

基于深度学习的铝电解槽阳极效应预测方法研究

何文

(眉山市博眉启明星铝业有限公司, 四川 眉山 620010)

[摘要] 阳极效应在铝电解生产中最为频发, 对其进行准确预测能够稳定电解铝生产, 降低能耗, 减少事故。本文从深度学习入手, 提出一种基于堆叠降噪自动编码器和长短时记忆网络的预测模型, 利用堆叠降噪自动编码器挖掘关键故障特征信息, 同时利用长短时记忆网络实现故障诊断。本文通过采集某铝厂的历史生产数据对模型进行性能验证, 结果表明, 该模型预测准确率和 F1 分数分别为 97.56% 和 0.968 6。对比分析 BP 神经网络、广义回归神经网络、LSTM 和 SDAE-RF, 本文构建的 SDAE-LSTM 的模型表现最佳, 能准确地对阳极效应进行预报, 在铝电解实际生产中具有重要的指导意义。

[关键词] 铝电解; 深度学习; 故障诊断; 阳极效应; 电解槽; 模型; SDAE-LSTM

[中图分类号] TF821 [文献标志码] A [文章编号] 1672-6103(2022)05-0112-06
DOI:10.19612/j.cnki.cn11-5066/tf.2022.05.016

铝电解生产环境恶劣, 受电场、磁场、流场、温度场、应力场、浓度场相互耦合, 导致铝电解生产过程中故障频发, 造成能耗增加、设备损坏, 甚至人员伤亡等巨大损失^[1-2]。阳极效应在铝电解生产过程中最为常见, 当阳极效应发生时, 电压在短时间内急剧上升, 影响电流效率, 导致能耗增加, 严重时损坏电解槽, 甚至导致人员伤亡, 同时产生 PFCs 等有害气体, 污染环境。因此对铝电解生产过程中发生的阳极效应进行预测具有重要意义。由于铝电解生产受环境等多因素影响, 使得阳极效应的预报存在较大困难。

目前, 国内外学者对阳极效应的预测研究主要集中在基于数据驱动方面。ZHOU 等^[3]结合支持向量机和 K 最邻近算法, 预测精度为 89%。周凯波等^[4]应用广义回归神经网络对预焙槽铝电解阳极效应预报问题展开研究, 结果表明该方法阳极效应的预报准确率平均在 90% 以上。田晔非等^[5]针对当前阳极效应预测方法精度低等缺陷, 设计了一种基于广义回归

神经网络的阳极效应预测模型, 结果显示该模型可以有效地拟合阳极效应变化特点, 具有较高的预测精度。李翹楚等^[6]使用改进的交叉熵算法(Cross Entropy Method, CEM)与支持向量机(Support Vector Machines, SVM)的组合优化算法, 相比传统交叉熵算法, 有效提高了阳极效应预测的准确率。ZHOU 等^[7]利用极端梯度提升机对阳极效应进行预报。PAN 等^[8]首先通过修正邻域互信息计算特征参数与阳极效应之间的关联度进行特征选择, 然后利用轻量梯度提升机算法对阳极效应进行预测。

深度学习具有强大的特征提取能力和非线性映射能力, 能更好地表征复杂的映射关系。目前, 深度学习在航空发动机、滚动轴承、电动汽车、风电机等故障诊断领域均有较为成功的应用。金江涛等^[9]结合卷积神经网络与长短时记忆网络提取信号特征, 并结合支持向量机完成故障分类, 实现对滚动轴承的故障诊断。李东东等^[10]提出一种基于深度特征融合网络的行星齿轮箱故障诊断方法, 经多场景对比实验, 所提方法在行星齿轮箱变速工况下分类效果良好。DE BRUIN 等^[11]利用长短时记忆神经网络实现对铁路轨道电路故障的检测。王鑫等^[12]提出一种基于多层网格搜索的长短时记忆网络方法, 实现对具有时间序列的故障进行预测。

本团队先后提出了基于长短时记忆网络(LSTM)和基于堆叠降噪自动编码器(SDAE)与随

[收稿日期] 2022-08-20 [修订日期] 2022-09-22

[录用日期] 2022-09-24 [出版日期] 2022-10-28

[作者简介] 何文(1968—), 男, 重庆人, 工程师, 主要研究方向为铝电解生产安全管理和故障诊断研究工作。

[基金项目] 国家自然科学基金面上项目(51374268)。



[引用格式] 何文. 基于深度学习的铝电解槽阳极效应预测方法研究[J]. 中国有色冶金, 2022, 51(5): 112-117.

