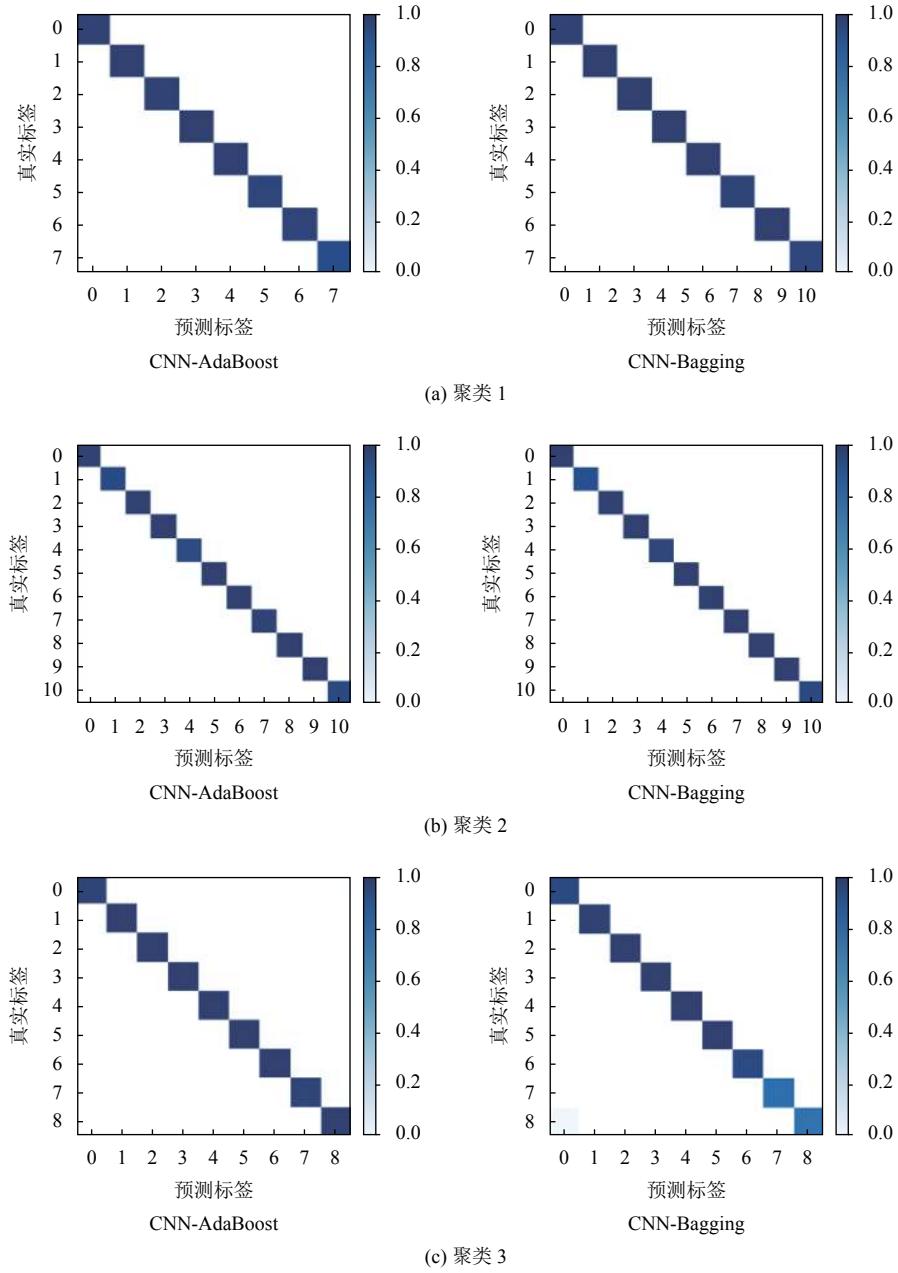


图 8 诊断结果混淆矩阵

Figure 8 Confusion matrices of diagnosis results

参考文献:

- [1] 中国风电产业发展现状及前景展望(下)[J]. 电器工业, 2019 (9): 32-46.
- [2] SIMANI S, CASTALDI P, TILLI A. Data-driven approach for wind turbine actuator and sensor fault detection and isolation[J]. *IFAC Proceedings Volumes*, 2011, 44(1): 8301-8306.
- [3] LYDIA M, SURESH KUMAR S, IMMANUEL SELVAKUMAR A, et al. Wind farm power prediction based on wind speed and power curve models[M]. BHUVANESWARI M, SAXENA J. Intelligent and efficient electrical systems. New York: Springer, 2018: 15-24.
- [4] XIANG Y, VEERAMACHANENI K, YAN Y, et al. Unsupervised learning and fusion for failure detection in wind turbines[C]// 2009 12th International Conference on Information Fusion. Seattle, WA: IEEE, 2009: 1497-1503.
- [5] PISU P, AYALEW B. Robust fault diagnosis for a horizontal axis wind turbine[J]. *IFAC Proceedings Volumes*, 2011, 44(1): 7055-7060.
- [6] 王旭, 孟克其劳, 张占强, 等. 基于Matlab的风力发电机组电能质量测量[J]. 太阳能学报, 2019, 40(5): 1387-1393. WANG Xu, MENGKE Qilao, ZHANG Zhanqiang, et al. Power quality measurement of wind turbines based on matlab[J]. *Acta Energiae Solaris Sinica*, 2019, 40(5): 1387-1393.
- [7] WANG H, LISERRE M, BLAABJERG F. Toward reliable power electronics: challenges, design tools, and opportunities[J]. *IEEE Industrial Electronics Magazine*, 2013, 7: 17-26.
- [8] JONES R M. Enveloping for bearing analysis[J]. *Journal of*