机森林(RF)的阳极效应预测方法^[13-14]。LSTM 充分考虑了前、后样本对当前样本的影响,善于处理时序数据。SDAE 可充分挖掘数据间的关系,提取阳极效应大量原始参数中的关键特征参数,同时利用 RF 对提取出的关键故障特征进行分类。铝电解生产数据具有时序性,LSTM 相对于 RF 能更好地处理铝电解生产数据。因此,本文在团队前期研究基础上提出一种将 SDAE 和 LSTM 结合起来的预测模型,用于铝电解槽阳极效应的诊断预测,以解决关键特征信息遗漏、预测精度低等不足。

1 铝电解工艺及故障

1.1 工艺流程

现代铝工业生产,普遍采用冰晶石-氧化铝熔盐电解法,电解设备为铝电解槽。在冰晶石-氧化铝熔盐电解法中,熔融冰晶石是溶剂,氧化铝作为溶质溶解在其中,以炭素材料作为阴、阳两极。通入强大的直流电后,在两极间发生电化学反应,阴极上的产物为铝液,阳极上的产物为二氧化碳等气体。通入直流电,一方面是利用热能将冰晶石熔化呈熔融状态,并保持恒定的电解温度,另一方面是要实现电化学反应。铝电解化学反应方程见式(1)。



电解槽的阴极,电流通过电解质由炭质阴极流入炭质阳极,完成电解过程。铝电解槽结构如图 2 所示。




图 2 铝电解槽结构
Fig. 2 Aluminum electrolytic cell structure

1.3 常见危害因素

1.3.1 阳极效应

阳极效应是铝电解生产过程中最为常见的一种现象。当阳极效应发生时,电压将在短时间内急剧上升,导致其发生的直接原因与氧化铝浓度有关。当氧化铝浓度过低时,电解质同炭阳极之间的湿润性变差,析出的一氧化碳、二氧化碳、氧气容易聚集在阳极和电解质的界面上,随着阳极气泡的逐渐增多,由小气泡聚合形成较大气泡,形成连续的气体膜,由于气体的绝缘性,阻碍了电流的通过,导致电压升高,由此产生阳极效应。目前关于阳极效应发生的机理,还没有定论,电解质水平、电解槽温度等也是重要影响因素。

阳极效应降低了铝电解电流效率的同时,增加了吨铝能耗,并且缩短电解槽寿命,严重的还会造成设备损坏。而铝电解生产环境复杂,受多种因素交叉影响,且铝电解槽槽况参数繁多,使得阳极效应预测极为困难。在实际生产过程中,目前对阳极效应的预测只能凭借电压单一参数,预测准确率及提前预测时间均有待提高。

1.3.2 漏槽

电解槽漏槽时不仅该槽的运行遭到破坏,同时漏出的高温电解质和铝水可能会冲坏阴极母线和烧毁槽下部设备,从而影响整个系列生产。电解槽的漏槽与内部槽帮结构被破坏有关,槽帮太薄,侧部内衬材料就会被电解质溶液和铝液所侵蚀,槽体结构被破坏,导致电解槽漏槽,造成重大经济损失。

2 方法理论

2.1 堆叠降噪自动编码器(SDAE)

堆叠降噪自动编码器(Stacked Denoising Auto

图 1 铝电解主要生产单元及工艺流程
Fig. 1 Main production unit and process flow of aluminum electrolysis