- Sound and Vibration, 1996, 30: 10-15.
- [9] LU D, QIAO W, GONG X, et al. Current-based fault detection for wind turbine systems via Hilbert-Huang transform[C]// Proceedings of the 2013 IEEE Power & Energy Society General Meeting. Vancouver, BC, Canada: IEEE, 2013: 1-5.
- [10] LI Y, LIU S, SHU L. Wind turbine fault diagnosis based on Gaussian process classifiers applied to operational data[J]. *Renewable Energy*, 2019, 134: 357-366.
- [11] TANG B, SONG T, LI F, et al. Fault diagnosis for a wind turbine transmission system based on manifold learning and Shannon wavelet support vector machine[J]. *Renewable Energy*, 2014, 62: 1-9.
- [12] 刘晶, 季海鹏. 基于神经网络的关联规则在故障诊断中的应用[J]. *工业工程*, 2011, 14(2): 118-121.
LIU Jing, JI Haipeng. Neural network based association rules for fault diagnosis[J]. *Industrial Engineering Journal*, 2011, 14(2): 118-121.
- [13] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [14] BACH-ANDERSEN M, RØMER-ODGAARD B, WINTHOR O. Deep learning for automated drivetrain fault detection[J].

(上接第44页)

- [10] 杨磊, 张琴, 张智勇. 碳交易机制下供应链渠道选择与减排策略[J]. *管理科学学报*, 2017, 20(11): 75-87.
YANG Lei, ZHANG Qin, ZHANG Zhiyong. Channel selection and carbon emissions reduction policies in supply chains with the cap-and-trade scheme[J]. *Journal of Management Sciences in China*, 2017, 20(11): 75-87.
- [11] 梁玲, 孙威风, 杨光, 等. 基于低碳偏好的多对一型供应链减排博弈[J]. *统计与决策*, 2019, 35(3): 54-58.
- [12] MADANI S R, RASTI-BARZOKI M. Sustainable supply chain management with pricing, greening and governmental tariffs determining strategies: A game-theoretic approach[J]. *Computers &*

(上接第63页)

- [13] PUGLIESE L D P, GUERRIERO F. Last-mile deliveries by using drones and classical vehicles[C]//International Conference on Optimization and Decision Science. Switzerland: Springer, Cham, 2017: 557-565.
- [14] HAM A M. Integrated scheduling of m-truck, m-drone, and m-depot constrained by time-window, drop-pickup, and m-visit using constraint programming[J]. *Transportation Research Part C: Emerging Technologies*, 2018, 91: 1-14.
- [15] 魏京婷. 京东无人机送出试运营第一单 智慧物流实现乡村落地 [DB/OL]. (2016-06-08). http://finance.ce.cn/rolling/201606/08/t20160608_12654261.shtml.
- [16] BOUZID M C, HADDADENE H A, SALHI S. An integration of Lagrangian split and VNS: the case of the capacitated vehicle routing problem[J]. *Computers & Operations Research*, 2017,

- Wind Energy*, 2018, 21: 29-41.
- [15] HARRINGTON P. Machine learning in action[M]. New York: Manning Publications, 2012: 269-272.
- [16] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: synthetic minority over-sampling technique[J]. *Journal of Artificial Intelligence Research*, 2011, 16(1): 321-357.
- [17] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [18] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [19] WANG G, SUN J, MA J, et al. Sentiment classification: the contribution of ensemble learning[J]. *Decision Support System*, 2014, 57: 77-93.
- [20] FREUND Y, SCHAPIRA R E. A Decision-theoretic generalization of on-line learning and an application to boosting[J]. *Journal of Computer and System Sciences*, 1997, 55(1): 119-139.
- [21] BREIMAN L. Bagging predictors[J]. *Machine Learning*, 1996, 24: 123-140.

(责任编辑: 张广珍)

Industrial Engineering, 2017, 105: 287-298.

- [13] CARTER C R, KALE R, GRIMM C M. Environmental purchasing and firm performance an empirical investigation[J]. *Transportation Research Part E: Logistics and Transportation Review*, 2000, 36(3): 219-228.
- [14] 骆瑞玲, 范体军, 夏海洋. 碳排放交易政策下供应链碳减排技术投资的博弈分析[J]. *中国管理科学*, 2014, 22(11): 44-53.
LUO Ruiling, FAN Tijun, XIA Hajiang. The game analysis of carbon reduction technology investment on supply chain under carbon cap-and-trade rules[J]. *Chinese Journal of Management Science*, 2014, 22(11): 44-53.

(责任编辑: 郑穗华)

78: 513-525.

- [17] DHAHRI A, MJIRDA A, ZIDI K, et al. A VNS-based heuristic for solving the vehicle routing problem with time windows and vehicle preventive maintenance constraints[J]. *Procedia Computer Science*, 2016, 80: 1212-1222.
- [18] DE FREITAS J C, PENNA P H V. A variable neighborhood search for flying sidekick traveling salesman problem[J]. *International Transactions in Operational Research*, 2020, 27(1): 267-290.
- [19] DE FREITAS J C, PENNA P H V. A randomized variable neighborhood descent heuristic to solve the flying sidekick traveling salesman problem[J]. *Electronic Notes in Discrete Mathematics*, 2018, 66: 95-102.

(责任编辑: 刘敏仪)