1.2 铝电解槽结构

工业铝电解槽包括阳极装置、阴极装置、母线装置、电器绝缘 4 个部分。电解槽外部是一个钢制槽壳,内部衬以耐火砖和保温层。以压型炭块镶于槽底作为

Encoder, SDAE) 的基本单元是降噪自动编码器 (Denoising Auto Encoder, DA), SDAE 由多个 DA 堆叠而成, 能有效地提取数据低维特征。对于第一个 DA, 其计算过程见式(2)~(3)。

$$h_{(y)} = \sigma(W_1 y + b_1) \quad (2)$$

$$\hat{X} = W_1^T h_{(y)} + b_2 \quad (3)$$

式中: σ 为激活函数; y 为被噪声污染后的输入数据, $\hat{X}$ 为重构后的输入数据。

损失函数表达式见式(4)。

$$\min_{\arg W, b} L(W, b) = \left[\frac{1}{m} \sum_{i=1}^m \frac{1}{2} \|y^{(i)} - x^{(i)}\|^2 \right] + \frac{\lambda}{2} \sum_{l=1}^{n_1-1} \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (W_{ji}^{(k,l)})^2 + \beta \sum_{j=1}^{s_2} KL(\rho \| \bar{\rho}_j) \quad (4)$$

式中: m 、 n 、 s_l 分别为样本数、网络层数和 l 层单元数; $W_{ji}^{(k,l)}$ 为辨识层间链接权重; $b_i^{(k,l)}$ 为 l 层的单元偏置; $\bar{\rho}_j$ 为隐含层单元平均输出; λ 为权重衰减系数, 同时, $y^{(i)}$ 表达式见式(5)~(7)。

$$y^{(i)} = f(W^{(k,2)} a^{(k,2)} + b^{(k,2)}) \quad (5)$$

$$a^{(k,2)} = f(W^{(k,1)} x^{(i)} + b^{(k,1)}) \quad (6)$$

$$f(z) = \frac{1}{1 + e^{-z}} \quad (7)$$

对权重 W 和偏置 b 进行更新, 得到式(8)。

$$\begin{cases} W_1^T : \Delta W_{i,j} = \varepsilon \frac{\partial J}{\partial \hat{X}_i} \frac{\partial \hat{X}_i}{\partial W_{i,j}} \\ b_2 : \Delta b_i = \varepsilon \frac{\partial J}{\partial \hat{X}_i} \frac{\partial \hat{X}_i}{\partial b_i} \\ b_1 : \Delta b_i = \varepsilon \frac{\partial J}{\partial \hat{X}_i} \frac{\partial \hat{X}_i}{\partial h_{(y)}} \frac{\partial h_{(y)}}{\partial b_i} \end{cases} \quad (8)$$

2.2 长短时记忆网络

长短时记忆网络 (Long Short-Term Memory, LSTM) 充分考虑了过去输入信息对当前样本的影响, 同时可有效解决梯度爆炸和梯度消失问题, 适用于复杂设备或系统的故障诊断。LSTM 由输入门、遗忘门和输出门构成, 通过引入门控循环单元 (Gated Recurrent Unit, GRU) 使自循环的权重可以通过前后单元确定, 其结构如图 3 所示。

LSTM 中, 遗忘门 (Forget gate) 决定过去输出信息对当前输入信息的重要程度, 表达式见式(9)。

$$\Gamma_f^{(t)} = \sigma(W_f[a^{(t-1)}, x^{(t)}] + b_f) \quad (9)$$

式中: $\Gamma_f^{(t)}$ 为遗忘门; W_f 为遗忘门的权值矩阵; b_f 为遗忘门阈值。

更新门 (update gate) 控制更新后的信息所占比




图 3 LSTM 网络基本结构

Fig. 3 Basic structure of LSTM network

例见式(10)。

$$\Gamma_u^{(t)} = \sigma(W_u[a^{(t-1)}, x^{(t)}] + b_u) \quad (10)$$

式中: $\Gamma_u^{(t)}$ 为更新门; W_u 、 b_u 分别为其权值矩阵和阈值。

临时记忆单元由上一时刻的输出内容及现在时刻的输入共同决定, 表达式见式(11)。

$$\tilde{c}^{(t)} = \tanh(W_c[a^{(t-1)}, x^{(t)}] + b_c) \quad (11)$$

式中: $\tilde{c}^{(t)}$ 为临时记忆单元; W_c 为其权值矩阵; b_c 为其阈值。

遗忘门和更新门共同决定记忆单元携带的信息, 见式(12)。

$$c^{(t)} = \Gamma_f^{(t)} c^{(t-1)} + \Gamma_u^{(t)} \tilde{c}^{(t)} \quad (12)$$

式中: $c^{(t)}$ 为记忆单元。

输出门 (output gate) 最终输出信息表达式见式(13)。

$$\Gamma_o^{(t)} = \sigma(W_o[a^{(t-1)}, x^{(t)}] + b_o) \quad (13)$$

$$a^{(t)} = \Gamma_o^{(t)} \tanh(c^{(t)}) \quad (14)$$

式中: $\Gamma_o^{(t)}$ 为输出门; W_o 为输出门的权值矩阵; b_o 为输出门阈值。

3 预测模型

3.1 模型框架

本文提出一种基于堆叠降噪自动编码器和长短时记忆网络的铝电解阳极效应预测方法。首先对数据集进行缺失值和标准化处理, 考虑到目前阳极效应发生的机理和影响因素没有统一的定论, 因此在以往的研究基础上, 为了尽可能避免关键特征的遗漏, 增加了特征参数, 把采集到的全部原始特征参数直接作为输入特征向量, 输入特征参数如表 1 所示。

本文利用堆叠降噪自动编码器对原始输入数据进行关键特征提取,同时通过长短时记忆网络对其进行分类预测,实现对阳极效应的诊断预测,模型框架如图 4 所示。本文在大量实验的基础上,以模型在训练集/验证集/测试集中的准确率作为调参指标,确定模型关键参数,具体超参数设置如表 2 所示。

表 1 模型输入特征参数

Table 1 Model input feature parameters

序号	特征参数
X1	平均电压
X2	工作电压
X3	槽温
X4	分子比
X5	电解质水平
X6	铝水平
X7	铁含量
X8	硅含量
X9	噪声
X10	出铝量
X11	氧化铝浓度
X12	电流密度
X13	电流效率
X14	氟化盐含量
X15	电耗
X16	阳极行程
X17	阴极压降




图 4 SDAE-LSTM 模型结构

Fig.4 Structure of SDAE-LSTM model

3.2 模型评价指标

为了更好地评价和验证模型的性能,本文采用准确率和 $F1$ 分数作为模型性能优劣的评价指标。 $F1$ 分数是用来衡量分类模型精确度的一种指标,它

表 2 SDAE-LSTM 模型超参数设置

Table 2 SDAE-LSTM model hyperparameter setting

方法	超参数	值
SDAE	编码器数量	3
	隐含层激活函数	Relu
	输出层激活函数	$\tanh$
	损失函数	Formula(3,3)
	优化算法	Adam
LSTM	时间步	10
	模型层数	3
	Dropout	0.1
	Recurrent dropout	0.5

同时兼顾了分类模型的查准率 P (precision) 和查全率 R (recall), $F1$ 表达式见式 (14) ~ (16), 准确率表达式见式 (17)。

$$F1 = 2 \frac{PR}{P + R} \tag{14}$$

$$P = \frac{TP}{TP + FP} \tag{15}$$

$$R = \frac{TP}{TP + FN} \tag{16}$$

$$\text{分类准确率} = \frac{\text{正确预测样本数}}{\text{样本总数}} \tag{17}$$

式中: $F1$ 最大值为 1, 最小值为 0, 值越大意味着模型性能越好; TP (True positive) 表示预测答案正确; FP (False positive) 表示预测答案错误; FN (False negative) 表示将本类标签预测为其他类标签。

4 实验验证

本文数据均来源于某铝业公司 360 kA 电流系列铝电解槽,原始数据为 25 台电解槽的日报表(现场槽控机在线自动记录数据和离线化验手动数据等),时间为 2020 年 6 月 1 日至 2021 年 6 月 1 日,共采集了 5 826 个样本,其中正常样本 4 781 个,效应样本 1 045 个,所有样本均匀分布在训练集、验证集和测试集中,具体实验设置如表 3 所示。

4.1 模型性能验证

本文共采集了 5 826 个实验样本,按照 6:2:2 的比例将数据集分为训练集、验证集和测试集。首先在训练集上用于模型训练,然后在验证集上调试超参数、验证模型性能、修正模型,最后在测试集上测试结果,以测试集准确率作为模型的最终性能评估。经过实验验证,评价结果如表 4 所示。阳极效应的预测属于二分类问题,采用点线图能形象直观地表

表 3 实验参数设置

Table 3 The experimental setup

参数	设置值
数据获取时间	2020 年 6 月 1 日至 2021 年 6 月 1 日
电解槽数量	25
特征参数数量	17
实验样本数量	5 826
正常样本	4 781
效应样本	1 045
训练集/测试集/验证集	6:2:2

征模型结果,模型部分预测结果如图 5 所示。

表 4 模型性能评价结果

Table 4 Model performance evaluation results

评价指标	值
TP	4 710
FP	52
FN	253
正确预测样本数	5 684
分类准确率	97.56%
F1 分数	0.968 6




图 5 模型部分预测结果

Fig. 5 Partial prediction results of the model

4.2 不同方法对比

为了验证本文提出的基于深度学习的 SDAE-LSTM 阳极效应预测模型的性能,本文另外单独构建了 BP 神经网络模型、广义回归神经网络模型及团队前期研究的 LSTM、SDAE-RF 模型,在相同的数据集下对几个模型性能进行对比验证,以测试集准确率和 F1 分数作为评估指标,实验结果如图 6 所示。实验结果表明,本文构建的 SDAE-LSTM 模型在准确率和 F1 分数上均具有显著优势。

5 结论

本文重点研究了基于深度学习的铝电解阳极效




图 6 多模型性能对比

Fig. 6 Performance comparison of multiple models

应诊断方法,提出一种基于堆叠降噪自动编码器和长短时记忆网络模型用于铝电解阳极效应诊断中。SDAE 能很好地提取阳极效应大量原始参数中的关键特征参数,LSTM 擅长于处理时序数据和前后关联数据,能很好地找出槽况参数变化趋势和阳极效应之间的联系。本文首先利用堆叠降噪自动编码器挖掘关键故障特征信息,然后利用长短时记忆网络实现对阳极效应的诊断。实验结果显示,相比 BP 神经网络和广义回归神经网络及团队前期提出的 LSTM、SDAE-RF 模型,本文构建的 SDAE-LSTM 模型有更好的表现,在测试集上的预测准确率和 F1 分数分别为 97.56% 和 0.9686,相比表现较好的 SDAE-RF 在预测准确率和 F1 分数上分别提高了 0.8%、1.9%。由此可见,本文验证了所提方法在铝电解阳极效应诊断应用的可行性和有效性,提出的 SDAE-LSTM 预测方法能够为铝电解阳极效应诊断提供更高的精度,对当前铝电解生产具有重要的现实指导意义。

[参考文献]

[1] DION L, MARKS J, KISS L I, et al. Quantification of perfluorocarbons emissions during high voltage anode effects using non-linear approach[J]. Journal of Cleaner Production, 2017, 164: 357-366.

[2] 陈建军, 陈善永. 降低铝电解槽阳极效应生产实践[J]. 中国有色冶金, 2017, 27(S2): 387-389.

CHEN Jianjun, CHEN Shanyong. Production practice of reducing anode effect of aluminum electrolysis[J]. China Nonferrous Metals, 2017, 27(S2): 387-389.

[3] ZHOU K B, XU G F, GUO S H, et al. Anode effect prediction based on support vector machine and K nearest neighbor[C]//2017 Chinese Automation Congress, 2017: 341-345.

[4] 周凯波, 余登志, 曹斌, 等. 基于广义回归网络的铝电解阳极效应预报[J]. 控制工程, 2017, 24(9): 1756-1762.

- ZHOU Kaibo, YI Dengzhi, CAO Bin, et al. Research of anode effect prediction of aluminum electrolysis cell based on Generalized Regression Neural Network [J]. Control Engineering of China, 2017, 24(9): 1756 – 1762.
- [5] 田晔非, 翟渊. 基于广义回归神经网络的阳极效应自动预测[J]. 电子器件, 2018, 41(5): 1291 – 1295.
- TIAN Yefei, ZHAI Yuan. Anodic Effect Automatic Prediction Based on Generalized Regression Neural Network [J]. Chinese Journal of Electron Devices, 2018, 41(5): 1291 – 1295.
- [6] 李翹楚, 潘浩, 陈晓冉. 基于改进交叉熵算法的阳极效应预测方法[J]. 国外电子测量技术, 2019, 38(9): 142 – 146.
- LI Qiaochu, PAN Hao, CHEN Xiaoran. Anode effect prediction method base on improve cross entropy algorithm [J]. Foreign Electronic Measurement Technology, 2019, 38(9): 142 – 146.
- [7] ZHOU K B, ZHANG Z X, LIU J, et al. Anode effect prediction based on a singular value thresholding and extreme gradient boosting approach [J]. Measurement Science and Technology, 2019, 30(1): 015104.
- [8] PAN H, KONG L, CHEN X R, et al. A modified neighborhood mutual information and light gradient boosting machine-based long-term prediction approach for anode effect [J]. Measurement Science and Technology, 2019, 30(11): 115105.
- [9] 金江涛, 许子非, 李春, 等. 基于深度学习与支持向量机的滚动轴承故障诊断研究[J]. 热能动力工程, 2022, 37(6): 176 – 184.
- JIN Jiangtao, XU Zifei, LI Chun, et al. Research on rolling bearing fault diagnosis based on deep learning and support vector machine [J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(6): 176 – 184.
- [10] 李东东, 赵阳, 赵耀, 等. 基于深度特征融合网络的风电机组行星齿轮箱故障诊断方法[J]. 电力系统保护与控制, 2022, 50(10): 1 – 10.
- LI Dongdong, ZHAO Yang, ZHAO Yao, et al. A fault diagnosis method for a wind turbine planetary gearbox based on a deep feature fusion network [J]. Power System Protection and Control, 2022, 50(10): 1 – 10.
- [11] DE BRUIN T, VERBERT K, BABUSKA R. Railway track circuit fault diagnosis using recurrent neural networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(3): 523 – 533.
- [12] 王鑫, 吴际, 刘超, 等. 基于 LSTM 循环神经网络的故障时间序列预测[J]. 北京航空航天大学学报, 2018, 44(4): 772 – 784.
- WANG Xin, WU Ji, LIU Chao, et al. Exploring LSTM based recurrent neural network for failure time series prediction [J]. Journal of Beijing University of Aeronautics and Astronautics, 2018, 44(4): 772 – 784.
- [13] 尹刚, 陈根, 何文, 等. 基于深度学习的 300 kA 铝电解槽阳极效应预测[J]. 中国有色金属学报, 2021, 31(1): 161 – 170.
- [14] YIN Gang, CHEN Gen, HE Wen, et al. Anode effect prediction of 300 kA aluminum electrolysis cell based on deep learning [J]. The Chinese Journal of Nonferrous Metals, 2021, 31(1): 161 – 170.
- [15] 尹刚, 陈根, 何文, 等. 基于 SDAE 和随机森林的铝电解槽阳极效应预测方法研究[J]. 稀有金属, 2021, 45(4): 428 – 436.
- YIN Gang, CHEN Gen, HE Wen, et al. A Method for anode effect prediction of aluminum electrolysis cell based on SDAE and Random Forest [J]. Chinese Journal of Rare Metal, 2021, 45(4): 428 – 436.

Research on prediction method of anode effect of aluminum electrolytic cell based on deep learning

HE Wen

(Meishan Bomei Qimingxing Aluminum Co., Ltd., Meishan 620010, China)

Abstract: Anode effect is the most frequent fault in the aluminum electrolysis production, and accurate prediction of the anode effect can reduce energy consumption and reduce accidents. Starting from deep learning, this paper proposes a prediction model based on stacked noise reduction autoencoder and long short term memory network. The stacked noise reduction autoencoder is used to find key fault feature information, and meanwhile the long short term memory network is used to realize fault diagnosis. Finally, the historical production data of an aluminum factory is collected to verify the performance of the model. The experimental results show that the prediction accuracy and $F1$ score of the model are 97.56% and 0.968 6, respectively. This paper makes a comparative analysis of the BP neural network, generalized regression neural network, LSTM and SDAE-RF. The experimental results show that the SDAE-LSTM model constructed in this paper has the best performance with more accurate prediction of the anode effect, which has important guiding significance for the actual production of aluminum electrolysis.

Key words: aluminium electrolysis; deep learning; fault diagnosis; anode effect; electrolytic cell; model; SDAE-LSTM